

Hochaufgelöste Erfassung zukünftiger Klimarisiken für Land- und Forstwirtschaft in Unterfranken

Inaugural-Dissertation zur Erlangung der Doktorwürde der
Philosophischen Fakultät
der
Julius-Maximilians-Universität Würzburg

vorgelegt von:

Luzia Esther Keupp
aus
Würzburg

Würzburg
2023



Erstgutachter: Prof. Dr. Heiko Paeth

Zweitgutachter: Prof. Dr. Roland Baumhauer

Tag des Kolloquiums: 29.11.2023

„Models are useful distillations of reality. Although wrong by definition, they are the wind that blows away the fog and cuts through the untamed masses of data to let us see answers to our questions.“

– D.K. Keller (The Tao of Statistics 2016)

Zusammenfassung

Das Klima und seine Veränderungen wirken sich direkt auf die Land- und Forstwirtschaft aus. Daher ist die Untersuchung der zukünftigen Klimarisiken für diese Sektoren von hoher Relevanz. Dies ist auch und vor allem für den schon heute weiträumig trockenheitsgeprägten und vom Klimawandel besonders betroffenen nordwestbayerischen Regierungsbezirk Unterfranken der Fall, dessen Gebiet zu über 80 % land- oder forstwirtschaftlich genutzt wird. Zur Untersuchung der Zukunft in hoher räumlicher Auflösung werden Projektionen von regionalen Klimamodellen genutzt. Da diese jedoch Defizite in der Repräsentation des beobachteten Klimas der Vergangenheit aufweisen, sollte vor der weiteren Verwendung eine Anpassung der Daten erfolgen. Dies geschieht in der vorliegenden Arbeit am Beispiel des regionalen Klimamodells REMO im Bezug auf klimatische Kennwerte für Trockenheit, Starkniederschlag, Hitze sowie (Spät-)Frost, die alle eine hohe land- und forstwirtschaftliche Bedeutung besitzen. Die Datenanpassung erfolgt durch zwei verschiedene Ansätze. Zum Einen wird eine Biaskorrektur der aus Globalmodell-angetriebenen REMO-Daten berechneten Indizes durch additive und multiplikative Linearskalierung sowie empirische und parametrische Verteilungsanpassung durchgeführt. Zum Anderen wird ein exploratives Verfahren auf Basis von Model Output Statistics angewandt: Lokale und großräumige atmosphärische Variablen von REMO mit Reanalyseantrieb, die eine zeitliche Korrespondenz zu den Beobachtungen aufweisen, dienen als Prädiktoren für die Aufstellung von Transferfunktionen zur Simulation der Indizes. Diese Transferfunktionen werden sowohl mithilfe Multipler Linearer Regression als auch mit verschiedenen Generalisierten Linearen Modellen konstruiert. Sie werden anschließend genutzt, um Analysen auf Basis von biaskorrigierten Globalmodell-angetriebenen REMO-Prädiktoren durchzuführen. Sowohl für die Biaskorrektur als auch die Model Output Statistics wird eine Kreuzvalidierung durchgeführt, um die Ergebnisse unabhängig vom jeweiligen Trainingszeitraum zu untersuchen und die jeweils besten Varianten zu finden. Werden beide Verfahren mit ihren Unterkategorien für den gesamten historischen Modellzeitraum verglichen, so weist für alle Monat-Kennwert-Kombinationen eine der beiden Verteilungskorrekturen die besten Ergebnisse auf. Die Zukunftsprojektionen unter Verwendung der jeweils erfolgreichsten Methode zeigen im regionalen Durchschnitt für das 21. Jahrhundert negative Trends der (Spät-)Frost- und Eis- sowie

positive Trends der Hitzetagehäufigkeit. Winterliche Starkregenereignisse nehmen hinsichtlich ihrer Anzahl zu, im Sommer verstärkt sich die Trockenheit. Die Hinzunahme zwei weiterer regionaler Klimamodelle bestätigt die allgemeinen Zukunftstrends, jedoch ergeben sich beim Spätfrost Widersprüche, wenn dieser hinsichtlich der thermisch abgegrenzten Vegetationsperiode definiert wird.

Zusätzlich werden die Model Output Statistics auf gleiche Weise mit bodennahen Prädiktoren zur Simulation von Erträgen aus Acker- und Weinbau wiederholt. Die Güte kann aufgrund mangelnder Beobachtungsdatenlänge nur anhand der Reanalyse-angetriebenen REMO-Daten abgeschätzt werden, ist hierbei jedoch deutlich besser als im Bezug auf die Kennwertsimulation. Die Zukunftsprojektionen von REMO sowie drei weiterer Regionalmodelle zeigen im Mittel über alle Landkreise Unterfrankens steigende Winter- sowie sinkende Sommerfeldfruchterträge. Hinsichtlich der Frankenweinerträge widersprechen sich die Ergebnisse der drei Klassen Weiß-, Rot- und Gesamtwein insofern, als dass REMO und ein weiteres Modell negative Weiß- und Rotweinertragstrends, jedoch positive Gesamtweinertragstrends simulieren. Die zwei anderen verwendeten Modelle führen durch positive Trendvorzeichen für den Weißwein zu insgesamt kohärenten Ergebnissen.

Die Resultate im Bezug auf die land- und forstwirtschaftlich relevanten klimatischen Kennwerte bedeuten, dass Anpassungsmaßnahmen gegenüber Hitze sowie im Speziellen gegenüber Trockenheit in Zukunft im ohnehin trockenheitsgeprägten Unterfranken an Bedeutung gewinnen werden. Auch die unsicheren Projektionen im Bezug auf die Spätfrostgefahr müssen im Blick behalten werden. Die Trends der Feldfruchterträge deuten in die gleiche Richtung, da Sommergetreide eine höhere Trockenheitsanfälligkeit besitzen. Die unklaren Ergebnisse der Weinerträge hingegen lassen keine eindeutigen Schlüsse zu. Der starke anthropogene Einfluss auf die Erntemengen sowie die großen Unterschiede der Rebsorten hinsichtlich der klimatischen Eignung könnten ein Grund hierfür sein.

Abstract

There is a direct impact of climate and its modifications on agriculture and forestry. For this reason, analyzing future climate risks concerning these sectors is highly important. This is also and particularly the case for the northwestern Bavarian administrative district of Lower Franconia, which is characterized by dry conditions even today and which is especially affected by climate change. Additionally, more than 80 % of its area is used for agriculture or forestry. To study future conditions in high spatial resolutions, projections of regional climate models are used. As these show deficits in the representation of the observed climate of the past, an adaption of the data should happen before application. In the study at hand, this is done using the example of the regional climate model REMO regarding climatic indices for dryness, heavy precipitation, and heat as well as (late) frost, all of which are of high agricultural and silvicultural relevance. Adaption of the data is handled via two different approaches. On the one hand, a bias correction of the indices calculated from REMO data based on global climate model output is done using additive and multiplicative linear scaling as well as empirical and parametric distribution adaption. On the other hand, an explorative technique based on model output statistics is applied: Local and large-scale atmospheric variables of REMO run with reanalysis data, possessing a temporal correspondence with observations, are used as predictors for the derivation of transfer functions for simulating the indices. The transfer functions are constructed by means of Multiple Linear Regression as well as different Generalized Linear Models. Subsequently, they are used for analyses based on bias corrected REMO predictors run with global climate model data. Both bias correction and model output statistics are performed in a cross-validated manner for examining the results independently from the training period and finding the best alternative for each situation. When comparing both methods with their subcategories for the entire historical model period, for all month-index-combinations one of the distribution correction techniques exhibits the best results. Future projections using the most successful method for each situation show negative trends of (late) frost and ice as well as positive trends of heat day occurrence for the 21st century. The number of heavy precipitation days increases in winter, dryness amplifies in summer. When taking into consideration two additional regional climate models, the general future trends are confirmed. Nevertheless, discrepancies result regarding

late frost when the respective vegetation period is demarcated based on temperature in contrast to monthly delineation.

Additionally, model output statistics are repeated in the same manner using near-surface predictors for simulating yield of agriculture and viticulture. Estimation of quality can only be performed on the basis of reanalysis-run REMO data as the duration of the observational data is too short. However, the respective results show a much better performance than for the index simulations. Averaging all rural districts of Lower Franconia, future projections of REMO as well as three additional regional models show rising yields for winter as well as falling yields for summer crops. With respect to the yield of Franconian wine, the results of the three analyzed classes of white, red and total wine disagree as REMO and one additional model simulate negative white and red wine, but positive total wine yields. More consistent results are achieved using the other models, which project positive trend signs for white wine.

The outcomes concerning climatic indices of agricultural and silvicultural relevance imply a future gain of importance of adaption measures towards heat and particularly dryness in Lower Franconia which is already drought-affected today. Furthermore, uncertainty in the projections of late frost has to be kept in mind. The resulting trends of agricultural yield point along the same lines as summer crops are more drought-sensitive. However, the ambiguity of the wine yield results impede precise conclusions. A reason for this could be the strong anthropogenic influence on yields as well as the great differences between grape varieties regarding their climatic suitability.

Inhaltsübersicht

| | |
|---------------------------------------------|--------------|
| Zusammenfassung | I |
| Abstract | III |
| Abbildungen | XIII |
| Tabellen | XVI |
| Abkürzungen | XIX |
| Mathematische Symbole | XXIII |
| 1 Einleitung | 1 |
| 2 Untersuchungsgebiet und Zielgrößen | 15 |
| 3 Daten | 29 |
| 4 Methoden | 37 |
| 5 Klimatische Kennwerte | 87 |
| 6 Ertragszahlen | 179 |
| 7 Diskussion | 189 |
| 8 Schlussfolgerungen und Ausblick | 249 |
| Literatur | 254 |
| Anhang | A1 |
| Danksagung | |

Inhaltsverzeichnis

| | |
|--------------------------------------------------------------------|--------------|
| Zusammenfassung | I |
| Abstract | III |
| Abbildungen | XIII |
| Tabellen | XVI |
| Abkürzungen | XIX |
| Mathematische Symbole | XXIII |
| 1 Einleitung | 1 |
| 1.1 Hintergrund, Motivation und Relevanz | 1 |
| 1.1.1 Anthropogener Klimawandel | 3 |
| 1.1.2 Land-, Forstwirtschaft und Weinbau in Unterfranken | 4 |
| 1.1.3 Klima und Land- bzw. Forstwirtschaft sowie Weinbau | 4 |
| 1.2 Klimamodelle | 6 |
| 1.2.1 Globale Klimamodelle | 6 |
| 1.2.2 Regionale Klimamodelle | 7 |
| 1.3 Zielsetzungen und Vorgehensweise | 11 |
| 2 Untersuchungsgebiet und Zielgrößen | 15 |
| 2.1 Untersuchungsgebiet | 15 |
| 2.1.1 Naturraum und Geologie | 16 |
| 2.1.2 Klima | 19 |
| 2.1.3 Boden | 22 |
| 2.1.4 Nutzung: Land- und Forstwirtschaft | 24 |
| 2.2 Kenngrößenwahl | 25 |
| 2.3 Indexberechnung | 27 |
| 3 Daten | 29 |

| | | |
|----------|------------------------------------------------------------------|-----------|
| 3.1 | Beobachtungsdaten | 29 |
| 3.1.1 | Klimavariablen | 29 |
| 3.1.2 | Erträge aus Landwirtschaft und Weinbau | 30 |
| 3.2 | Modelldaten | 31 |
| 3.3 | Vorverarbeitung | 35 |
| 4 | Methoden | 37 |
| 4.1 | Statistische Grundlagen und Definitionen | 37 |
| 4.1.1 | Univariate Deskriptive Statistik | 37 |
| 4.1.2 | Bivariate Deskriptive Statistik | 39 |
| 4.1.3 | Anpassungstest | 41 |
| 4.2 | Güteabschätzung und Modellvalidierung | 41 |
| 4.2.1 | Bias | 42 |
| 4.2.2 | Verteilungsmaße | 42 |
| 4.3 | Biaskorrektur | 43 |
| 4.3.1 | Linearskalierung | 45 |
| 4.3.2 | Verteilungskorrekturen | 45 |
| 4.3.2.1 | Nicht-parametrisches Quantilmapping | 45 |
| 4.3.2.2 | Parametrisches Quantilmapping | 47 |
| 4.3.3 | Bootstrapping und Auswahlverfahren | 50 |
| 4.3.4 | Nachgelagerte Wertebereichkorrekturen | 51 |
| 4.4 | Model Output Statistics | 51 |
| 4.4.1 | Lineare Regression | 54 |
| 4.4.1.1 | Einfache Lineare Regression | 54 |
| 4.4.1.2 | Multiple Lineare Regression | 55 |
| 4.4.1.3 | Voraussetzungen | 57 |
| 4.4.2 | Generalisierte Lineare Modelle | 58 |
| 4.4.2.1 | Zählraten | 62 |
| 4.4.2.2 | Verhältniszahlen und nach oben begrenzte Zählvariablen | 63 |
| 4.4.2.3 | Positiv-kontinuierliche Daten | 65 |
| 4.4.2.4 | GLM-Parameterschätzung | 66 |
| 4.4.2.5 | Dispersionsparameter und Quasi-Likelihood | 69 |
| 4.4.3 | Prädiktorenvorbereitung | 70 |
| 4.4.3.1 | Prädiktorvariablen | 70 |

| | | |
|----------|---------------------------------------------------------------------------|-----------|
| 4.4.3.2 | Hauptkomponentenanalyse | 73 |
| 4.4.3.3 | Fenster | 77 |
| 4.4.3.4 | Zeitversatz | 77 |
| 4.4.4 | MOS REMO-Eval | 78 |
| 4.4.4.1 | MLR oder GLM? | 78 |
| 4.4.4.2 | Optionen | 80 |
| 4.4.4.3 | Durchführung | 81 |
| 4.4.5 | Übertragung MOS auf REMO-MPI-Prädiktoren | 84 |
| 5 | Klimatische Kennwerte | 87 |
| 5.1 | Modellvalidierung | 88 |
| 5.1.1 | Durchschnittswerte: Prozentualer Bias der arithmetischen Mittel | 88 |
| 5.1.2 | Streuung: Prozentualer Bias der Standardabweichungen | 90 |
| 5.1.3 | Verteilung: Prozentualer Quantil-RMSE | 92 |
| 5.1.4 | Verteilung: Q-Q-Plots | 94 |
| 5.2 | Biaskorrektur | 97 |
| 5.2.1 | Durchschnittswerte: Prozentualer Bias der arithmetischen Mittel | 98 |
| 5.2.2 | Streuung: Prozentualer Bias der Standardabweichungen | 111 |
| 5.2.3 | Verteilung: Prozentualer Quantil-RMSE | 122 |
| 5.2.4 | Verteilung: Q-Q-Plots | 132 |
| 5.3 | Model Output Statistics | 132 |
| 5.3.1 | MOS REMO-Eval | 132 |
| 5.3.1.1 | Optionen | 132 |
| 5.3.1.2 | Prädiktoren | 136 |
| 5.3.1.3 | Anzahl Gitterzellen mit gültigem Modell | 138 |
| 5.3.1.4 | Modellgüte | 140 |
| 5.3.2 | MOS REMO-ESM | 141 |
| 5.3.2.1 | Durchschnittswerte: Prozentualer Bias der arithmetischen Mittel | 142 |
| 5.3.2.2 | Streuung: Prozentualer Bias der Standardabweichungen | 148 |
| 5.3.2.3 | Verteilung: Prozentualer Quantil-RMSE | 153 |
| 5.3.2.4 | Verteilung: Q-Q-Plots | 158 |
| 5.4 | Synthese | 160 |
| 5.4.1 | Ergebnisüberblick REMO | 160 |

| | | |
|----------|--------------------------------------------------------|------------|
| 5.4.1.1 | pQRMSE zur Selektion der besten Methode | 161 |
| 5.4.1.2 | Indexmittelwerte | 167 |
| 5.4.2 | Zukunftsprojektionen REMO | 169 |
| 5.4.2.1 | Monatlich aufgelöste Indizes | 169 |
| 5.4.2.2 | Spätfrost | 171 |
| 5.4.3 | Anwendung auf Multimodellensemble | 172 |
| 5.4.3.1 | Monatlich aufgelöste Indizes | 172 |
| 5.4.3.2 | Spätfrost | 175 |
| 5.4.4 | Gesamtsynthese | 177 |
| 6 | Ertragszahlen | 179 |
| 6.1 | MOS REMO-Eval | 179 |
| 6.1.1 | Optionen | 179 |
| 6.1.2 | Prädiktoren | 180 |
| 6.1.3 | Modellgüte | 181 |
| 6.2 | Zukunftsprojektionen | 184 |
| 6.3 | Anwendung auf Multimodellensemble | 185 |
| 6.4 | Gesamtsynthese | 187 |
| 7 | Diskussion | 189 |
| 7.1 | Pflanzenproduktion und Klimawandel | 189 |
| 7.1.1 | Wechselwirkungen zwischen Klima und Pflanzen | 189 |
| 7.1.2 | Stagnationen europäischer Ackerfrucherträge | 194 |
| 7.1.3 | Feldfrüchte und ihre klimatischen Ansprüche | 196 |
| 7.1.3.1 | Körnergetreide | 196 |
| 7.1.3.2 | Andere betrachtete Feldkulturpflanzen | 197 |
| 7.1.3.3 | Klimatische Anbaubeschränkungen | 198 |
| 7.1.4 | Simulation von Feldfrucherträgen | 198 |
| 7.1.4.1 | Prozessbasierte Modelle | 198 |
| 7.1.4.2 | Statistische Modelle | 200 |
| 7.1.4.3 | Ergebnisse der Simulationen | 204 |
| 7.1.5 | Anpassungsmaßnahmen | 205 |
| 7.1.6 | Weinbau | 207 |
| 7.1.6.1 | Studienlage im Bezug auf den Klimawandel | 207 |

| | | |
|---------|-------------------------------------------------------------------------------|-----|
| 7.1.6.2 | Exkurs: Rebsorten im Frankenweingebiet und deren thermische Eignung | 211 |
| 7.1.7 | Forstwirtschaft | 214 |
| 7.1.7.1 | Direkte und indirekte Wirkung klimatischer Veränderungen . | 214 |
| 7.1.7.2 | Modellierung der Forsterträge | 216 |
| 7.1.7.3 | Dürresommer 2018 | 217 |
| 7.1.7.4 | Forstliche Anpassung an den Klimawandel | 218 |
| 7.2 | Zusammenfassender Ergebnisüberblick | 227 |
| 7.2.1 | Modellvalidierung REMO | 227 |
| 7.2.2 | Biaskorrektur | 227 |
| 7.2.3 | Model Output Statistics | 229 |
| 7.2.3.1 | MOS REMO-Eval | 229 |
| 7.2.3.2 | MOS REMO-ESM | 230 |
| 7.2.4 | Biaskorrektur, MOS und Zukunftsprojektionen | 231 |
| 7.2.5 | Erträge aus Landwirtschaft und Weinbau | 231 |
| 7.3 | Diskussion der Ergebnisse | 232 |
| 7.3.1 | Biaskorrekturmethoden und deren Erfolg | 232 |
| 7.3.2 | MOS | 233 |
| 7.3.2.1 | Güte | 233 |
| 7.3.2.2 | Exkurs: Frankenweinsimulation mit gewichtetem Modellmittel | 235 |
| 7.3.2.3 | Prädiktoren | 236 |
| 7.3.2.4 | Exkurs: Spätfrostsimulation auf GCM-Basis | 237 |
| 7.3.3 | Zukunftsprojektionen klimatischer Kennwerte | 238 |
| 7.3.3.1 | Exkurs: Auswirkungen des Spätfrostereignisses im Mai 2020 | 242 |
| 7.3.3.2 | Implikationen der projizierten klimatischen Veränderungen . | 243 |
| 7.3.4 | Zukünftige Ertragsprojektionen | 243 |
| 7.3.4.1 | Landwirtschaft | 244 |
| 7.3.4.2 | Frankenwein | 245 |
| 7.3.5 | Limitationen | 246 |

8 Schlussfolgerungen und Ausblick **249**

Literatur **254**

| | |
|-----------------------------------------------|-----------|
| Anhang | A1 |
| A1 Untersuchungsgebiet | A3 |
| A1.1 Naturraum | A3 |
| A1.2 Geologie | A5 |
| A2 Nutzung | A6 |
| A3 Feldfrüchte und deren Verwendung | A6 |

Danksagung

Abbildungen

| | | |
|------|------------------------------------------------------------------------------------------------------------------|-----|
| 1.1 | Projektlogo | 1 |
| 1.2 | Wald- und Landwirtschaftsflächen in Unterfranken 2012 | 5 |
| 1.3 | Auflösungsvergleich GCM – RCM – gerasterte Beobachtungsdaten | 9 |
| 1.4 | Fließdiagramm zur Vorgehensweise dieser Studie | 12 |
| 2.1 | Untersuchungsgebiet und dessen Topographie | 16 |
| 2.2 | Interne Gliederung Unterfrankens und umgebender Bereiche | 17 |
| 2.3 | Geologischer Schnitt von Aschaffenburg nach Weiden | 18 |
| 2.4 | Mittlere Temperatur 1971–2000 | 20 |
| 2.5 | Mittlerer Jahresniederschlag 1971–2000 | 21 |
| 2.6 | Mittlere Wasserbilanz 1991–2020 | 22 |
| 2.7 | Jahresgang von Niederschlag und Wasserbilanz im Untersuchungsgebiet | 23 |
| 2.8 | Nennungshäufigkeit relevanter klimatischer Rahmenbedingungen | 26 |
| 3.1 | Landkreise und kreisfreie Städte Unterfrankens auf dem Gitter der verwendeten Klimamodelldaten (EUR11) | 31 |
| 3.2 | Gemeinden des Frankenweins | 32 |
| 5.1 | Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: pBias MW | 88 |
| 5.2 | Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: pBias SD | 90 |
| 5.3 | Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: pQRMSE | 92 |
| 5.4 | Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: Q-Q-Plots | 95 |
| 5.5 | Modellgüte bzgl. der Spätfrosthäufigkeiten 1951–2005: Q-Q-Plots | 96 |
| 5.6 | Modellgüte bzgl. der klimatischen Kennwerte nach Biaskorrektur: pBias MW | 99 |
| 5.7 | Biaskorrekturergebnisse pBias MW: Regionale Mittelwerte | 100 |
| 5.8 | Biaskorrekturergebnisse pBias MW: Verteilung der prozentualen Verbesserung | 101 |
| 5.9 | Beispielsituationen pBias MW vor und nach der Korrektur (QM11) sowie prozentuale Verbesserung | 109 |
| 5.10 | Biaskorrekturergebnisse pBias MW Spätfrost: Regionale Mittelwerte | 110 |
| 5.11 | Biaskorrekturergebnisse pBias MW Spätfrost: Verteilung der prozentualen Verbesserung | 111 |

| | | |
|------|----------------------------------------------------------------------------------------------------------------------------------|-----|
| 5.12 | Modellgüte bzgl. der klimatischen Kennwerte nach Biaskorrektur: pBias SD . . . | 112 |
| 5.13 | Biaskorrekturergebnisse pBias SD: Regionale Mittelwerte | 114 |
| 5.14 | Biaskorrekturergebnisse pBias SD: Verteilung der prozentualen Verbesserung . | 116 |
| 5.15 | Biaskorrekturergebnisse pBias SD Spätfrost: Regionale Mittelwerte | 121 |
| 5.16 | Biaskorrekturergebnisse pBias SD Spätfrost: Verteilung der prozentualen Verbesserung | 122 |
| 5.17 | Modellgüte bzgl. der klimatischen Kennwerte nach Biaskorrektur: pQRMSE . . | 124 |
| 5.18 | Biaskorrekturergebnisse pQRMSE: Regionale Mittelwerte | 125 |
| 5.19 | Biaskorrekturergebnisse pQRMSE: Verteilung der prozentualen Verbesserung . | 126 |
| 5.20 | Biaskorrekturergebnisse pQRMSE Spätfrost: Regionale Mittelwerte | 130 |
| 5.21 | Biaskorrekturergebnisse pQRMSE Spätfrost: Verteilung der prozentualen Verbesserung | 131 |
| 5.22 | Biaskorrekturergebnisse Verteilung Indizes: Q-Q-Plots | 133 |
| 5.23 | Biaskorrekturergebnisse Verteilung Spätfrost: Q-Q-Plots | 134 |
| 5.24 | Gewählte Modellfamilien | 135 |
| 5.25 | Gewählte Prädiktorvariablen aller Indizes, Monate und Gitterzellen | 136 |
| 5.26 | Gewählte Prädiktorvariablen aller Spätfrostindizes und Gitterzellen pz2 | 138 |
| 5.27 | Anzahl der Gitterzellen mit gültigen MLR-Modellen je Index und Monat | 139 |
| 5.28 | Qualität MOS REMO-Eval: MSSS und R ² Klimaindizes | 140 |
| 5.29 | Anzahl der Eistage: Vergleich MOS REMO-Eval und Beobachtungsdaten Januar (MLR) | 141 |
| 5.30 | Qualität MOS REMO-Eval: MSSS und R ² Spätfrost preco-ztrans2 | 141 |
| 5.31 | Modellgüte bzgl. der MOS-simulierten klimatischen Kennwerte: pBias MW . . | 142 |
| 5.32 | Ergebnisse MOS REMO-ESM pBias MW: Regionale Mittelwerte | 143 |
| 5.33 | Ergebnisse MOS REMO-ESM Spätfrost: Regionale Mittelwerte pBias MW und SD sowie pQRMSE | 148 |
| 5.34 | Modellgüte bzgl. der MOS-simulierten klimatischen Kennwerte: pBias SD . . . | 149 |
| 5.35 | Ergebnisse MOS REMO-ESM pBias SD: Regionale Mittelwerte | 150 |
| 5.36 | Modellgüte bzgl. der MOS-simulierten klimatischen Kennwerte: pQRMSE . . | 154 |
| 5.37 | Ergebnisse MOS REMO-ESM pQRMSE: Regionale Mittelwerte | 155 |
| 5.38 | MOS-Ergebnisse Verteilung Indizes: Q-Q-Plots | 158 |
| 5.39 | MOS-Ergebnisse Verteilung Spätfrost: Q-Q-Plots | 159 |
| 5.40 | Regionale Mittelwerte der pro Gitterzelle berechneten pQRMSEs der klimatischen Kennwerte für alle BK- und MOS-Methoden | 162 |

| | | |
|------|-----------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 5.41 | pQRMSE Spätfrost als Kartendarstellung sowie regionales Mittel der Gitterzellenwerte | 166 |
| 5.42 | Regionale Mittelwerte der klimatischen Kennwerte für alle BK- und MOS-Methoden sowie die jeweiligen Beobachtungsdaten | 168 |
| 5.43 | Mittlere beobachtete, RCM-modellierte und korrigierte sowie MOS-simulierte Anzahl der Spätfrosttage | 169 |
| 5.44 | Trends der klimatischen Kennwerte im 21. Jahrhundert | 170 |
| 5.45 | Spätfrost im 21. Jahrhundert | 172 |
| 5.46 | Trends der klimatischen Kennwerte im 21. Jahrhundert für REMO und zwei weitere RCMs | 173 |
| 5.47 | DMI-Projektionen Ende des 20. und 21. Jahrhunderts (MMM) | 175 |
| 5.48 | Spätfrosttrends im 21. Jahrhundert für REMO und zwei weitere RCMs | 176 |
| 5.49 | Karten der VPT-Spätfrosttrends im 21. Jahrhundert relativ zum jeweiligen Mittelwert 1971–2000. REMO2015, REMO2009, ALADIN und RACMO | 177 |
| 6.1 | Gewählte Prädiktoren der Simulation landwirtschaftlicher Erträge | 181 |
| 6.2 | Gewählte Prädiktoren der Frankenweinsimulation | 182 |
| 6.3 | MSSS und R^2 Simulationen landwirtschaftliche Erträge Kontrollzeitraum | 183 |
| 6.4 | MSSS und R^2 Simulationen Frankenweinerträge Kontrollzeitraum | 183 |
| 6.5 | Simulierte Trends der landwirtschaftlichen Erträge im 21. Jahrhundert | 184 |
| 6.6 | Simulierte Trends der Frankenweinerträge im 21. Jahrhundert | 185 |
| 6.7 | Simulierte Trends der landwirtschaftlichen Erträge im 21. Jahrhundert durch REMO und drei weitere regionale Klimamodelle | 186 |
| 6.8 | Simulierte Trends der Frankenweinerträge im 21. Jahrhundert durch REMO und drei weitere regionale Klimamodelle | 187 |
| 7.1 | Schematische Darstellung zur Temperaturabhängigkeit von Photosynthese und Atmung bei C3-Pflanzen | 192 |
| 7.2 | Huglin-Index Multimodellmittel | 212 |
| 7.3 | Verbreitung der Fichte im Untersuchungsgebiet | 220 |
| 7.4 | Ergebnisse Spätfrost basierend auf REMO- und MPI-ESM-Daten 1951–1980 | 238 |
| 7.5 | Vorzeichen der beobachteten vergangenen und simulierten zukünftigen Trends der regionalen Mittelwerte | 239 |
| A1 | Naturräumliche Gliederung | A3 |
| A2 | Geologie des Untersuchungsgebietes | A5 |
| A3 | Legende zur Geologischen Karte | A7 |
| A4 | Deutsche Fabrikstandorte der Südzucker AG | A8 |

Tabellen

| | | |
|-----|-----------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 2.1 | Untersuchte Indizes | 27 |
| 2.2 | Trockenheitsklassen des De Martonne-Index | 28 |
| 3.1 | Verwendete regionale Klimamodelle | 34 |
| 4.1 | Vergleich Biaskorrektur und Modell Output Statistics | 53 |
| 4.2 | Merkmale der Indizes | 58 |
| 4.3 | Geläufige EDMs | 61 |
| 4.4 | Verwendete Prädiktorvariablen | 72 |
| 4.5 | Saat- und Erntekalender | 78 |
| 4.6 | Anzahl der Jahre in den Kalibrations-, Validations- und Kontrollzeiträumen der betrachteten Größen | 83 |
| 5.1 | Veränderung des regionalen Mittelwerts von pBias MW durch die Biaskorrektur | 102 |
| 5.2 | Regionaler Mittelwert (Median) der prozentualen Verbesserung von pBias MW durch die Biaskorrektur | 103 |
| 5.3 | Spätfrost: Veränderung des regionalen Mittelwerts und regionaler Mittelwert der prozentualen Verbesserung von pBias MW durch die Biaskorrektur | 110 |
| 5.4 | Veränderung des regionalen Mittelwerts von pBias SD durch die Biaskorrektur | 115 |
| 5.5 | Regionaler Mittelwert (Median) der prozentualen Verbesserung von pBias SD durch die Biaskorrektur | 115 |
| 5.6 | Spätfrost: Veränderung des regionalen Mittelwerts und regionaler Mittelwert der prozentualen Verbesserung von pBias SD durch die Biaskorrektur | 120 |
| 5.7 | Veränderung des regionalen pQRMSE-Mittelwerts durch die Biaskorrektur | 123 |
| 5.8 | Regionaler Mittelwert (Median) der prozentualen pQRMSE-Verbesserung durch die Biaskorrektur | 127 |
| 5.9 | Spätfrost: Veränderung des regionalen pQRMSE-Mittelwerts und regionaler Mittelwert der prozentualen pQRMSE-Verbesserung durch die Biaskorrektur | 130 |
| 7.1 | Ergebnisse MLR-MOS Frankenwein mit gewichteten Modelldurchschnitt | 236 |
| A1 | Naturräume des Untersuchungsgebietes | A4 |

Abkürzungen

| | |
|-----------------------|-------------------------------------------------------------------------------------------------|
| AI | Artificial Intelligence |
| AOGCM | Atmosphere-Ocean General Circulation Model, gekoppeltes Atmosphären-Ozean-Zirkulationsmodell |
| AR5 | Fifth Assessment Report, fünfter Sachstandsbericht |
| BK | Biaskorrektur |
| CH₄ | Methan |
| CMIP | Coupled Model Intercomparison Project |
| CMIP3 | Phase 3 CMIP |
| CMIP5 | Phase 5 CMIP |
| CO₂ | Kohlenstoffdioxid |
| CORDEX | Coordinated Regional Downscaling Experiment |
| DMI | De Martonne-Index |
| DWD | Deutscher Wetterdienst |
| ECMWF | European Centre for Medium-Range Weather Forecasts |
| EDM | Exponential Dispersion Model |
| EFRE | Europäischer Fonds für regionale Entwicklung |
| EOF | Empirische Orthogonalfunktion |
| ESM | Earth System Model, Erdsystemmodell |
| FW | Frankenwein |
| GCM | Global Climate Model, globales Klimamodell |
| GAM | Generalized Additive Model |
| GLM | Generalized Linear Model |
| H₂O | Wasser (Wasserdampf als Treibhausgas) |
| HI | Huglin-Index |
| IPCC | Intergovernmental Panel on Climate Change |
| IRLS | Iteratively Reweighted Least Squares, iterativ gewichtete kleinste Quadrate |
| IWLS | Iteratively (Re-)weighted Least Squares, iterativ gewichtete kleinste Quadrate |
| Kfs. | Kreisfreie Stadt |
| KMU | Kleine und mittelständische Unternehmen |
| KQ | Kleinste Quadrate |
| Lkr. | Landkreis |
| LSE | Least-Squares Estimation, Methode der kleinsten Quadrate |
| LS | Linearskalierung |
| LSM | Multiplikative Linearskalierung |

| | |
|-----------------------|------------------------------------------------------------------------------------------|
| LW | Landwirtschaft |
| MCD | Maximum Number of Consecutive Dry Days, maximale Anzahl aufeinanderfolgender Trockentage |
| MLR | Multiple Lineare Regression |
| MME | Multi Model Ensemble |
| MMM | Multi Model Mean |
| MOS | Model Output Statistics |
| MPI | Max-Planck-Institut für Meteorologie |
| MSE | Mean Squared Error |
| MW | Arithmetischer Mittelwert |
| N₂O | Lachgas |
| O₃ | Ozon |
| OLS | Ordinary Least-Squares, Methode der kleinsten Quadrate |
| PC | Principal Component |
| PCA | Principal Component Analysis |
| PDF | Probability Density Function, Wahrscheinlichkeitsdichtefunktion |
| PM | PDF-Matching |
| PMPE | parametrisches PDF-Matching mit Pearson III-Verteilung |
| PP | Prozentpunkte |
| pV | prozentuale Veränderung bzw. Verbesserung (negative Werte entsprechen Verschlechterung) |
| pz2 | preco-ztrans2 |
| QRMSE | Quantil-Root Mean Squared Error |
| QM | Quantilmapping |
| QM11 | nicht-parametrisches Quantilmapping mit 11 Quantilen |
| R1mmn | Anzahl der Trockentage |
| R95n | Anzahl der Tage mit Starkniederschlag |
| RCM | Regional Climate Model, regionales Klimamodell |
| RCP | Representative Concentration Pathway |
| REMO | REgional MOdel |
| -iMOVE | REMO with interactive MOsaic-based VEgetation |
| RMSE | Root Mean Squared Error |
| SD | Standardabweichung, Standard Deviation |
| SLR | Simple Lineare Regression |
| SSE | Sum of Squared Errors, Summe der quadrierten Fehler |
| TFF | Thüringisch-Fränkischer Wald samt Fichtelgebirge |
| UG | Untersuchungsgebiet |
| Var | Varianz |
| VP | Vegetationsperiode |
| VPM | monatlich definierte Vegetationsperiode |
| VPT | thermisch definierte Vegetationsperiode |

| | |
|-------------|-----------------------------------|
| VZ | Vorzeichen |
| WCRP | World Climate Research Programme |
| WMA | Weighted Model Averaging |
| WMO | World Meteorological Organisation |

Mathematische Symbole

| | |
|-----------------|-------------------------------------------------------------------------------------|
| e | Eigenvektor |
| $e^x = \exp(x)$ | Natürliche Exponentialfunktion mit Euler'scher Zahl $e \approx 2,718282$ |
| \in | Element (einer Menge) |
| g | Linkfunktion |
| h | Responsefunktion |
| $L(\cdot)$ | Likelihood-Funktion |
| $l(\cdot)$ | log-Likelihood-Funktion |
| \mathbb{N} | Menge der natürlichen Zahlen |
| \mathbb{N}_0 | Menge der natürlichen Zahlen inklusive Null |
| P | Wahrscheinlichkeit |
| P_p | Perzentil der Wahrscheinlichkeit p |
| Q_p | Quantil der Wahrscheinlichkeit p |
| \mathbb{R} | Menge der reellen Zahlen |
| \mathbb{R}^+ | Menge der positiven reellen Zahlen |
| r | Korrelationskoeffizient |
| r^2 | quadrierter Korrelationskoeffizient, Bestimmtheitsmaß, Determinationskoeffizient |
| R^2 | quadrierter Korrelationskoeffizient, Bestimmtheitsmaß, Determinationskoeffizient |
| s | Standardabweichung einer Stichprobe |
| s^2 | Varianz einer Stichprobe |
| $V(\cdot)$ | Varianzfunktion |
| \bar{x} | Arithmetischer Mittelwert einer Stichprobe |
| α | Irrtumswahrscheinlichkeit |
| $\Gamma(\cdot)$ | Gammafunktion |
| η | Linearprädiktor |
| θ | kanonischer Parameter |
| $\kappa(\cdot)$ | Kumulantfunktion |
| λ | Eigenwert |
| μ | Erwartungswert, auch $E(\cdot)$ |
| π | Kreiszahl ($\pi \approx 3,141593$) |
| \prod | Produkt |
| σ | Standardabweichung einer Grundgesamtheit |
| σ^2 | Varianz einer Grundgesamtheit |

| | |
|----------|-----------------------------|
| Σ | Summe |
| ϕ | Dispersionsparameter |
| Φ | kumulative Normalverteilung |

1 Einleitung

1.1 Hintergrund, Motivation und Relevanz

Diese Dissertationsschrift entstand im Rahmen des Projektes *BigData@Geo: BigData in Geographie – Fortschrittliche Umwelttechnologien mittels AI im Web*. AI steht hierbei für Artificial Intelligence, zu deutsch Künstliche Intelligenz. Abbildung 1.1 zeigt das Logo des Projekts.




Abbildung 1.1: Projektlogo. Im Hintergrund des Logos ist in blauer Farbe Unterfranken, Bayerns nordwestlichster Regierungsbezirk, zu sehen. Das @-Zeichen aus dem Namen BigData@Geo – hier abgekürzt als bd@g – soll eine Punktwolke darstellen. Diese steht hierbei für die großen Datenmengen, die innerhalb des Projekt verarbeitet werden. (Entwurf: K. Kobs, L. Keupp).

Dieses Projekt wird vom Europäischen Fonds für regionale Entwicklung (EFRE) gefördert und zielt darauf ab, kleine und mittelständische Unternehmen – kurz KMU – aus Land-, Forstwirtschaft und Weinbau auf die Herausforderungen der Zukunft vorzubereiten. Ein Teil hiervon – und der Inhalt dieser Arbeit – besteht darin, in enger Kooperation mit regionalen KMU-Partnerunternehmen, relevante klimatische Kenngrößen herauszuarbeiten und die zukünftige Entwicklung derselben abzuschätzen. Um dies zu ermöglichen, werden Daten regionaler Klimamodelle (Abschnitt 1.2.2) verwendet. Aufgrund der Fehleranfälligkeit derselben, werden sie vor der Analyse von Zukunftsprojektionen hinsichtlich ihrer Güte untersucht und durch verschiedene Methoden korrigiert.

Die Hauptcharakteristika der vorliegenden Arbeit sind folgende:

- Anstatt ein physiologisches, prozessbasiertes Pflanzen(wachstums)modell zu nutzen (wie z.B. DONATELLI *et al.* 2015; FRAGA *et al.* 2016a; OTU-LARBI *et al.* 2020; REYER *et al.* 2014; ROSENZWEIG *et al.* 2014; WHITE *et al.* 2011; ZIMMERMANN *et al.* 2017), werden land-, forstwirtschaftlich und önologisch relevante klimatische Kenngrößen verwendet.
- Die Erarbeitung der zu untersuchenden klimatischen Kenngrößen findet in Zusammenarbeit mit Unternehmen aus Land-, Forstwirtschaft, Wein-, Garten- und Gemüsebau statt. Hierdurch werden diejenigen klimatischen Aspekte untersucht, die praktische Relevanz besitzen.
- Für die Zukunftsuntersuchungen werden hochaufgelöste – hinsichtlich der zu untersuchenden Kennwerte korrigierte – Klimamodelldaten verwendet.
- Die Biaskorrektur wird auf verschiedene Arten durchgeführt und die jeweils beste Methode für die Untersuchung zukünftiger Entwicklungen übernommen.
- Neben gängigen Korrekturverfahren (vgl. z.B. TEUTSCHBEIN & SEIBERT 2012; MARAUN 2016; MARAUN & WIDMANN 2018; LAFON *et al.* 2013) wird auf explorative Weise eine neue Methode entwickelt und angewandt. Diese basiert auf Model Output Statistics, die zu untersuchenden Größen werden dabei durch verschiedene Regressionstechniken aus unterschiedlichen klein- und großskaligen Variablen simuliert.
- Diese explorative Methode wird zusätzlich verwendet, um Erträge aus Landwirtschaft und Weinbau zu simulieren (statistisches Modell) (vgl. z.B. FRAGA *et al.* (2016b) zur Rebphänologiesimulation, AWOYE *et al.* (2017) für Landwirtschaftssimulation in Benin, LOBELL & BURKE (2010) für einen Vergleich zwischen statistischen und prozessbasierten Maisertragsmodellen).
- Die Untersuchungen finden für Unterfranken und umgebende Gebiete statt.

Nachfolgend wird auf die Hauptmotivationsgründe für die Untersuchung zukünftiger Klimarisiken für Land- und Forstwirtschaft in Unterfranken eingegangen: Den anthropogenen Klimawandel (Abschnitt 1.1.1), die Land- und Forstwirtschaft in Unterfranken (Abschnitt 1.1.2) sowie die klimatische Beeinflussung letzterer (Abschnitt 1.1.3). Anschließend werden Klimamodelle einschließlich ihrer Schwächen thematisiert (Abschnitt 1.2). Aus diesen Ausführungen werden schließlich die Zielsetzungen sowie die Vorgehensweise dieser Arbeit abgeleitet (Abschnitt 1.3).

1.1.1 Anthropogener Klimawandel

Die Existenz des anthropogenen Klimawandels ist unumstritten (IPCC 2021). Der natürlicherweise vorhandene Treibhauseffekt (Absorption und anschließende Emission von Wärmestrahlung durch natürlicherweise in der Atmosphäre befindliche Spurengase (v.a. H₂O und CO₂) in Richtung Erdoberfläche) wird durch anthropogene Treibhausgasemissionen (v.a. CO₂, CH₄, N₂O, indirekt gebildetes O₃) verstärkt. Hierdurch steigt die globale Temperatur an, was weitere Effekte und auch Rückkopplungen (z.B. Erhöhung des atmosphärischen Wassergehalts durch höhere Aufnahmekapazität wärmerer Luft) nach sich zieht (z.B. LATIF 2009; SCHMIDT *et al.* 2017). Die momentane Höhe der Konzentrationen der wichtigsten anthropogenen Treibhausgase ist seit mindestens zwei Millionen Jahren (CO₂) bzw. mindestens 800.000 Jahren (CH₄, N₂O) unübertroffen (hohe bzw. sehr hohe Wahrscheinlichkeit) (IPCC (2021) bzgl. 2019; für CO₂ und CH₄ bzgl. 2022 bestätigt durch C3S (2023a,b)). Ein Temperaturanstieg wie der von den Menschen verursachte kam in den letzten zwei Jahrtausenden nicht vor. Ein Teil des Effektes der anthropogenen Treibhausgase wurde dabei durch (anthropogene) Aerosole überdeckt, die eine Kühlung bedingen (z.B. Schwefeldioxid, Kohlenstoff). Der gesamte anthropogen-bedingte Strahlungsantrieb¹ 2019 betrug 2,72 W m⁻² im Vergleich zu 1750 (IPCC 2021)². „Jede der letzten vier Jahrzehnte war fortschreitend wärmer als jedes andere Jahrzehnt davor seit 1850“ (IPCC 2021). Vergleicht man die beobachtete Entwicklung der globalen Oberflächentemperatur seit 1850 mit simulierten Werten mit rein natürlichem Antrieb sowie natürlichem plus anthropogen bedingtem Antrieb, wird der menschliche Einfluss in den letzten 50 Jahren mit deutlich zunehmender Stärke sichtbar (IPCC 2021). Dies betrifft jedoch nicht nur Mittelwerte, sondern auch Extrema. Sowohl Häufigkeit als auch Stärke von Hitze und Starkregen hat seit den 1950er Jahren über den meisten Landregionen, Dürre³ über einigen Landregionen anthropogen bedingt zugenommen (IPCC 2021).

¹Definiert als „die Veränderung des Nettostrahlungsflusses (abwärts minus aufwärts, ausgedrückt in W m⁻²) durch eine Veränderung in einem externen Treiber des Klimawandels“ (MATTHEWS *et al.* 2021)

²Anthropogen bedingt waren also pro Sekunde und Quadratmeter zusätzlich 2,72 J an Energie an der Erdoberfläche vorhanden.

³Landwirtschaftliche bzw. ökologische Dürren, definiert als „Periode mit abnormalem Bodenfeuchtedefizit, das auch einer Kombination von Niederschlagsmangel und Evapotranspirationsüberschuss resultiert“ (MATTHEWS *et al.* 2021)

Unterfranken kann als ein „Hot Spot des Klimawandels“ (RAUH & PAETH 2011) gesehen werden, da die beobachteten Erwärmungsraten den weltweiten Durchschnitt deutlich überschreiten (RAUH & PAETH 2011, vgl. GIORGI 2006). So lag der globale lineare Trend der Durchschnittstemperatur von 1951 bis 2020 bei 1,42 °C pro 100 Jahre (30-jähriges gleitendes Mittel 1,48 °C), während die Temperatur im Untersuchungsgebiet (vgl. Kapitel 2.1) durchschnittlich um 2,87 °C pro 100 Jahre stieg (3,10 °C). Selbst wenn nur die globalen Landflächentemperaturen zum Vergleich herangezogen werden (2,27 °C (2,38 °C)), tritt der Klimawandel in Unterfranken stärker zum Vorschein (eigene Berechnungen, Daten DWD (2021a); NOAA NCEI (2022)).

1.1.2 Land-, Forstwirtschaft und Weinbau in Unterfranken

Des Weiteren sind Wald und Landwirtschaft die vorherrschenden Flächennutzungen in Unterfranken, wie Abbildung 1.2 in 10 ha-Auflösung für das Jahr 2012 zeigt. Hinsichtlich der exakten Flächenbetrachtung zum Stichtag 31.12.2020 waren 82 % der Fläche Unterfrankens von Landwirtschaft (inkl. Weinbau) oder Wald bedeckt (Fläche nach Art der tatsächlichen Nutzung, LFSTAT 2022), davon entfielen 39,9 % auf Wald, 32,3 % auf Ackerland und 0,7 % auf Weingärten (Rest Grünland, Gartenland, Obstplantagen). Nähere Informationen hierzu sind im Abschnitt 2.1.4 zu finden.

1.1.3 Klima und Land- bzw. Forstwirtschaft sowie Weinbau

Unterfranken besitzt also eine land- und forstwirtschaftliche Prägung und ist überdurchschnittlich vom globalen Klimawandel betroffen. Die Verbindung dieser beiden Aspekte stellt die Untersuchung der zukünftigen Klimarisiken für Land- und Forstwirtschaft in Unterfranken dar. Die Relevanz des Klimas und seiner Veränderung für Land-, Forstwirtschaft und Weinbau besteht schon an sich, da bestimmte klimatische Bedingungen zuträglich für bestimmte Pflanzenarten (und -sorten) sind, andere jedoch abträglich. Hierbei muss mitunter zwischen Qualität und Quantität unterschieden werden (vgl. z.B. GÖMANN *et al.* 2017; BOCK *et al.* 2011). In umgekehrter Weise dienen Baumringe, Aufzeichnungen zu Weinmenge und -güte ebenso wie Getreideernteerträge als Proxydaten für die Rekonstruktion des vergangenen Klimas. Hinsichtlich letzterer ist die Aussagekraft durch den häufigen Wechsel der Fruchtart sowie die große menschliche Einflussnahme jedoch verringert (GLASER 2008).

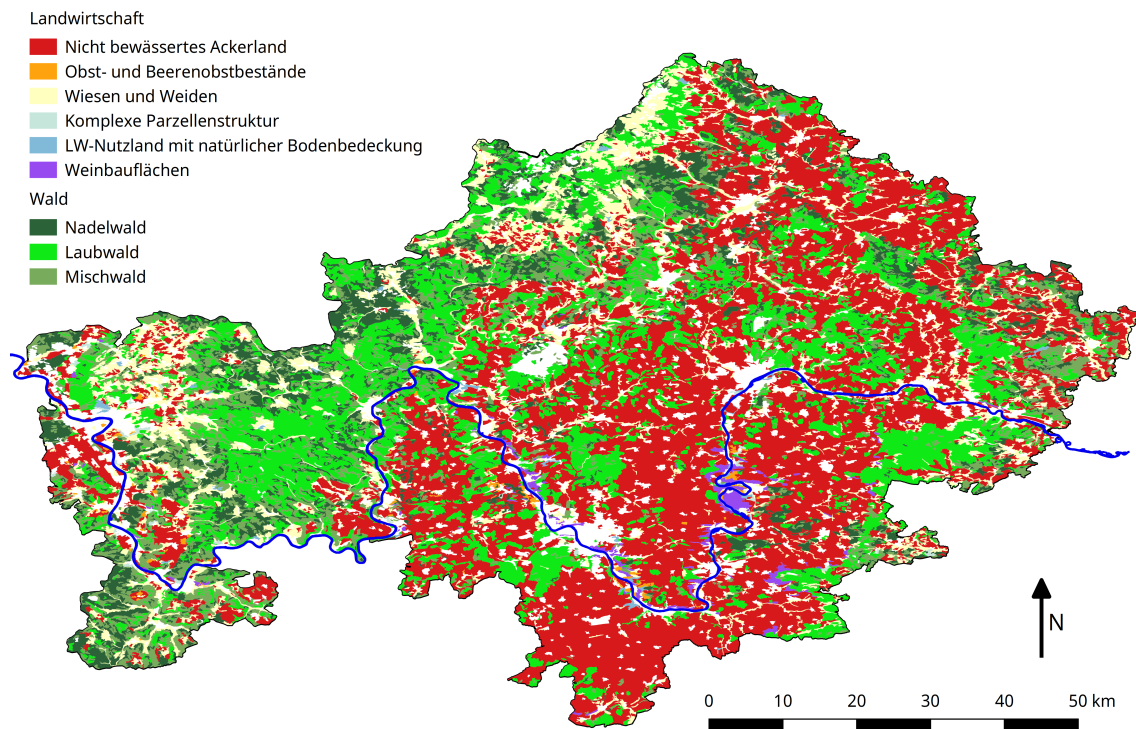


Abbildung 1.2: Wald- und Landwirtschaftsflächen in Unterfranken 2012 (Darstellung L. Keupp, Daten GEOBASIS-DE 2012).

Laut GÖMANN *et al.* (2017) ist die Häufigkeit von Extremereignissen (Frost, Hitze, Trockenheit etc.) ein großer Unsicherheitsfaktor in Bezug auf die landwirtschaftliche Entwicklung Deutschlands in den nächsten Jahrzehnten (vgl. z.B. VERBAND DER LANDWIRTSCHAFTSKAMMERN 2010; BMU *et al.* 2008; FELBERMEIR 2011; BUTH *et al.* 2015; BMELV 2008; STMUV 2015). Diese besitzen auch große Auswirkungen auf die Forstwirtschaft (z.B. KÖHL *et al.* 2017; BMU *et al.* 2008; BUTH *et al.* 2015; BMELV 2008). Die Anpassungsfähigkeit an den Klimawandel hinsichtlich der Wahl der kultivierten Pflanzen ist abhängig von der Häufigkeit dieser Wahlmöglichkeit. Daher ist sie für die Forstwirtschaft und den Weinbau (sowie den Obstbau) deutlich geringer als für die Landwirtschaft (v.a. Acker- und Gartenbau). Gerade für erstere ist also eine langfristige Planung relevant (BMELV 2008; STMUV 2015).

Die Untersuchung der zukünftigen Entwicklung klimatischer (Extrem-)Kennwerte mit land- und forstwirtschaftlichem Bezug ist daher von großer Relevanz. Hierfür werden entsprechende Modelldaten mit möglichst hoher Auflösung und Qualität benötigt. Diese werden durch regionale Klimamodelle bereitgestellt, auf welche im folgenden Kapitel 1.2 näher eingegangen wird. Das Kapitel 7.1 beschäftigt sich mit dem Zusammenhang von Klima und Pflanzenproduktion (Landwirtschaft, Weinbau, Forstwirtschaft).

1.2 Klimamodelle

1.2.1 Globale Klimamodelle

Die Untersuchung zukünftiger Klimaentwicklungen beruht auf Simulationen durch Klimamodelle. Diese sind raumzeitlich diskretisierte (also in Gitterzellen und Zeitschritte unterteilte) Abbildungen des irdischen Klimas. Prozesse, die dieser Auflösung entsprechen (skalig) werden durch numerische Gleichungen implementiert, für Prozesse, die auf feineren raumzeitlichen Skalen stattfinden (subskalig) kommen Parametrisierungen zur Anwendung (CORTEKAR 2017; PAETH 2007). Während AOGCMs (Atmosphere-Ocean General Circulation Models, gekoppelte Atmosphäre-Ozean-Zirkulationsmodelle) atmosphärische sowie ozeanische Klimaprozesse und ihre Wechselwirkungen beinhalten, umfassen ESMs (Erdsystemmodelle, Earth System Models) je nach Ausführung zusätzliche Komponenten und Prozesse (CORTEKAR 2017; SCHMIDT *et al.* 2017). Beim MPI-ESM des Max-Planck-Instituts für Meteorologie (MPI) beispielsweise ist der atmosphärischen Modellkomponente ein Landoberflächen- bzw. Vegetationsmodell angeschlossen sowie der ozeanischen Modellkomponente ein Modell für die marine Biogeochemie (GIORGETTA *et al.* 2013). Auch weitere Komponenten sind möglich (z.B. Aerosole, Kohlenstoffkreislauf), um die Prozesse des Klimasystems immer weiter zu untersuchen, zu verstehen und Zukunftsprojektionen zu verbessern (SCHMIDT *et al.* 2017). Sowohl die Diskretisierung als auch die damit verbundenen Parametrisierungen sind ein großer Unsicherheitsfaktor von Klimamodellen (z.B. MARAUN & WIDMANN 2018; PAETH 2007). Um diesen auf regionaler Ebene zu verringern und detailliertere Aussagen zu ermöglichen, werden Simulationen globaler Klimamodelle (GCM⁴) für spezielle Gebiete auf eine höhere Auflösung gebracht. Diese Regionalisierung wird auch Downscaling genannt und kann auf statistische oder dynamische Weise erfolgen (JACOB *et al.* 2017; MARAUN & WIDMANN 2018). Erstere basiert auf statistischen Beziehungen und wird in Kapitel 4.4 thematisiert. Zweitere ist physikalisch begründet und erfolgt durch regionale Klimamodelle.

⁴GCM kann auch für General Circulation Model, also allgemeines Zirkulationsmodell, stehen. Alle hier angesprochenen Globalmodelle sind mindestens AOGCMs. ESMs sind wie oben beschrieben erweiterte AOGCMs. Im weiteren Verlauf wird GCM (ohne AO) für globale Klimamodelle verwendet.

1.2.2 Regionale Klimamodelle

„Die Erfassung von Klimaauswirkungen und die Entwicklung regionaler bis lokaler Anpassungsstrategien erfordert die Verfügbarkeit hochaufgelöster Klimawandelszenarien, inklusive einer Einschätzung ihrer Robustheit und inhärenter Unsicherheiten.“ (JACOB *et al.* 2014)

Regionale Klimamodelle sind wie globale Klimamodelle raumzeitlich diskretisierte dreidimensionale numerische Modelle. Sie besitzen jedoch eine höhere räumliche Auflösung und die Berechnungen erfolgen nur für ein begrenztes Gebiet (FESER *et al.* 2011; GIORGI 2019; JACOB *et al.* 2017). Die Daten globaler Klimamodelle oder Reanalysen⁵ stellen dabei die Randbedingungen dar, da das regionale in ein globales Modell eingebettet wird (Nesting) (DOBLAS-REYES *et al.* 2021; GIORGI & GUTOWSKI 2015; GIORGI 2019; JACOB *et al.* 2017). Die horizontale Auflösung an den Rändern wird innerhalb der Relaxationszone schrittweise erhöht. Die Regionalklimamodelle des EURO-CORDEX-Projektes (Europaregion des Coordinated Regional Downscaling Experiment (GIORGI *et al.* 2009; JACOB *et al.* 2014) des World Climate Research Programme (WCRP)) etwa berechnen Zielaufösungen von ca. 50 km und ca. 12,5 km (JACOB *et al.* 2014) unter Verwendung von Globaldaten mit Auflösungen die meist zwischen 100 und 250 km liegen (vgl. FLATO *et al.* 2013). Regionale Klimamodelle sind an sich atmosphärische Zirkulationsmodelle, können aber mit weiteren Komponenten gekoppelt werden (JACOB *et al.* 2017; GIORGI & GUTOWSKI 2015).

Ein Beispiel hierfür ist das in dieser Arbeit vorrangig verwendete Modell REMO (REgional MOdel) (JACOB & PODZUN 1997), dessen Weiterentwicklung ebenfalls Teil des Projektes *BigData@Geo* ist: Es beinhaltet neben der Atmosphäre die Landoberfläche (Topographie, Vegetation, Oberflächen- und Bodeneigenschaften, Boden). Die Verbesserung der Topographie (höhere Auflösung (ZIEGLER *et al.* 2020; ZIEGLER 2022)), des Bodens (fünf Schichten statt Bucket-Schema (dt. Eimer) sowie höher aufgelöste Bodeneigenschaften und neue Parametrisierungen (ABEL *et al.* 2020, 2021; ABEL 2023)) sowie der Vegetation (unter Verwendung von REMO-iMOVE (WILHELM *et al.* 2014) mit interaktiver Vegetation (POLLINGER *et al.* 2020)) sind Teilprojekte von *BigData@Geo*.

⁵Auf Beobachtungs- und Modelldaten basierende „Rekonstruktion des Zustands eines Systems (z.B. der Atmosphäre) für einen Zeitraum in der Vergangenheit“ (CORTEKAR 2017)

Das regionale Klima ist das Ergebnis von Prozessen unterschiedlicher Skalen. Die großskaligen Treiber Breitengrad und Land-See-Verteilung werden auf regionaler Ebene durch viele dynamisch wie auch thermodynamisch wirksame Prozesse und Faktoren modifiziert. Hierbei spielen z.B. Topographie, Bodenfeuchte und konvektive Instabilität eine große Rolle (DOBLAS-REYES *et al.* 2021; FESER *et al.* 2011; GIORGI & GUTOWSKI 2015; JACOB *et al.* 2017; MARAUN & WIDMANN 2018). Eine höhere Auflösung und die Implementierung dann skaliger Prozesse kann so zur Verbesserung der Repräsentation des Klimas führen (added value) (z.B. PAETH & MANNIG 2013; FESER *et al.* 2011; DOBLAS-REYES *et al.* 2021; GIORGI 2019). Dieser Zusatznutzen ist vor allem dort zu erwarten, wo das Klima stark regional geprägt ist, also kleinräumige Unterschiede hinsichtlich Topographie, Wasser- (Küsten, Seen), Landoberflächen etc. vorzufinden sind oder auch im Bezug auf Niederschlagsextreme (GIORGI & GUTOWSKI 2015; GIORGI 2019; KOTLARSKI *et al.* 2014; PREIN *et al.* 2016; VAUTARD *et al.* 2013). Die Kopplung weiterer Komponenten kann je nach Anwendung zusätzliche Verbesserungen mit sich bringen (z.B. AKHTAR *et al.* 2018; HO-HAGEMANN *et al.* 2017; KELEMEN *et al.* 2019; WILHELM *et al.* 2014, vgl. DOBLER *et al.* 2017; GIORGI 2019; VAUTARD *et al.* 2013).

„Regionalisierungen von globalen Klimaprojektionen liefern detailliertere Aussagen für bestimmte Gebiete innerhalb der Gitterweite globaler Modelle. Viele Fragen, etwa nach der Verfügbarkeit von Wasser oder der Änderung von Wetterextremen, lassen sich eher mit solchen hochaufgelösten Daten beantworten als mit den Ergebnissen der Globalmodelle.“ (JACOB *et al.* 2017)

Abbildung 1.3 zeigt die Auflösungsunterschiede zwischen REMO (12,5 km EUR-11-Auflösung) und MPI-ESM-LR (LR hier für Low Resolution, ca. $1,875^\circ$, was in den Breiten des Untersuchungsgebietes (vgl. Kapitel 2.1) etwa $130 \text{ km} \times 210 \text{ km}$ entspricht) sowie zum Vergleich gerasterte Beobachtungsdaten in 1 km Auflösung (näheres zu den Daten siehe Abschnitt 3.1, 3.2). MPI-ESM-LR ist das Globalmodell, welches für die in dieser Arbeit verwendeten REMO-Daten als GCM-Antrieb dient (siehe Abschnitt 3.2). Hieraus lässt sich bereits erkennen, dass die Auflösung Auswirkungen auf die simulierten Daten – sowohl hinsichtlich der Repräsentation des vergangenen als auch der Projektion des zukünftigen Klimas – und deren praktische Nutzbarkeit für regionale Untersuchungen hat.

Weder für GCM-angetriebene regionale Klimamodelle, noch für die GCMs an sich liegt eine zeitliche Korrespondenz mit der Realität vor. Die simulierten Werte können also nicht einem ex-

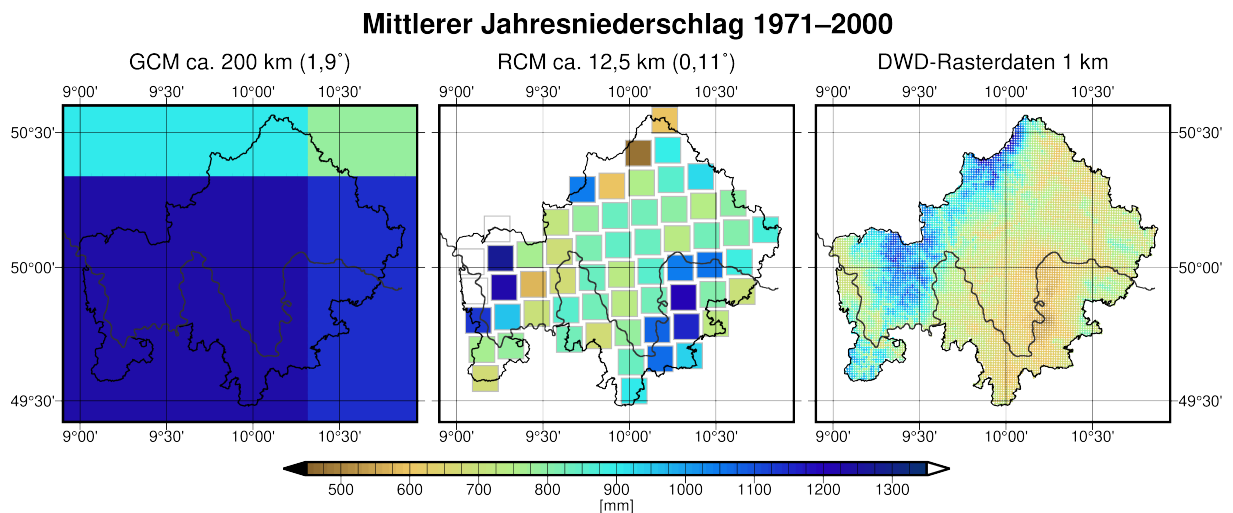


Abbildung 1.3: Auflösungsvergleich Globalmodell – Regionalmodell – gerasterte Beobachtungsdaten. Mittlerer Niederschlag über Unterfranken aus MPI-ESM-LR-, MPI-ESM-LR-REMO2015-Daten sowie gerasterten Beobachtungsdaten des Deutschen Wetterdienstes.

akten Zeitpunkt zugeordnet werden. Stattdessen werden Zeiträume von mehreren Jahrzehnten (meist 30 Jahre) hinsichtlich ihrer Statistiken (Verteilung, Mittelwerte, Schwankungen, Extrema, Auftrittshäufigkeiten bestimmter Grenzwertüberschreitungen etc.) untersucht (vgl. JACOB *et al.* 2017; DOBLER *et al.* 2017).

Es existieren einige typische Schwachstellen von RCMs. Hierzu gehören zu kalte und zu feuchte Bedingungen für die meisten Jahreszeiten und den Großteil Europas sowie zu warme und trockene Sommer in Süd(ost)europa wie sie bei den EURO-CORDEX-RCMs zu finden sind (KOTLARSKI *et al.* 2014). Im Winter werden hier meist zu niedrige Temperaturen simuliert, im Sommer schwanken die Abweichungen je nach Region und Modell. Zu feuchte Winter liegen für weite Teile Europas vor, am stärksten für Mittel- und Osteuropa, in Südeuropa sind sie gebietsweise zu trocken. Für Mitteleuropa findet sich allgemein eine überwiegende Unterschätzung der Temperaturen und Überschätzung der Niederschläge für alle Jahreszeiten. Die interannuelle Variabilität wird für die Winter besser dargestellt als für die Sommer (für Niederschlag und Temperatur, im Sommer wird das Wetter regionaler beeinflusst, im Winter ist das Wetter synoptischen Ursprungs). Der Jahresgang der Niederschläge wird im Mittel für Zentraleuropa sehr schlecht repräsentiert, wobei sehr große Modellunterschiede vorliegen (KOTLARSKI *et al.* 2014). VAUTARD *et al.* (2013) stellen bei der Untersuchung von EURO-CORDEX-RCMs eine Überschätzung der Sommertemperaturextreme (90. Perzentil (siehe 4.1.1) der Temperaturen von Juni, Juli, August) in Zentral- und Südeuropa (Unterschätzung in Skandinavien) fest. Hit-

zewellen werden zu häufig, zu lange und mit zu hoher interannuellen Variabilität simuliert. Des Weiteren wird ein negativer Zusammenhang zwischen der Häufigkeit der simulierten Hitzetage und den mittleren sommerlichen Tagesniederschlägen gefunden. Die Ergebnisse dieser beiden Studien basieren auf Reanalyse-angetriebenen RCMs (sog. perfect boundary conditions). Bei GCM-Randbedingungen kommen zusätzliche Unsicherheiten der GCM-Simulationen hinzu, die durch die RCMs modifiziert (Verbesserung, aber auch Verschlechterung möglich) werden können (vgl. (KOTLARSKI *et al.* 2014; VAUTARD *et al.* 2013; GIORGI & GUTOWSKI 2015; JACOB *et al.* 2014; DOBLER *et al.* 2017)). JACOB *et al.* (2014) zeigen eine bessere Repräsentation der Niederschläge über Europa durch RCMs im Vergleich zu den antreibenden GCMs, bei denen die Verteilung in Richtung zu vieler niedriger und zu wenig höherer Niederschläge verschoben ist (vgl. SUN *et al.* 2006; STEPHENS *et al.* 2010). In Zentraleuropa simulieren viele RCMs eine zu starke Land-Atmosphären-Kopplung (Korrelation sensible und latente Wärmeflüsse sowie Korrelation latente Wärmeflüsse und oberflächennahe Temperatur), was z.B. Konvektion und Bewölkung beeinflusst (KNIST *et al.* 2017). Laut SCHWINGSHACKL *et al.* (2019) wird die Zunahme extremer Temperaturen durch RCMs unterschätzt, weil in diesen im Gegensatz zu GCMs keine Aufheizung der Pflanzen durch Stomataverschluss bei steigenden CO₂-Konzentrationen implementiert ist.

Gerade Niederschlagssimulationen stellen eine große Herausforderung der Klimamodellierung dar. Gängige Klimamodelle – GCMs und RCMs – sind nicht konvektionsauflösend. Konvektion wird also parametrisiert, was zu Modellunsicherheiten führt (DOBLAS-REYES *et al.* 2021; GIORGI 2019). TAPIADOR *et al.* (2019) gehen auf die Parametrisierung der Niederschlagsmikrophysik und damit verbunden Probleme ein. In VILLALBA-PRADAS & TAPIADOR (2022) und RIO *et al.* (2019) werden verwendete Konvektionsparameterisierungen untersucht. Konvektionsauflösende Modelle (Auflösung im Kilometerbereich) bringen vor allem Vorteile hinsichtlich der Repräsentation von Sommerniederschlägen auf Tages- oder niedrigerer Skala und somit für Niederschlagsextrema im Sommer (KENDON *et al.* 2017, vgl. GIORGI 2019).

Allgemein bergen sowohl GCM- als auch RCM-Simulationen immer Unsicherheiten. Diese haben verschiedene Quellen. Zum Einen sind nicht alle Prozesse des Klimasystems verstanden (epistemisch) und Modelle stellen immer vereinfachte Abbilder der Realität dar (inkl. Diskretisierung, Parametrisierung). Zum Anderen gibt es Unsicherheiten hinsichtlich des Antriebes (Treibhausgaszenarien, aber auch Landnutzung etc.) und verschiedene Modelle reagieren unterschiedlich auf gleiche Antriebe (strukturelle Unsicherheit). Hinzu kommt die interne Varia-

bilität des jeweiligen Systems (v.a. durch Land- und Ozeanprozesse, die träger als atmosphärische Prozesse sind; im RCM die eigene und zusätzlich die von den Globaldaten übertragene) und bzgl. RCMs das verwendete Downscalingverfahren (GIORGI & GUTOWSKI 2015; GIORGI 2019; MARAUN & WIDMANN 2018; DOBLER *et al.* 2017).

Daher ist es sinnvoll, die zu untersuchenden Daten vor der Analyse von Zukunftsprojektionen auf (systematische) Fehler hin zu untersuchen und zu korrigieren (näheres zu dieser Korrektur siehe Abschnitte 4.3 und 4.4) sowie ein Ensemble mehrerer Modelle zu betrachten (vgl. z.B. GIORGI & GUTOWSKI 2015; GIORGI 2019; MARAUN & WIDMANN 2018; JACOB *et al.* 2017; DOBLER *et al.* 2017). Letzteres geschieht hier nur auf Basis der besten Methoden des Referenzmodells REMO.

1.3 Zielsetzungen und Vorgehensweise

Aus den Ausführungen der vorangegangenen Abschnitte lassen sich folgende Zielsetzungen für diese Arbeit formulieren:

- Herausarbeitung relevanter klimatischer Kenngrößen für Land-, Forstwirtschaft sowie Weinbau in Unterfranken
- Güteabschätzung von regionalen Klimamodelldaten hinsichtlich dieser Größen
- Korrektur vorhandener systematischer Fehler und statistische Simulation durch unterschiedliche Methoden
- Vergleich der Methoden hinsichtlich des Korrektur- bzw. Simulationserfolges
- Analyse der projizierten Zukunftsentwicklung der Zielgrößen mithilfe der jeweils besten Methode
- Simulation von Ertragszahlen aus Acker- und Weinbau: Gütebewertung und Zukunftsprojektionen

Abbildung 1.4 zeigt die Vorgehensweise zur Bearbeitung dieser Teilaspekte: Die Kommunikation mit in der Land-, Forstwirtschaft sowie im Weinbau tätigen Unternehmen (Mitte) stellt die Basis zur Findung der zu untersuchenden klimatischen Zielgrößen (Mitte oben) dar. Diese werden anschließend aus Modelldaten berechnet (links oben) und die Repräsentation der jeweiligen Kenngröße durch das Klimamodell bewertet. Anschließend folgt eine Anpassung der Modell-

an die Beobachtungsdaten mit Hilfe mehrerer statistischer Korrekturverfahren (Biaskorrektur) (linke Seite). Parallel dazu werden die herausgearbeiteten Kennwerte sowie Ertragszahlen aus Landwirtschaft und Weinbau unter Verwendung eines explorativen Verfahrens modelliert (rechte Spalte): Reanalyse-angetriebene Regionalklimamodell­daten atmosphärischer und bodennahe­rer Variablen werden genutzt, um die gesuchten Größen durch so genannte Model Output Statistics (MOS) unter Anwendung verschiedener Regressionstechniken zu simulieren. Diese Regressionsmodelle werden anschließend auf Globalmodell-angetriebene Regionalklimamodell­daten übertragen. Sowohl die Güte dieser Simulationen als auch die der Biaskorrektur der berechneten Zielgrößen werden validiert, um die Methode mit den besten Ergebnissen für die Untersuchung von Zukunftsprojektionen zu verwenden (Mitte unten). Zusätzlich zu den klimatischen Zielgrößen werden Erträge aus Acker- und Weinbau untersucht. Da sie nicht direkt berechnet, sondern nur simuliert werden können, ist die linke Seite des Schemas in Abbildung 1.4 nicht anwendbar.

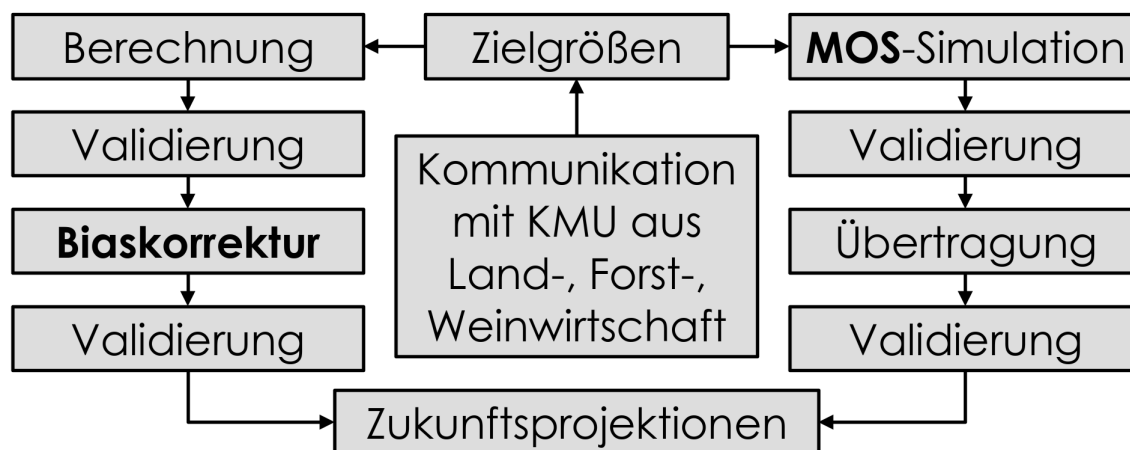


Abbildung 1.4: Fließdiagramm zur Vorgehensweise dieser Studie.

Die Arbeit ist folgendermaßen aufgebaut: Im Kapitel 2 wird zunächst auf das Untersuchungsgebiet, seine natürlichen Gegebenheiten sowie seine Nutzung eingegangen (2.1). Anschließend erfolgt die Herausarbeitung der zu untersuchenden Zielgrößen (2.2) sowie eine Vorstellung der jeweiligen Berechnungsvorschriften (2.3). Kapitel 3 ist den in dieser Arbeit verwendeten Daten gewidmet: Beobachtungs- (3.1) sowie Modell­daten (3.2) und deren Vorverarbeitung (3.3). Darauf folgt das Methodenkapitel 4, in welchem zunächst statistische Grundlagen und Definitionen (4.1) erläutert werden, bevor auf Verfahren zur Güteabschätzung und Modellvalidierung (4.2) eingegangen wird. Der Abschnitt zur Biaskorrektur (4.3) umfasst die Erläuterung verschiedener Korrekturverfahren sowie die damit zusammenhängende Vorgehensweise. Gleiches gilt für das sich anschließende Themenfeld der Model Output Statistics (4.4): Hier wird neben den grund-

legenden Regressionverfahren ebenfalls auf Details zu Vorverarbeitung und Durchführung eingegangen. Im Anschluss erfolgt die Darlegung der Ergebnisse für die klimatischen Kennwerte (Kapitel 5) in Bezug auf Modellvalidierung (5.1), Biaskorrektur (5.2) sowie Model Output Statistics (5.3). Darauf beziehend wird in einem Syntheseteil (5.4) die beste Korrektur- bzw. Simulationsmethode ermittelt (5.4.1) sowie auf Zukunftsprojektionen angewendet (5.4.2). Diese Zukunftsprojektionen werden zusätzlich im Rahmen eines Multimodellensembles untersucht (5.4.3). Das zweite Ergebniskapitel 6 behandelt Ertragszahlen aus Landwirtschaft und Weinbau, die mittels Model Output Statistics simuliert werden. Auch hier werden Simulationsergebnisse, Zukunftsprojektionen sowie die Anwendung auf ein Multimodellensemble vorgestellt. Zur Einordnung der Ergebnisse beginnt die Diskussion (Kapitel 7) mit einem umfassenden literaturbasierten Unterkapitel zum Thema Pflanzenproduktion und Klimawandel (7.1). Anschließend werden die Ergebnisse der Kapitel 5 und 6 zusammengefasst (7.2) und diskutiert (7.3). Zur Abrundung werden Schlussfolgerungen im Bezug auf die Zielsetzungen gezogen (Kapitel 8).

2 Untersuchungsgebiet und Zielgrößen

In den folgenden Abschnitten wird die Untersuchungsregion dieser Arbeit abgegrenzt (Abschnitt 2.1) sowie ihre natürlichen Gegebenheiten (2.1.1–2.1.2) und ihre Nutzung (2.1.4) vorgestellt. Im Anschluss wird auf die zu untersuchenden klimatischen Aspekte (2.2) sowie der Berechnung der daraus abgeleiteten Zielgrößen (2.3) eingegangen.

2.1 Untersuchungsgebiet

Wie bereits in Abschnitt 1.1 erläutert, thematisiert diese Arbeit die Auswirkungen des Klimawandels auf Land-, Forstwirtschaft und Weinbau in Unterfranken. Auch wenn der thematische und interpretatorische Schwerpunkt auf Unterfranken liegt (daher wird in den folgenden Abschnitten auch hierauf der Fokus gelegt), umfasst das untersuchte Areal auch den Regierungsbezirk umgebende Bereiche (8–12° O, 49–50,75° N), wie in Abbildung 2.1 dargestellt. Dieses Gebiet wird im Folgenden auch *Unterfranken+* genannt. Auf eine engere Eingrenzung für einzelne Untersuchungen wird in Kapitel 3 eingegangen.

Das betrachtete Gebiet liegt in Mitteleuropa, in der südlichen Mitte Deutschlands und umfasst Anteil von Bayern, Baden-Württemberg, Hessen, Thüringen und Rheinland-Pfalz sowie kleine Flächen von Sachsen (und je nach Auflösung der gewählten Daten von Frankreich). Folgende Abbildung 2.1 zeigt die Höhenverhältnisse (Topographie), die kreisfreien Städte sowie Landkreise Unterfrankens mit Kreisstädten, eine Auswahl an kreisfreien Städten außerhalb Unterfrankens und die Lage der KMU-Projektpartner.

In dunkelroter Färbung ist im Westen deutlich das Rhein-Main-Tiefland (Höhenminima unter 100 m) zu erkennen.. Im Gegensatz hierzu reichen die Höhen (von West nach Ost) von Westerwald, Taunus, Vogelsberg, Rhön, Thüringer Wald, Frankenwald und Fichtelgebirge in blauer Färbung bis über 900 m. Im Zusammenhang zur Topographie stehen Geologie und Naturraumgliederung. Unterfranken selbst liegt auf Höhen zwischen etwa 100 m (bei Kahl am Main) und 928 m (Dammersfeldkuppe und Kreuzberg in der Rhön) (LOTH *et al.* 2013).

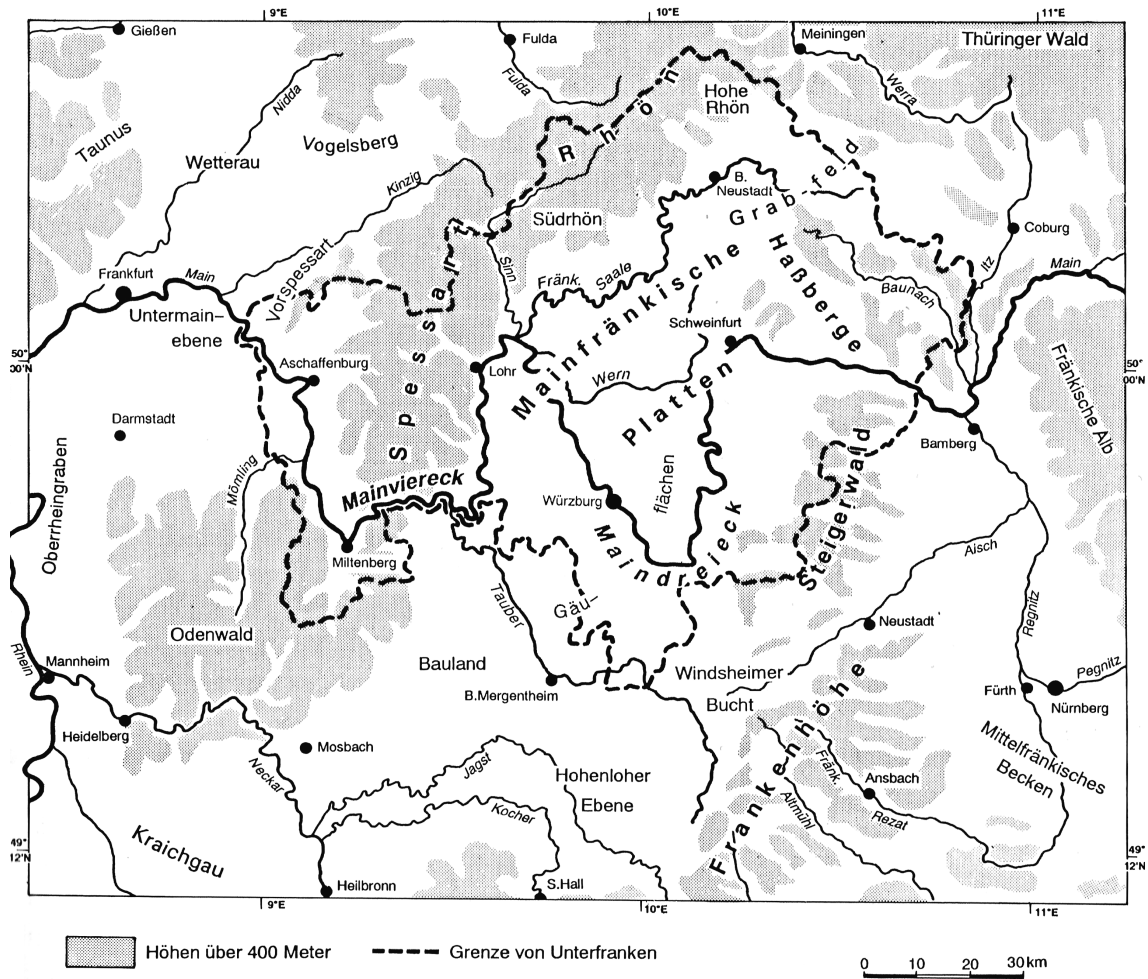


Abbildung 2.2: Interne Gliederung Unterfrankens und umgebender Bereiche (MÜLLER 1996).

Zum Verständnis der Geologie des Untersuchungsgebietes ist die Betrachtung eines Schnittes wie in Abbildung 2.3 hilfreich. Die dort erkennbaren Schichten besaßen ursprünglich eine horizontale Anordnung: Das variszische Grundgebirge (mehr oder weniger stark metamorphisch überprägte Sedimentgesteine und magmatische Gesteine aus Präkambrium bis Devon, Orogenese im Devon und Karbon) wurde teilweise erodiert und anschließend überlagert von marinen und terrestrischen Ablagerungen der permomesozoischen Sedimentation (Deckgebirge). Es finden sich also übereinander gelagert Sedimentite aus Oberkarbon–Perm (Rotliegendes, Zechstein), Trias (Buntsandstein, Muschelkalk, Keuper (letzterer in der Abbildung dreigeteilt), Jura (Lias, Dogger, Malm) und Kreide (hier nur Oberkreide) (BAUMHAUER 2007a; DOPPLER *et al.* 2004; LOTH *et al.* 2013; MÜLLER 1996). Durch die alpine Orogenese im Tertiär wurden Schwarzwald, Vogesen, Odenwald und Pfälzer Wald angehoben und der Oberrheingraben entstand. Dies hatte eine Verkippung der Süddeutschen Großscholle (in deren Nordwesten sich Unterfranken befindet) um $1\text{--}2^\circ$ (BAUMHAUER 2007a) zur Folge (BAUMHAUER 2007a; DOPP-

LER *et al.* 2004; LOTH *et al.* 2013; MÜLLER 1996). Diese Schrägstellung in Verbindung mit anschließender Abtragung resultiert in einer Abnahme des Alters des anstehenden Gesteins von West (Nordwest) nach Ost (Südost) (BAUMHAUER 2007a; DOPPLER *et al.* 2004; MÜLLER 1996). Im Westen Unterfrankens wurde gebietsweise das gesamte Deckgebirge abgetragen und das Grundgebirge freigelegt (kristalliner Vorspessart) (MÜLLER 1996; DOPPLER *et al.* 2004; LOTH *et al.* 2013). Gleiches gilt für Thüringer Wald, Frankenwald und Fichtelgebirge jenseits der fränkischen Linie als weiterer Verwerfung im Osten (MÜLLER 1996). Die für die Region charakteristischen Schichtstufen sind auf die Unterschiede der Gesteine hinsichtlich ihrer Abtragungsresistenz zurückzuführen (BAUMHAUER 2007b; LOTH *et al.* 2013). Aufgrund der tektonischen Aktivität im Tertiär kam es zudem zur Bildung vulkanischer Gesteine (Westerwald, Vogelsberg, Rhön, Heldburger Gangschar, z.T. Odenwald, Kraichgau, Spessart) (BAUMHAUER 2007a; LOTH *et al.* 2013). Auch tertiäre und quartäre Sediment(gestein)e sind in Teilen des Untersuchungsgebiets zu finden (LOTH *et al.* 2013).




Abbildung 2.3: Geologischer Schnitt von Aschaffenburg ($9,15^{\circ} O$, $49,97^{\circ} N$) nach Weiden in der Oberpfalz ($12,16^{\circ} O$, $49,68^{\circ} N$) (DOPPLER *et al.* 2004) (Koordinaten GEOBASIS-DE 2017).

Weitere Informationen zu Naturraum und Geologie sind in den Anhängen A1.1 und A1.2 zu finden.

2.1.2 Klima

Durch die Lage in Mitteleuropa befindet sich das Untersuchungsgebiet großräumig betrachtet im Bereich der Frontalzone, in der tropische Warm- und polare Kaltluftmassen aufeinandertreffen, was Instabilität und die Bildung von Tiefdruckgebieten bedingt (GLASER & SCHÖNBEIN 2007). Durch das Vorherrschen westlicher Wetterlagen führen atlantische Luftmassen im allgemeinen zu milden Temperaturen und unbeständigem Wetter (MÜLLER 1996). Verallgemeinert liegt Unterfranken und das gesamte Untersuchungsgebiet mit einigen Ausnahmen „im Bereich des kühlgemäßigten, subozeanischen Klimas der außertropischen Westwindzirkulation“, wobei Richtung Osten ein Übergang zu subkontinentalen Bedingungen erkennbar wird (MÜLLER 1996). Da die aktualisierte (Basiszeitraum 1980–2016) effektive Köppen-Geiger-Klimaklassifikation nach BECK *et al.* (2018) eine andere Grenze zwischen kalten (D) und gemäßigten (C) Klimaklassen zieht (kältester Monat max. 0 °C anstatt -3 °C nach PEEL *et al.* 2007), sind gemäß dieser Großteile des Untersuchungsgebiets der Klimaklasse Dfb (kaltes Klima ohne Trockenzeit mit warmen Sommern (heißester Monat unter 22 °C, aber mindestens 4 Monate über 10 °C)) zuzuordnen. Die Bereiche mit sehr geringer Höhenlage im Westen inkl. Kraichgau, Lahnsenke sowie Teile des Main- und Taubertals zeichnen sich durch wärmeres Klima aus (Klasse Cfb: Gemäßigtes Klima (kältester Monat über 0 °C) ohne Trockenzeit mit warmem Sommer). Die Höhen von Thüringer Wald und Fichtelgebirge werden zum Teil der Dfc-Klasse (kalt, keine Trockenzeit, kalte Sommer) gezählt. Nähere Informationen zur Klassifizierung sind in PEEL *et al.* 2007 und BECK *et al.* 2018 zu finden.

Die mittleren Verhältnisse von Temperatur und Niederschlag im Zeitraum 1971–2000 sind in den Abbildungen 2.4 und 2.5 zu sehen. Beide zeigen im Grundsatz eine deutliche topographische Prägung (vgl. Abbildung 2.1) mit hohen Niederschlägen und niedrigen Temperaturen in höheren Lagen und geringeren Niederschlägen sowie höheren Temperaturen in geringeren Höhen (vgl. z.B. GLASER & SCHÖNBEIN 2007). Die oben genannten Cfb-Bereiche sind deutlich anhand ihrer höheren Mitteltemperaturen zu erkennen. Die niedrigsten Niederschläge finden sich im westlichen Bereichs des Rhein-Main-Tieflandes im Lee der Mittelgebirge (im südlichen Bereich des im Untersuchungsgebiet befindlichen Rheintieflandes wird dies durch die Zaberner Senke abgemildert) sowie in den niedrigen Höhenlagen des östlichen Maindreiecks. Generell sind Luv-Lee-Gegensätze erkennbar, sowohl im westlichen Rheingraben als auch in den Mainfränkischen Platten bestehen zudem Föhneffekte, was zusätzlich trockenere und warme Bedingungen begünstigt (vgl. MÜLLER 1996; GLASER & SCHÖNBEIN 2007).

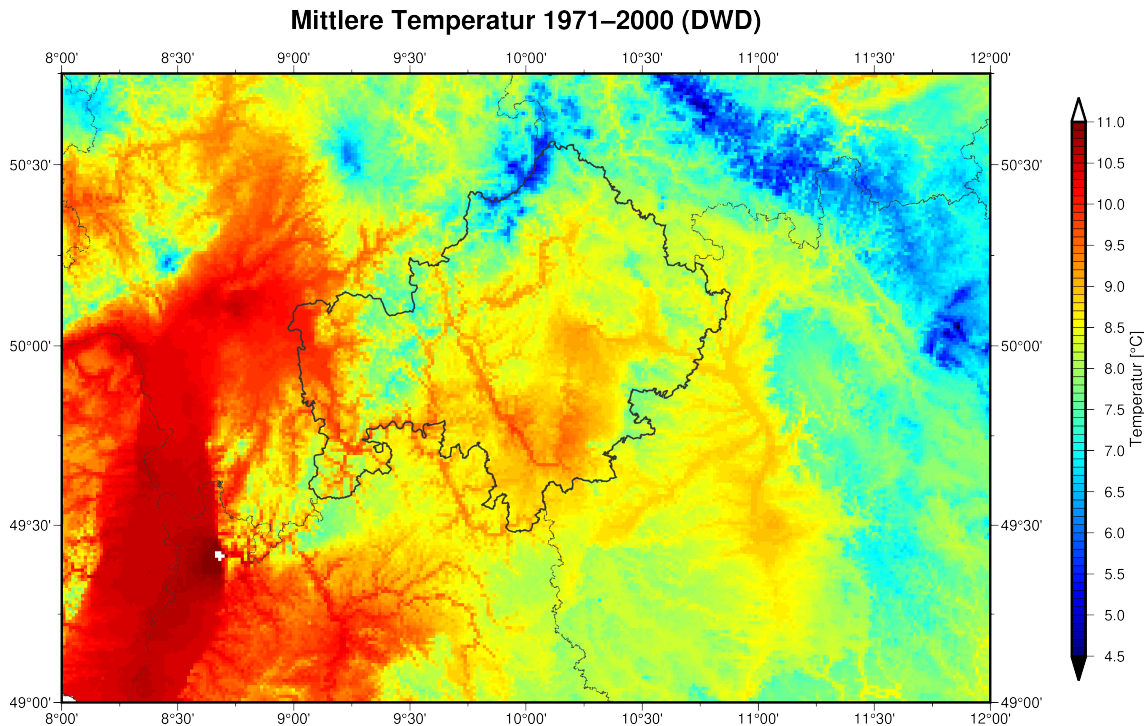


Abbildung 2.4: Mitteltemperatur 1971–2000 (Daten DWD 2021a, Verwaltungsgrenzen GEOBASIS-DE 2017).

Im langjährigen räumlichen Mittel des Untersuchungsgebietes liegt ein primäres Sommer- (Juni) und ein sekundäres Wintermaximum (Dezember) der Niederschläge vor (Abbildung 2.7a). Werden jedoch die regional niedrigsten und höchsten Werte betrachtet, so findet sich für erstere ein klares Sommermaximum (Juni, Dominanz konvektive Niederschläge), während für die regionalen Maxima die höchsten Niederschläge im Dezember (zweithöchste im Juli) erkennbar werden. Dies entspricht den advektiven Wintermaxima, die in den Höhenlagen (generell feuchtere Gebiete) typisch sind, sowie den konvektiven Sommermaxima, wie sie für Beckenlagen und allgemein für das Schichtstufenland zu erwarten sind (GLASER & SCHÖNBEIN 2007).

Im Zusammenspiel aus Niederschlag und Temperatur resultieren in einigen Bereichen des Untersuchungsgebietes subhumide Bedingungen. Um das südliche Maindreieck, in der Windsheimer Bucht und dem Mittelfränkischen Becken sowie dem Oberrheinischen Tiefland ist der Niederschlag gebiets- und zeitweise geringer als die Verdunstung. Pedologische und geologische Verhältnisse sowie die darausfolgende Boden- und Grundwasserverfügbarkeit prägen dann natürliche Vegetation und Anbaumöglichkeiten (MÜLLER 1996). Mit Ausnahme der humiden (in hohen Höhen z.T. perhumiden) Höhenlagen besitzt auch der Rest des UGs größtenteils nur eine leicht positive Wasserbilanz, ist also trockenheitsgefährdet (MÜLLER 1996). Abbildung

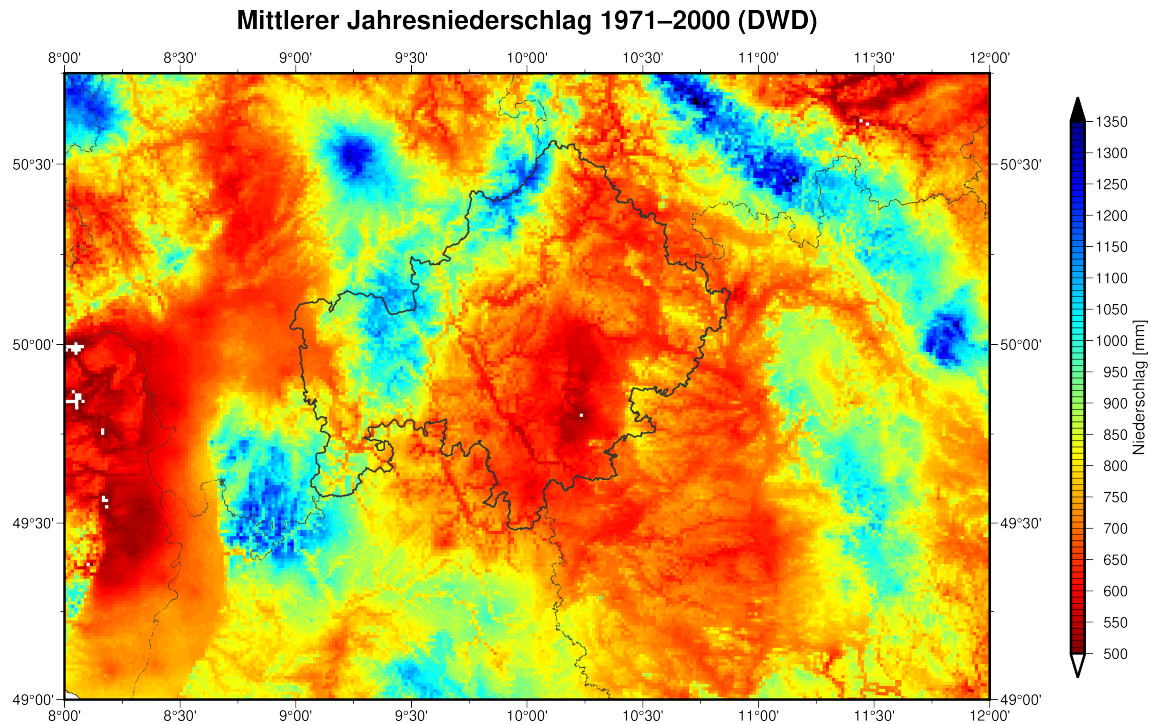


Abbildung 2.5: Mittlerer Jahresniederschlag 1971–2000 (Daten DWD 2021b, Verwaltungsgrenzen GEOBASIS-DE 2017).

2.6 zeigt die durchschnittliche klimatische Wasserbilanz für den Zeitraum 1991–2020⁶. Weiße Flächen stehen für eine negative Wasserbilanz im Jahresmittel, die jährliche potenzielle Verdunstung übersteigt also die Jahresniederschlagssumme. Im Westen des UG sind dies fast das gesamte Rhein-Main-Tiefland inkl. des Beckengebietes zwischen Taunus und Vogelsberg sowie das Limburger Becken. Auch zwischen Vogelsberg und Rhön treten zum Teil Wasserdefizite auf, ebenso in Großteilen der Mainfränkischen Platten (v.a. um das östliche Mairdreieck sowie in der Windsheimer Bucht (Nomenklatur LFU o.J.) südöstlich davon), des Taubertals sowie des Neckartals um Heilbronn. Gleiches gilt für Bereiche des Fränkischen Keuper-Lias-Landes (Mittelfränkisches Becken (Nomenklatur LFU o.J.) v.a. um Nürnberg) sowie des Thüringer Beckens und Vogtlandes.

⁶Wenn möglich, wird in dieser Arbeit der Zeitraum 1971–2000 als klimatologischer Zeitraum bzw. als Basiszeitraum verwendet. Für die potenzielle Verdunstung sind jedoch erst ab 1991 Daten verfügbar, sodass hier ein anderer 30-jähriger Zeitraum Verwendung findet. Die gezeigte Wasserbilanz beinhaltet daher eine Jahrestemperaturerhöhung zwischen den beiden Zeiträumen von durchschnittlich 0,81 °C (je nach Gitterzelle 0,43–1,31 °C), wobei der Niederschlag im Mittel um 12,13 mm abgenommen hat (Veränderung -103,23–+110,10 mm).

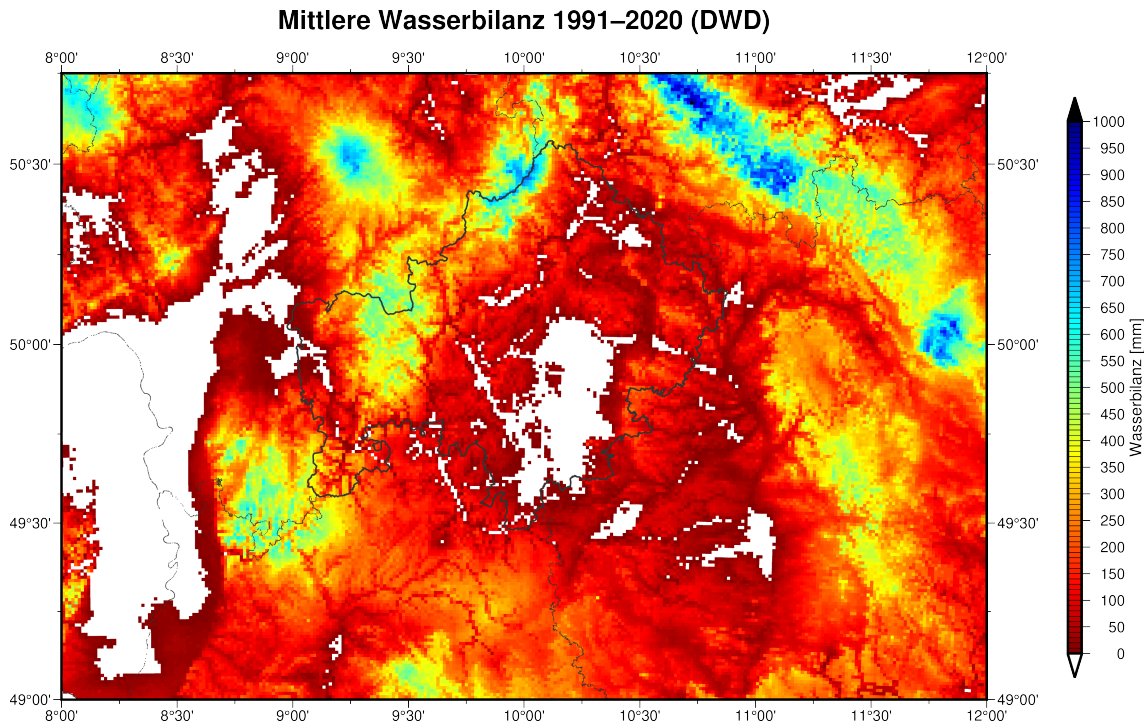


Abbildung 2.6: Mittlere Wasserbilanz 1991–2020 (Daten DWD 2021c,b, Verwaltungsgrenzen GEOBASIS-DE 2017).

Im Jahresgang (Abbildung 2.7b) ist die regional gemittelte Wasserbilanz zwischen April und August negativ, wobei von März bis September negative Werte auftreten und auch in den übrigen Monaten gebietsweise niedrige Werte vorzufinden sind. Zusätzlich erschwert wird die Wasserversorgung im Bereich der Mainfränkischen Platten durch gebietsweise auftretenden Karst, so dass wenig oberflächennahes Grundwasser zu Verfügung steht (MÜLLER 1996).

Verallgemeinert kann das Untersuchungsgebiet bis auf die Höhenlagen also als relativ warm und trocken beschrieben werden. Gerade für solche Regionen bestehen im Bezug auf Land- und Forstwirtschaft klimatische Risiken (Hitze, Trockenheit). Für bisher kühle und feuchte Gebiete hingegen wird mit besseren Anbaubedingungen gerechnet (BMELV 2008). Dies unterstreicht die Notwendigkeit, land- und forstwirtschaftlich relevante klimatische Kenngrößen gerade für dieses Gebiet zu untersuchen.

2.1.3 Boden

Da die Böden des Untersuchungsgebietes sich erst seit der letzten Eiszeit bilden konnten und relativ geringe Niederschläge vorherrsch(t)en, sind sie in der Regel nicht ausgelaugt. Auf den Mainfränkischen Platten außerhalb der Gäuflächen sowie im Vorspessart und gebietsweise in




Abbildung 2.7: Jahresgang von Niederschlag und Wasserbilanz im Untersuchungsgebiet (Daten DWD 2021c,b). Die schwarze Linie zeigt regionale Mittelwerte, die beiden grauen Linien entsprechende Minima und Maxima.

den östlichen Rahmenhöhen treten Braunerden und ähnliche Bodentypen auf „und werden zu meist intensiv ackerbaulich genutzt“ (MÜLLER 1996). Noch ertragreichere Böden sind die Parabraunerden der Gäuflächen. Ihre Fruchtbarkeit basiert auf den eiszeitlichen Lößablagerungen (periglazial) dieser Gegend. Hier stellt jedoch Erosion ein großes Problem dar, ebenso wie teilweise eine defizitäre Wasserversorgung. In den westlichen Rahmenhöhen sind aus dem Zusammenspiel sandiger Ausgangsgesteine und größerer Niederschlagssummen podsolige Braunerden entstanden, ebenso wie „auf den Flugsandfeldern im Raum Kitzingen und am Untermain“ (MÜLLER 1996). Diese sind arm an Tonmineralen und daher Nährstoffen und haben eine Tendenz zur Versauerung. Deshalb sind sie meist mit Nadelwäldern bepflanzt. Aufgrund toniger Ausgangsubstrate (Tonmergel, Tonstein) finden sich in den östlichen Rahmenhöhen häufig Pelosole mit Weidenutzung. Nur wenig Pedogenese mit resultierenden Rendzinen fand schließlich in Bereichen der westlichen Mainfränkischen Platten auf unbedeckten Kalksteinen (des Muschelkalk) statt. Diese tragen meist Kiefernforste (MÜLLER 1996).

Diese typischen Böden Unterfrankens mit ihrer vorherrschenden Nutzung deuten auf die tatsächliche Vegetation hin. Wie bereits im Kapitel 1.1 genannt, werden etwa 40 % der Fläche Unterfrankens forstwirtschaftlich genutzt, rund ein Drittel landwirtschaftlich (inkl. Weinbau) (LFSTAT 2022).

2.1.4 Nutzung: Land- und Forstwirtschaft

Die Wälder Unterfrankens sind Forste, ihre Baumartenverteilung wird daher anthropogen bestimmt (MÜLLER 1996). Die Bundeswaldinventur 2012⁷ erfasste hierbei auf 62,9 % der Fläche Laubbäume (25,6 % Buche, 22,0 % Eiche). Bei den Nadelbäumen besaßen Fichte (16,9 %) und Kiefer (13,4 %) die größten Flächenanteile (LWF 2012) (vgl. hierzu auch Unterteilung der Waldflächen in Abbildung 1.2). Auch wenn der Anteil an Laubbäumen also überwiegt, ist zu bedenken, dass die potenzielle natürliche Vegetation Unterfrankens hauptsächlich durch Buchenwald (*Fagus sylvatica*) und zum Teil Eichen-Hainbuchenwald (Stieleiche *Quercus robur* mit Beimischung von Hainbuche *Carpinus betulus*) gebildet wird (MÜLLER 1996). Nicht nur kann Nadelbewuchs an Laubstandorten eine Bodenversauerung bedingen (MÜLLER 1996), auch die Anpassung an klimatische Veränderungen fällt standortfremden Arten mitunter schwerer (BMU *et al.* 2008; KAISER 1994; SCHULDT *et al.* 2020).

Neben dem Wald ist die gesamte Vegetation Unterfrankens und des Untersuchungsgebietes anthropogen geprägt (MÜLLER 1996). Im Jahr 2016 wurden 32,2 % der Fläche Unterfrankens als Ackerland genutzt (LFSTAT 2022). Hiervon entfielen 59,8 % auf Getreide (zur Körnergewinnung), 10,9 % auf Winterraps, 10,4 % auf Silo-/Grünmais sowie 6,2 % auf Zuckerrüben. Das angebaute Getreide war überwiegend Weizen (60,5 %, davon 96,3 % Winterweizen), gefolgt von Gerste (24,8 %). Der Anbau von Triticale (5,8 %), Roggen (4,9 %), Körnermais (2,8 %) sowie Hafer (1,0 %) nahm geringere Flächenanteile ein (LFSTAT 2023).

Landschaftlich, kulturell und wirtschaftlich von besonderer Bedeutung ist der Weinbau mit der fränkischen Charaktersorte Silvaner. Er wird aufgrund der thermischen Begünstigung meist an Hängen mit Süd- bis Westausrichtung betrieben. Die Diversität der unterschiedlichen Terroirs (Zusammenspiel aus Geologie, Boden, Topographie und Klima (HOPPMANN *et al.* 2010)) führt zu einem hohen Abwechslungsreichtum der fränkischen Weine. Das „räumliche Nebeneinander unterschiedlicher Gesteine der Trias“ (STMELF 2011) ist ein Alleinstellungsmerkmal des Frankenweingebietes (LOTH *et al.* 2013; STMELF 2011; HOPPMANN *et al.* 2010; MÜLLER 1996). Der mainfränkische Weinbau ist ab dem achten Jahrhundert n. Chr. belegt. Das Maximum der Rebflächenausdehnung wurde im 16. Jahrhundert mit etwa 40000 ha erreicht, danach ging sie bis zum Jahr 1959 (2300 ha) deutlich zurück. Seit dieser Zeit wird der Weinanbau in

⁷Die aktuelle Inventur findet bis zum Ende des Jahres 2022 statt (BUNDESGESETZBLATT 2019).

Mainfranken gezielt gefördert („Qualitätsweinanbau [...] mit dem Leitziel [...] des «fränkisch-trockenen» Ausbaus“, Genossenschaftsgründungen, Senkung des Arbeitsaufwandes um 80 % durch Weinbergsbereinigungen, Weintourismusförderung), so dass er inzwischen wieder eine hohe ökonomische und kulturelle Relevanz für Mainfranken besitzt (SCHENK 2007).

Auf den Mainfränkischen Platten ist zudem Streuobstanbau landschaftsprägend. Dieser extensive Anbau von Äpfeln, Birnen (diese v.a. zur Weiterverarbeitung) und verschiedenen Pflanzen der Gattung *Prunus* (z.B. Mirabelle, Kirsche, Zwetschge) fördert die Biodiversität und hat eine große historische Bedeutung. Zu finden ist er vor allem um Dörfer und auf für ackerbauliche Nutzung ungünstigen Standorten (MÜLLER 1996).

Weit intensiver und mit höheren Bödenansprüchen verbunden ist die Kultivierung von Zuckerrüben. Der Fokus des deutschen Zuckerrübenanbaus liegt auf den Lößgebieten. Neben den Bördegebieten in West- und Norddeutschland sowie um die bayerische Donau, finden sich diese auch innerhalb des Untersuchungsgebietes. Der gesamte Südwesten und Westen bis nordöstlich von Frankfurt sowie die Landkreise Würzburg, Schweinfurt, Kitzingen, Neustadt/Aisch sind hierbei zu nennen (BLE 2021; GEBHARDT 2007). Von den sieben deutschen Fabrikstandorten der Südzucker AG (SÜDZUCKER 2022) befinden sich drei innerhalb des Untersuchungsgebietes (siehe Anhang A2). In West- und Norddeutschland erfolgt die Zuckerproduktion durch andere Unternehmen (GEBHARDT 2007).

2.2 Kenngrößenwahl

Die Auswahl der zu untersuchenden Zielgrößen basiert auf einer Umfrage unter den KMU-Partnerunternehmen innerhalb des Projekts *BigData@Geo*. Hierbei wurde gezielt nach klimatologischen Kenngrößen außerhalb der typischen Variablen Durchschnittstemperatur und -niederschlag gesucht. Die Antworten von 16 Unternehmen auf die Frage „Welche klimatischen Rahmenbedingungen, Prozesse, Ereignisse oder Variablen sehen Sie als wichtig für Ihre Anbauprodukte?“ beinhalteten die in Abbildung 2.8 aufgeführten Kennwerte. Aufgrund der Seltenheit sowie der schlechten Beobachtungsdatenlage⁸ und der hohen Entstehungskomplexität wird Hagel als Zielgröße verworfen. Nach weiterem Ausschluss von Durchschnittsnieder-

⁸An der Station Würzburg z.B. wurden in den Jahren 1949 bis 2014 insgesamt 99 Hagelereignisse registriert, pro Jahr also durchschnittlich 1.5 Ereignisse (DWD 2021d)

schlag und -temperatur (s.o.) sind die fünf am häufigsten genannten Rahmenbedingungen (in Abbildung 2.8 grau hinterlegt): Spätfrost, Trockenheit, Hitze, Frost und Starkniederschlag. Diese Größen decken wichtige Aspekte der Variabilität und Intensität von Niederschlag (Starkregen, Trockenheit) und Temperatur (Spätfrost, Frost, Hitze) mit ab. Auch die (fluviale) Erosion, welche ebenfalls nicht durch (flächige) Beobachtungsdaten abgedeckt ist, wird indirekt durch die Thematisierung von Starkregen mitbehandelt. Unter die Kategorie *Sonstiges* fallen folgende Nennungen: Verdunstung, Wetter im Jahresverlauf, Regen-Frost-Kombination, Schädlinge. Letztere sowie Bodenparameter stellen keine klimatischen Rahmenbedingungen dar, wurden aber von den KMU genannt und daher hier aufgeführt.

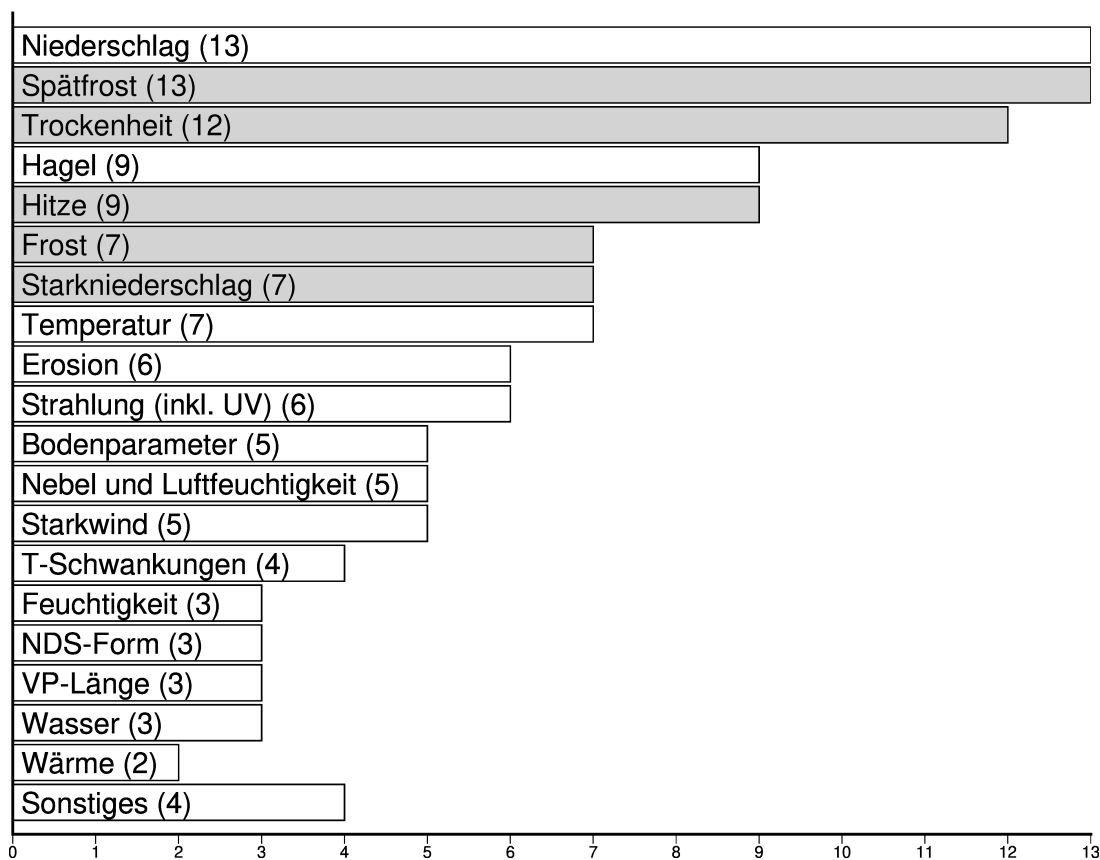


Abbildung 2.8: Nennungshäufigkeit relevanter klimatischer Rahmenbedingungen. Auswahl (siehe Text) grau hinterlegt. Abkürzungen UV Ultraviolett, T Temperatur, NDS Niederschlag, VP Vegetationsperiode.

Die gewählten Aspekte überschneiden sich mit den Ergebnissen einer Umfrage unter mehreren hundert Personen aus Landwirtschaft und landwirtschaftlicher Beratung zu den erwarteten Klimawandelauswirkungen im Bezug auf die deutsche Getreideerzeugung, bei der milde Winter (also Ausbleiben von Frost), Dürre, Hitze und Starkregen am häufigsten genannt wurden (MACHOLDT & HONERMEIER 2016).

2.3 Indexberechnung

Die fünf gewählten Rahmenbedingungen (siehe Abbildung 2.8) stellen klimatische Extremereignisse dar, die durch verschiedene Kennwerte beschrieben werden können. Die verwendeten Indizes sind in Tabelle 2.1 aufgeführt.

Tabelle 2.1: Untersuchte Indizes. Die zeitliche Auflösung der Eingangs- (in) und Ausgabedaten (out) ist je nach Index täglich (d), monatlich (m) oder jährlich (a). P = Niederschlag, T = bodennahe Temperatur, Tmax = Tagesmaximum von T, Tmin = Tagesminimum von T, Q95 = 95. Perzentil, siehe 4.1.1..

| Ereignis | Kürzel | Index | Berechnung | in | out |
|-------------------|----------------------------------------------------------------------------|----------------------------------------|----------------------------------------|----|-----|
| Trockenheit | R1mmn | Anzahl der Trockentage | Tage mit $P < 1 \text{ mm}$ | d | m |
| | MCD | Maximum number of consecutive dry days | max. Anzahl konsekutiver R1mmn-Tage | | |
| | DMI | De Martonne-Index* | $DMI=12P/(T+10)$ | | |
| Starkniederschlag | R95n | Anzahl der Tage mit Starkniederschlag | Tage mit $P > Q95(P_{obs}, 1961-1990)$ | d | m |
| Hitze | Hitze(tage) | Anzahl der heißen Tage | Tage mit $T_{max} \geq 30 \text{ °C}$ | | |
| Frost | Frost(tage) | Anzahl der Frosttage | Tage mit $T_{min} < 0 \text{ °C}$ | | |
| | Eis(tage) | Anzahl der Eistage | Tage mit $T_{max} < 0 \text{ °C}$ | | |
| Spätfrost | Anzahl der Frosttage nach Beginn der Vegetationsperiode (VP) bis Ende Juni | | | d | a |
| | late (VPM) | monatsbezogene VP | ab April | | |
| | late (VPT) | thermische VP | 5 Folgetage $T \geq 5 \text{ °C}$ | | |

* (DE MARTONNE 1926a,b, 1942)

Mit Ausnahme des Trockenheitsindex nach DE MARTONNE (1926a,b, 1942) basieren alle verwendeten Kennwerte auf Grenzwertunter- bzw. -überschreitungen von Niederschlag oder Temperatur(-maximum, -minimum- oder -mittel). Die verwendeten Indizes basieren auf den Empfehlungen führender Klimaforschungsorganisationen (IPCC (Intergovernmental Panel on Climate Change), WCRP (World Climate Research Programme), WMO (World Meteorological Organization)) zur Untersuchung von Klimaextremen (z.B. SENEVIRATNE *et al.* 2012; NICHOLLS & MURRAY 1999; FRICH *et al.* 2002; PETERSON *et al.* 2001; ETCCDI 2022). Frosttage, Eistage, heiße Tage und Trockentage (als Gegenteil des Niederschlagstages) stellen zudem klimatologische Kenntage dar (DWD 2022). Die Anzahl der Trockentage sowie deren maxi-

male Andauer und die Anzahl der Starkniederschlagstage werden auch in KEUPP *et al.* (2019) verwendet.

Der De Martonne-Trockenheitsindex wird vom „Climate Impact on Agriculture“-Projekt der UN-Ernährungs- und Landwirtschaftsorganisation verwendet (GRIESER *et al.* 2006) ebenso vom Deutschen Wetterdienst (DWD 2019, 2020) und anderen Autoren (z.B. PELLICONE *et al.* 2019 für Kalabrien, DENIZ *et al.* 2011 für die Türkei oder BALTAS 2007 für Nordgriechenland). Er zeichnet sich dadurch aus, dass er ein Dürre- bzw. Feuchtigkeitsindikator ist, der allein auf Niederschlag und Temperatur basiert und somit aus gut verfügbaren Klimavariablen berechnet werden kann. Grundsätzlich steht ein niedrigerer Wert für trockenere und ein höherer Wert für feuchtere Verhältnisse (es wird eine künstliche obere Grenze von 100 verwendet, vgl. GRIESER *et al.* 2006). In der Interpretation des Indizes wird mit Klassen gearbeitet, wobei die verschiedenen Quellen keine einheitliche Klassifizierung verwenden. In Anlehnung an die Originalquellen (DE MARTONNE 1926a,b, 1942) soll hier folgende Klasseneinteilung als Orientierung dienen (Tabelle 2.2). Die Klassenbeschreibung bezieht sich auf langfristige Mittelwerte (Klimaklassifikation), kann aber auch hilfreich für die Interpretation von Einzelwerten sein (z.B. wenn ein sehr trockener Monat vorliegt). Somit wird für Werte < 20 von Trockenklimaten gesprochen, die eine landwirtschaftliche Bewässerung notwendig machen. Bei Werten < 25 ist Grasvegetation (kein Wald) zu erwarten. Ab DMI-Werten von 30 liegen humide Klimate vor.

Tabelle 2.2: Trockenheitsklassen des De Martonne-Index nach DE MARTONNE 1926a,b, 1942.

| Wert | Klasse |
|---------------------------|-------------------------------------------------------------------------------------------------------|
| $\text{DMI} < 5$ | trocken, abflusslos (Wüste) |
| $5 \leq \text{DMI} < 10$ | kein regelmäßiger Abfluss, kein Abfluss ins Meer, immer Bewässerung nötig (Wüste oder Halbwüste) |
| $10 \leq \text{DMI} < 20$ | temporärer Abfluss (Savanne, Steppe) |
| $20 \leq \text{DMI} < 30$ | intermediär, Bewässerung oft sinnvoll (Savanne) |
| $\text{DMI} \geq 30$ | humid, kaum Beispiele für defizitäre Bewässerung keine Bewässerung nötig, oft sogar Drainage nötig |
| $\text{DMI} \geq 40$ | reichlich Abfluss |

3 Daten

Die in Abschnitt 2.3 vorgestellten Kennwerte werden aus Beobachtungs- und Klimamodelldaten berechnet, um die Güte letzterer in Bezug auf die zu betrachtenden Größen abzuschätzen und sie entsprechend zu korrigieren. Zusätzlich werden die Zielgrößen durch verschiedene Regressionsverfahren aus Modelldaten simuliert. Die beste Methode wird anschließend auf Zukunftsprojektionen angewendet, um diese zu untersuchen. Des Weiteren kommen beobachtete Ertragszahlen aus Acker- und Weinbau zum Einsatz. Diese dienen als Referenz für die Simulation und Zukunftsbetrachtung der jeweiligen Erträge.

Die verwendeten Beobachtungs- (Abschnitt 3.1) und Modelldaten (3.2) sowie ihre Vorverarbeitung (3.3) werden anschließend beschrieben.

3.1 Beobachtungsdaten

3.1.1 Klimavariablen

Die zu untersuchenden klimatischen Zielgrößen (siehe Abschnitt 2.3) basieren auf den atmosphärischen Variablen Niederschlag, Tages- bzw. Monatsmitteltemperatur (bodennah, also in 2 m Höhe), Tagesmaximumtemperatur sowie Tagesminimumtemperatur. Als Referenz werden gerasterte Beobachtungsdaten verwendet.

Die auf Tagesdaten basierenden Indizes werden aus den Variablen Tagesmitteltemperatur (nur für die Berechnung der Vegetationsperiode), Tagesminimum-, Tagesmaximumtemperatur sowie Niederschlag des E-OBS-Datensatzes (V19.0e, HAYLOCK *et al.* 2008; CORNES *et al.* 2018) in 0,1° Auflösung berechnet. Hierbei handelt es sich um eine gerasterte Weiterverarbeitung der durch das Projekt „European Climate Assessment & Dataset“ (ECA&D) (KLEIN TANK *et al.* 2002; KLOK & KLEIN TANK 2009) gesammelten und verschnittenen Stationsdaten aus Europa und dem Nahen Osten. Die Werte der einzelnen Rasterzellen sind hierbei der Mittelwert eines

Ensembles aus 100 Simulationen des räumlichen Trends auf Basis Generalisierter Additiver Modelle⁹ (CORNES *et al.* 2018).

Für den De Martonne-Trockenheitsindex werden monatlich aufgelöste Temperatur- und Niederschlagsdaten benötigt. Diese werden – im Gegensatz zu den täglichen Daten – als Rasterdatensatz vom Deutschen Wetterdienst (DWD 2021a,b; KASPAR *et al.* 2013) angeboten. Diesen Daten wird hier der Vorzug gegeben, da die nationalen Datensätze in der Regel auf einer höheren Stationsanzahl basieren als der ECA&D-Datensatz (CORNES *et al.* 2018). Die Stationsdaten des Deutschen Wetterdienstes (DWD) werden hierfür mittels Inverse Distance Weighting¹⁰ auf ein $1\text{ km} \times 1\text{ km}$ -Raster projiziert. Diese Projektion geschieht jedoch nicht auf Basis der Rohdaten: Für die Temperaturdaten erfolgt zunächst eine Höhenangleichung auf Meeresniveau (monatlich, auf Basis linearer Regression mit der jeweiligen Stationshöhe), für den Niederschlag werden die monatlichen Anomalien (Basisperiode 1961–1990) verwendet. Nach der Interpolation erfolgt jeweils eine Rückkorrektur. Details zu den Verfahren sind auch in MÜLLER-WESTERMEIER (1995) sowie MAIER & MÜLLER-WESTERMEIER (2010) beschrieben. Das digitale Höhenmodell gibt die Zielaufösung vor, es findet keine dezidierte Abbildung lokalklimatischer bzw. -meteorologischer Effekte statt. Für die in dieser Arbeit genutzten Zeiträume bilden mehr als 500 Wetterstationen die Basis der Interpolationen.

3.1.2 Erträge aus Landwirtschaft und Weinbau

Der unterfränkische Ackerbau (Landwirtschaft, LW) wird in Form von Ertragszahlen [dt/ha] verschiedener Feldfrüchte aus den amtlichen Statistiken (LFSTAT 2020a,b) betrachtet. Hierbei werden nur solche Feldfrüchte untersucht, deren Ertragszahlen für den gesamten erfassten Zeitraum für alle unterfränkischen Landkreise und kreisfreien Städte verfügbar sind: Hafer, Wintergerste, Sommergerste, Silomais, Winterraps sowie Winterweizen. Die abrufbaren Daten

⁹Additive Modelle verwenden im Vergleich zu linearen Modellen einen additiven Prädiktor anstelle eines Linearprädiktors. Es wird somit keine lineare Prädiktor-Prädiktand-Beziehung vorausgesetzt. Generalisierte Additive Modelle (GAM) stellen eine Verallgemeinerung Additiver Modelle dar, so dass diese auch bei nicht-normalverteilten Fehlern anwendbar sind. Dies geschieht analog zu den in Abschnitt 4.4.2 vorgestellten Generalisierten Linearen Modellen als Verallgemeinerung Linearer Modelle (HASTIE & TIBSHIRANI 1990; vgl. KNAFL & DING 2016).

¹⁰Reziproker quadrierter Abstand als Gewicht

beginnen im Jahr 1983. Abbildung 3.1 zeigt die Landkreise (Lkr.) und kreisfreien Städte (Kfs.) Unterfrankens in der Auflösung der verwendeten und in Abschnitt 3.2 beschriebenen Klimamodell­daten. Nachfolgend impliziert der Begriff *Landkreise* immer auch die *kreisfreien Städte*.

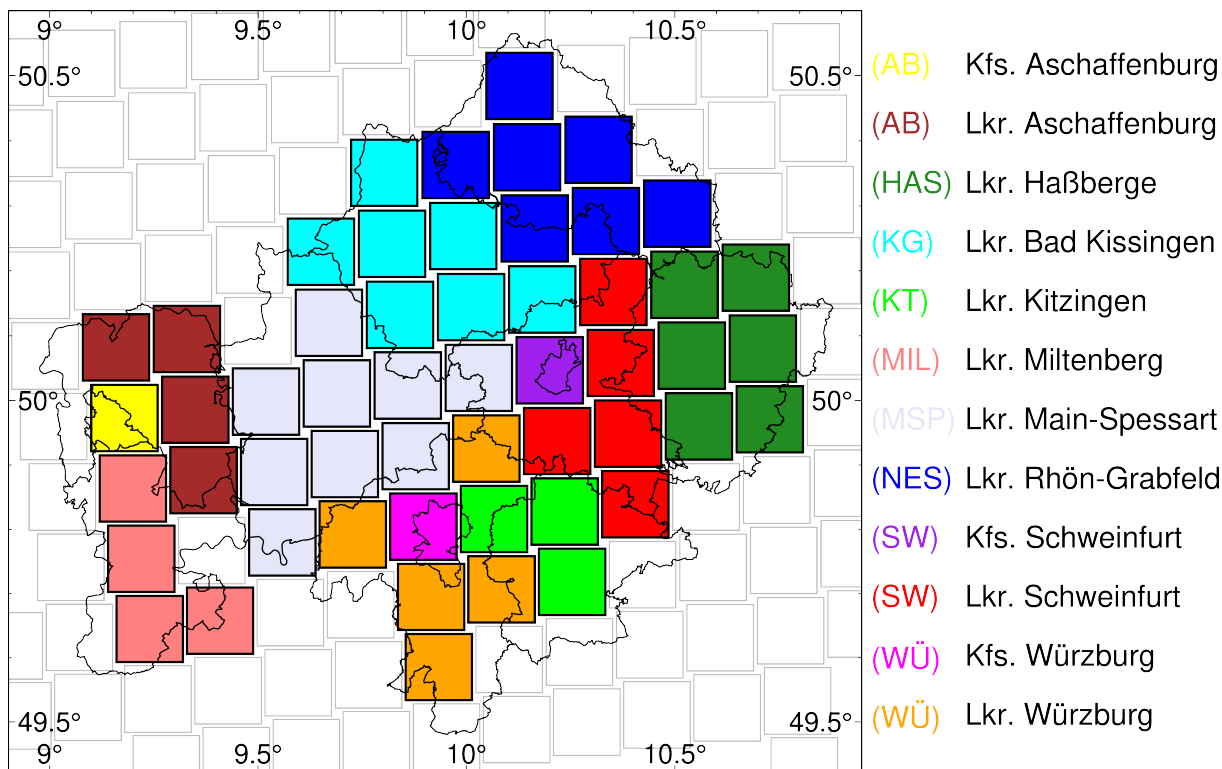


Abbildung 3.1: Landkreise (lkr.) und kreisfreie Städte (Kfs.) Unterfrankens auf dem Gitter der verwendeten Klimamodell­daten (EUR11) (Landkreisdaten GEOBASIS-DE 2017).

Zudem werden auch die Erträge des Frankenweins (FW) in die Analysen einbezogen. Dies geschieht in Form der Weinmosterträge [hl/ha] der amtlichen Statistiken (DESTATIS 2020) untergliedert in Rotwein, Weißwein sowie Gesamtwein. Diese sind ab 1994 verfügbar und beziehen sich jeweils auf das gesamte Frankenweingebiet. Die Gemeinden, deren Wein als Frankenwein gilt, sind in Abbildung 3.2 dargestellt. Die jeweiligen Koordinaten (GEOBASIS-DE 2017) werden für die Simulation der Erträge verwendet (siehe Abschnitt 4.4.3.3).

3.2 Modelldaten

Die genutzten regionalen Klimamodell­daten entstammen dem bereits im Abschnitt 1.2.2 erwähnten EURO-CORDEX-Projekt (JACOB *et al.* 2014). Das Coordinated Regional Downscaling Experiment (GIORGI *et al.* 2009) dient zur Abstimmung, vergleichenden Analyse und Ver-

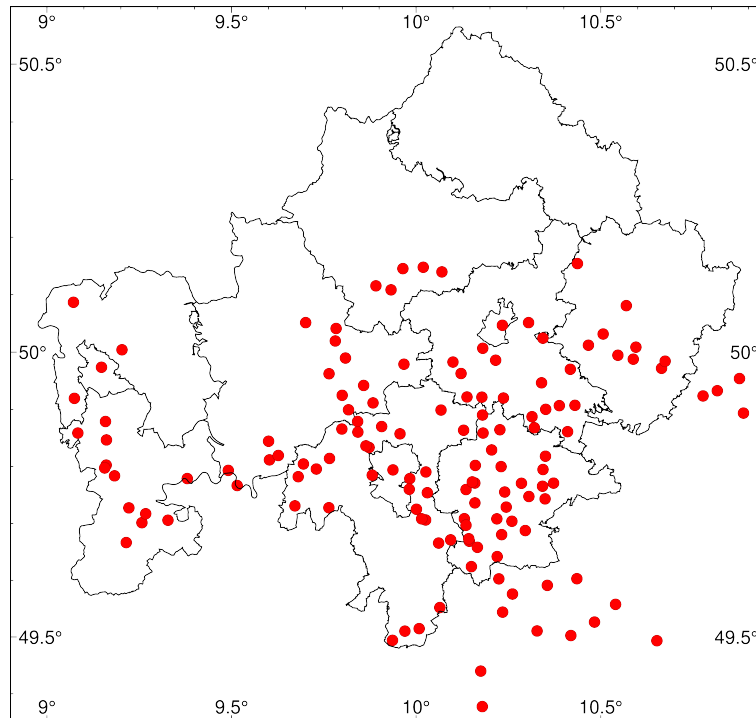


Abbildung 3.2: Gemeinden des Frankenweins (Daten GEOBASIS-DE 2017; STMELF 2011).

besserung hochaufgelöster regionaler Klimasimulationen. Es finden EUR-11-Daten mit einer Auflösung von $0,11^\circ$ (entspricht ca. 12,5 km) Anwendung.

Als Basis für die Güteabschätzungen, Korrekturen und Simulationen dient das regionale Klimamodell REMO (JACOB & PODZUN 1997). Dieses wird am Climate Service Center Germany (GERICS) des Helmholtz-Zentrums Hereon betrieben und wurde auf Basis des Wettervorhersagemodells EUROPA-Modell des Deutschen Wetterdienstes (MAJEWSKI 1991) entwickelt.

Für die Herleitung der MOS-Transferfunktionen werden REMO-Daten der Version 2015 (REMO2015) mit Reanalyseantrieb verwendet (REMO-Eval, verfügbar für den Zeitraum Februar 1979–Dezember 2012), ansonsten (REMO-ESM) liefert das globale Klimamodell MPI-ESM-LR (GIORGETTA *et al.* 2013; STEVENS *et al.* 2013; JUNGCLAUS *et al.* 2013). die Randbedingungen. Die Reanalysedaten entstammen der ERA-Interim-Reanalyse (DEE *et al.* 2011) des Europäischen Zentrums für mittelfristige Wettervorhersagen (ECMWF). Für diese werden Beobachtungsdaten (v.a. Satellitendaten, aber auch Direktmessungen versch. Quellen wie Radiosonden, Flugzeuge, Bojen oder Klimastationsdaten) in einem gekoppelten Atmosphären-Landoberflächen-Ozeanwellen-Vorhersagemodell (ECMWF IFS) verarbeitet, um ein konsistentes globales Bild des atmosphärischen Zustandes mit geringer zeitlicher Verzögerung zur Verfügung zu stellen (DEE *et al.* 2011).

MPI-ESM-LR (GIORGETTA *et al.* 2013; STEVENS *et al.* 2013; JUNGCLAUS *et al.* 2013) wurde bereits in Kapitel 1.2 genannt. Seine horizontale Auflösung beläuft sich auf etwa 1,875°. Direkte MPI-ESM-LR-Daten kommen in einem Exkurs zur Spätfrostsimulation zur Anwendung (Abschnitt 7.3.2.4).

Die besten Korrektur- und Simulationsverfahren aus den Analysen auf REMO-Basis werden anschließend auf weitere RCMs (mit jeweils unterschiedlichem GCM-Antrieb) angewandt. Hierdurch wird eine größere Bandbreite an struktureller Unsicherheit, interner Variabilität und Anfangsbedingungen abgebildet (z.B. COLLINS *et al.* 2013). Hinzu kommen Unterschiede im jeweiligen dynamischen Downscalingverfahren (vgl. Abschnitt 1.2.2). Die Betrachtung eines Multimodellensembles (MME) führt prinzipiell zu verlässlicheren Ergebnissen, da Modelle mit verschiedenen internen Eigenschaften einfließen (z.B. RANDALL *et al.* 2007; KNUTTI *et al.* 2010). Die für das Multimodellensemble hinzugezogenen zusätzlichen RCMs wurden gemäß der Verfügbarkeit der verwendeten Prädiktorvariablen aus den GCM-RCM-Kombinationen des EURO-CORDEX-Projektes (EUR-11-Auflösung) gewählt. Sie sind Tabelle 3.1 zu entnehmen¹¹.

Da die HIRHAM-Tagesdaten keine Schaltjahre beachten, die genaue Tagesanzahl je Monat jedoch wichtig für die Indexberechnung ist, wird dieses RCM nicht im Rahmen der Biaskorrektur verwendet, sondern nur für die MOS-Analysen.

Alle Antriebs-GCMs sind Teil der fünften Phase des vom WCRP (World Climate Research Programme) koordinierten Coupled Model Intercomparison Projects (CMIP5, TAYLOR *et al.* 2009, 2012b), welche die Datenbasis für den fünften Sachstandsbericht (AR5) des Weltklimarates (IPCC) bildet (MASSON-DELMOTTE *et al.* 2021). Sie und die angetriebenen RCMs verwenden ein historisches Szenario für das 20. Jahrhundert (je nach RCM 1950 bzw. 1951–2005)

¹¹Hierbei wurde verfügbarkeitsbedingt mit Ausnahme von MPI-ESM-LR-REMO2015 (r3i1p1) jeweils der Modelllauf r1i1p1 genutzt (auch für REMO-Eval). Der Name des Laufs im Modell-Ensemble zeigt unterschiedliche Realisationen (r), Startbedingungen (Initialisierungsparameter i) und physikalische Parametrisierungen (p) eines Modells. Die verschiedenen Realisierungen (r) basieren hierbei auf zufälligen Veränderungen der Startbedingungen (z.B. HORANYI 2021; MEREDITH *et al.* 2021; TAYLOR *et al.* 2012a). Da sich die Startbedingungen und Parameterisierungen ohnehin zwischen den verschiedenen Modellen (und erstere auch zwischen Reanalyse- und GCM-angetriebenem Modell) unterscheiden, ist die Nutzung eines anderen Modelllaufs für REMO-ESM gerechtfertigt. r3i1p1 ist der einzige verfügbare Ensemblelauf für REMO-ESM (mit MPI-ESM-LR-Antrieb s.o.), für REMO-Eval hingegen ist ausschließlich r1i1p1 verfügbar.

Tabelle 3.1: Verwendete regionale Klimamodelle, RCMs und Antriebs-GCMs. REMO bildet die Ausgangsbasis der Analysen. ALADIN, HIRHAM und RACMO werden später hinzugezogen. REMO2009 wird nur zum Zwecke eines Vergleichs in der Synthese verwendet.

| Kurz-name | RCM GCM | Institution | Quelle |
|------------------|----------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------|
| REMO | REMO2015 MPI-ESM-LR | Climate Service Center Germany (GERICS) des Helmholtz-Zentrums Hereon Max Planck-Institut für Meteorologie (MPI-M) | JACOB & PODZUN (1997) GIORGETTA <i>et al.</i> (2013) |
| ALADIN | ALADIN63 CNRM-CM5 | Centre National de Recherches Météorologiques (CNRM) Frankreich CNRM, Centre Européen de Recherche et de Formation Avancée en Calcul Scientifique (CERFACS) | DANIEL <i>et al.</i> (2019) VOLDOIRE <i>et al.</i> (2012) |
| HIRHAM | HIRHAM5 NorESM1-M | Danish Meteorological Institute (DMI) Norwegian Climate Consortium (NCC) | CHRISTENSEN <i>et al.</i> (2007) BENTSEN <i>et al.</i> (2013) |
| RACMO | RACMO22E EC-EARTH | Royal Netherlands Meteorological Institute (KNMI) Irish Centre for High-end Computing (ICHEC) | VAN MEIJGAARD <i>et al.</i> (2008) HAZELEGER <i>et al.</i> (2012) |
| REMO 2009 | REMO2009 MPI-ESM-LR | Climate Service Center Helmholtz-Zentrum Geesthacht (CSC), MPI-M MPI-M | JACOB & PODZUN (1997) GIORGETTA <i>et al.</i> (2013) |

sowie die sogenannten RCPs (Representative Concentration Pathways) als Zukunftsszenarien (VAN VUUREN *et al.* 2011). Die vier RCPs implizieren einem Strahlungsantrieb von 2,6 bis 8,5 W m⁻² im Jahr 2100 basierend auf spezifischer Landnutzung sowie Emissionen und damit verbundenen Konzentrationen von Treibhausgasen und Luftschadstoffen. Darin enthalten sind Annahmen zur sozio-ökonomischen Entwicklung (Bevölkerung, Bruttoinlandsprodukt, Technologie, Energienutzung etc.). Sie besitzen jeweils charakteristische Verläufe der Strahlungsantriebe im 21. Jahrhundert gemäß den zugrundeliegenden Landnutzungs- sowie Konzentrationspfaden (VAN VUUREN *et al.* 2011). In dieser Arbeit werden ausschließlich Projektionen des höchsten, bisher jedoch realistischsten (SCHWALM *et al.* 2020) Szenarios RCP8.5 (siehe auch RIAHI *et al.* 2011) betrachtet.

3.3 Vorverarbeitung

Vor den Analysen sind einige Gitternetzadaptierungen nötig. Um einen direkten Vergleich zu ermöglichen, werden die Beobachtungsdatensätze der klimatischen Variablen für die Modellevaluierung und die Biaskorrektur auf das EUR-11-Gitter interpoliert. Für die MOS-Berechnungen wird die Originalauflösung und -projektion der E-OBS-Daten beibehalten, die DWD-Daten (monatlich, für DMI-Berechnung) werden zur Beschleunigung der Rechenzeit auf das E-OBS-Gitter angeglichen. Da das ALADIN-Gitternetz von dem der anderen RCMs abweicht, wird es entsprechend angepasst.

Für diese Umprojektionen wird das Verfahren der bilinearen Interpolation genutzt. Bei dieser häufig verwendeten (z.B. VOGEL *et al.* 2019; WU *et al.* 2022; LLOPART *et al.* 2020) Resamplingmethode wird ein distanz-gewichtetes Mittel der vier nächsten Gitterzellen genutzt (Glättung), um die gesuchten Werte entsprechend einer subsequenten linearen Interpolationen in horizontale und vertikale Richtung zu berechnen (z.B. JONES 1998; BURGER & BURGE 2016; DISTANTE & DISTANTE 2020).

4 Methoden

In den folgenden Abschnitten werden zunächst statistische Grundlagen und Definitionen (4.1) sowie Methoden zur Güteabschätzung und Modellvalidierung (4.2) erläutert. Anschließend wird auf Verfahren zur statistischen Aufbereitung und Anpassung der Modelldaten an die entsprechenden Beobachtungsdaten eingegangen: Biaskorrektur (kurz BK, Abschnitt 4.3) und Model Output Statistics (kurz MOS, Abschnitt 4.4).

4.1 Statistische Grundlagen und Definitionen

Die nachfolgenden statistischen Grundlagen und Definitionen entstammen soweit nicht explizit gekennzeichnet den Werken von WILKS (2011), VON STORCH & ZWIERS (2003), BORTZ & SCHUSTER (2010) und SCHÖNWIESE (2006).

4.1.1 Univariate Deskriptive Statistik

Für die Stichprobe x mit Elementen x_i ($i = 1, \dots, n$) gilt:

(Arithmetischer) **Mittelwert** \bar{x} (auch abgekürzt als MW) als Lageparameter:

$$\bar{x} = \frac{1}{n} \sum_i x_i \quad (4.1)$$

Varianz s^2 (auch abgekürzt als Var) und **Standardabweichung** s (auch abgekürzt als SD) als Streuungsparameter:

$$s^2 = \frac{1}{n-1} \sum_i (x_i - \bar{x})^2 \quad (4.2)$$

$$s = \sqrt{\frac{1}{n-1} \sum_i (x_i - \bar{x})^2} \quad (4.3)$$

Die **Schiefe** γ kann durch folgende Formel beschrieben werden:

$$\gamma = \frac{\frac{1}{n-1} \sum_i (x_i - \bar{x})^3}{s^3} \quad (4.4)$$

Hierbei stehen positive Werte für linkssteile bzw. rechtsschiefe Verteilungen, also solche bei denen der Mittelwert größer ist als der häufigste Wert. Umgekehrtes gilt für $\gamma < 0$. Für $\gamma = 0$ liegt eine symmetrische Verteilung vor. Es ist zu beachten, dass durch die dritte Potenz der Abweichungen vom Mittelwert Ausreißer stark ins Gewicht fallen (WILKS 2011).

Quantile oder Perzentile beschreiben die Lage eines Wertes innerhalb der aufsteigend sortierten Stichprobe. Der mittlere Wert heißt hierbei Median Med , das bedeutet, dass gleich viele Werte unterhalb wie oberhalb dieses Wertes liegen¹². Allgemeiner ausgedrückt ist die Wahrscheinlichkeit für einen Wert kleiner oder gleich dem p -ten Quantil Q_p p und die Wahrscheinlichkeit für einen Wert oberhalb von $1 - p$, also:

$$P(x \leq Q_p) = p \quad \text{bzw.} \quad P(x > Q_p) = 1 - p \quad (4.5)$$

Für Perzentile P_p wird die Wahrscheinlichkeit in der Regel in Prozent, für Quantile als Relativzahl angegeben, also $Med = P_{50} = Q_{0.5}$. Liegt das gesuchte Quantil zwischen zwei realisierten Werten, wird eine lineare Interpolation durchgeführt¹³.

Die **z-Transformation** (auch Normalisierung oder Standardisierung) ist definiert als:

$$z = \frac{x - \bar{x}}{s} \quad (4.6)$$

Für die transformierten Daten gilt dann $\bar{x} = 0$ und $s = 1$. Somit werden Daten unterschiedlicher Variablen besser vergleichbar, da Unterschiede in Lage und Streuung relativiert werden. Für standardisierte Daten ist die ursprüngliche Einheit nicht mehr gültig.

Die **Analyse des zeitlichen Trends** entspricht einer linearen Regression mit der Zeit als einziger erklärender Variable für die entsprechenden Daten. Als Enttrending wird die Entfernung (Subtraktion) dieses Trends bezeichnet. Nähere Ausführungen zur linearen Regression sind in Kapitel 4.4.1 zu finden. Die Signifikanz des Trends (bzw. dessen Steigung, $\alpha = 0,05$) wird mithilfe eines t-Tests mit $n-2$ Freiheitsgraden überprüft. Die Prüfgröße lautet:

$$t = \frac{|b| \cdot \sqrt{\sum (x_i - \bar{x})^2}}{\sqrt{\frac{\sum (y_i - y'_i)^2}{n-2}}} \quad (4.7)$$

¹²Bei ungeraden Stichprobengrößen, ansonsten wird der Mittelwert der beiden die Zentralposition umgebenden Werte verwendet.

¹³Für Quantile unterhalb des Minimums bzw. oberhalb des Maximums werden das Minimum bzw. das Maximum verwendet.

mit Trendsteigung b , Zeit x und Werten y bzw. Schätzwerten y' . Der Divisor ist gleichbedeutend mit $\sqrt{s_y^2 \cdot (1 - r_{xy}^2) \cdot \frac{n-1}{n-2}}$, wobei r_{xy} dem im nächsten Abschnitt erläuterten Produkt-Moment-Korrelationskoeffizient nach Pearson r_p entspricht.

4.1.2 Bivariate Deskriptive Statistik

Bei der bivariaten deskriptiven Statistik erfolgt ein Vergleich zweier Variablenstichproben x mit Elementen x_i und y mit Elementen y_i sowie $i = 1, \dots, n$.

Hierbei dient die **Kovarianz** s_{xy} als Maß gemeinsamer Streuung:

$$s_{xy} = \frac{1}{n-1} \sum (x_i - \bar{x})(y_i - \bar{y}) \quad (4.8)$$

Der **Produkt-Moment-Korrelationskoeffizient** nach Pearson r_p beschreibt die Güte des linearen Zusammenhangs der beiden Variablen und ist gleichbedeutend mit der Kovarianz der standardisierten Variablen:

$$r_p = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}}, -1 \leq r_p \leq 1 \quad (4.9)$$

Für diesen Koeffizienten wird eine Normalverteilung der Daten vorausgesetzt. Bei negativem Vorzeichen liegt ein gegen-, bei positivem ein gleichgerichteter Zusammenhang vor. $|r_p| = 1$ bedeutet, dass die gegeneinander aufgetragenen Werte der Variablen exakt auf einer Geraden liegen.

Ist nicht von einem linearen Zusammenhang der Stichproben auszugehen oder muss von Abweichungen von der Normalverteilung ausgegangen werden, wird der verteilungsfreie **Rangkorrelationskoeffizient** nach Spearman r_s verwendet (der eine Anwendung der Pearson-Korrelation auf die Rangplätze darstellt):

$$r_s = 1 - \frac{6 \sum D_i^2}{n^3 - n}, -1 \leq r_s \leq 1, \quad (4.10)$$

wobei D_i die Differenzen der Rangplätze von x_i und y_i sind und die Rangplätze anhand der aufsteigend sortierten Stichproben vergeben werden. Im Falle von Bindungen (gleiche Platzierungen) werden Durchschnittswerte zugewiesen. Bei vielen (> 20 %) Bindungen findet gemäß BORTZ & SCHUSTER (2010) eine korrigierte Formel Anwendung:

$$r_s = \frac{2 \left(\frac{n^3-n}{12} \right) - T_a - T_b - \sum D_i^2}{2 \sqrt{\left(\frac{n^3-n}{12} - T_x \right) \left(\frac{n^3-n}{12} - T_y \right)}} \quad (4.11)$$

mit $T_x = \frac{1}{12} \sum_{j=1}^J [h_j^3(x) - h_j(x)]$ und entsprechendem T_y , mit h_j Anzahl jeweils gleicher Rangplätze und J Häufigkeit gleicher Rangplätze

Zur Testung der Nullhypothese $H_0 : r = 0$ (es liegt keine signifikante Korrelation vor) wird ein **t-Test** mit $n - 2$ Freiheitsgraden zum Signifikanzniveau von 95% ($\alpha = 0,05$) durchgeführt:

$$t = |r| \sqrt{\frac{n-2}{1-r^2}} \quad (4.12)$$

Der quadrierte Korrelationskoeffizient r^2 ($r^2 \leq 1$, folgend auch als R^2 bezeichnet) wird Bestimmtheitsmaß oder Determinationskoeffizient genannt. Er gibt an, welcher Anteil der Varianz von x durch y (oder anders herum) beschrieben wird. Da der Korrelationskoeffizient r_p der Kovarianz der standardisierten Variablen entspricht (und r_s seiner Anwendung auf die Rangplätze entspricht), wird durch ihn – und somit auch durch R^2 – keine Aussage über die Schwankungsbreite getroffen.

Der mittlere quadratische Fehler (engl. Mean Squared Error (MSE)), auch mittlere quadratische Abweichung, sowie deren Wurzel (Root Mean Squared Error (RMSE)) werden vor allem dann verwendet, wenn eine der beiden betrachteten Variablen (etwa y) eine Simulation der anderen (etwa x) darstellt (vgl. Abschnitt 4.4). Er beschreibt dann die durchschnittliche Güte der Simulation, wobei durch die Quadrierung der Fehler Ausreißer mehr ins Gewicht fallen. Der RMSE liegt in der Größenordnung und damit der Einheit der Variablen vor.

$$MSE = \frac{1}{n} \sum (x - y)^2, 0 \leq MSE < \infty \quad (4.13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (x - y)^2}, 0 \leq RMSE < \infty \quad (4.14)$$

Aus dem MSE kann der Mean Squared Skill Score ($MSSS$) konstruiert werden (vgl. WILKS 2011), um die Abweichungen von x und y (MSE) relativ zu den internen Schwankungen von y (MSE_{ref}) zu betrachten:

$$\begin{aligned} MSSS &= \frac{MSE - MSE_{ref}}{MSE_{perf} - MSE_{ref}} = \frac{MSE - MSE_{ref}}{0 - MSE_{ref}} = 1 - \frac{MSE}{MSE_{ref}} \\ &= 1 - \frac{\sum_i (x_i - y_i)^2}{\sum_i (y_i - \bar{y})^2} \end{aligned} \quad (4.15)$$

Der perfekte MSE (MSE_{perf} , keine Abweichungen zwischen x und y) entspricht 0. Je höher der $MSSS$ (max. 1), desto geringer sind x - y -Abweichungen (bzw. die Summe ihrer Quadrate)

im Vergleich zur internen Variabilität von y . Ein $MSSS < 0$ bedeutet, dass die Streuung zwischen x und y größer ist, als innerhalb von y . Dieses Gütemaß entspricht einer alternativen r^2 -Definition im Rahmen der Regressionsrechnung. Zur klaren Unterscheidung wird im weiteren Verlauf jedoch r^2 bzw. R^2 für den quadrierten r_p bzw. r_s verwendet. Der $MSSS$ unterscheidet sich von den anderen vorgestellten bivariaten Kenngrößen insofern, als dass vorher ein Referenz- (hier y) und ein Vergleichswert (x) festgelegt werden muss. Bei den übrigen Maßzahlen sind x und y austauschbar.

4.1.3 Anpassungstest

Um eine Stichprobenhäufigkeitsverteilung mit einer theoretischen Häufigkeitsverteilung zu vergleichen dienen Anpassungs- bzw. Verteilungstests. Auf einige theoretische Häufigkeitsverteilungen wird in den Abschnitten 4.4.2 und 4.3.2.2 näher eingegangen.

Der **Kolmogorov-Smirnov-Test** vergleicht eine empirische Verteilung mit der angepassten Verteilung, indem die maximale Differenz der kumulierten Häufigkeiten betrachtet wird.

$$D = \max_x |F_e(x) - F(x)| \quad , \quad (4.16)$$

wobei die empirische kumulative Verteilung als $F_e(x(i)) = 1/n$ angenommen wird und die theoretische kumulative Wahrscheinlichkeit $F(x)$ den an der zu testenden Verteilung angepassten Daten entspricht. Die Nullhypothese H_0 : Die Daten folgen der angenommenen Verteilung F wird angenommen, wenn D einen bestimmten kritischen Wert nicht übersteigt (HEDDERICH & SACHS 2016; WILKS 2011; VON STORCH & ZWIERS 2003). Dabei werden die kritischen Werte aus HEDDERICH & SACHS (2016) verwendet.

4.2 Güteabschätzung und Modellvalidierung

Wie in Abschnitt 1.2.2 aufgeführt, weisen (regionale) Klimamodelle oft typische Fehler auf. Um die Güte der in dieser Arbeit verwendeten Modelldaten abzuschätzen und die Notwendigkeit einer Datenkorrektur zu überprüfen, werden verschiedene Maßzahlen untersucht. Gleiches gilt für die Ergebnisse der durchgeführten Korrektur und Simulationen.

4.2.1 Bias

„A climate model bias can be defined as the systematic difference between a simulated climatic statistic and the corresponding real-world climatic statistic.“

(MARAUN 2016)

Wenn x die Simulation von y darstellt, ist der Bias von x bzgl. y definiert als dessen mittlere Abweichung von y . Er steht damit für den systematischen Fehler (MARAUN & WIDMANN 2018; VON STORCH & ZWIERS 2003; WILKS 2011). Dies beschreibt den Mittelwert-Bias (Bias MW, B) als Bias im engeren Sinne:

$$B(x|y) = \bar{x} - \bar{y} \quad (4.17)$$

oder als relativen Bias rB (vgl. 4.3.1):

$$rB(x|y) = \frac{\bar{x}}{\bar{y}} \quad (4.18)$$

Weiter gefasst, wie im oben genannten Zitat von MARAUN (2016), können auch weitere deskriptive Maße von y und x verglichen werden, etwa die Standardabweichung (Bias SD, B_s):

$$B_s(x|y) = s_x - s_y \quad (4.19)$$

Beide können auch im Verhältnis zur Referenzgröße als jeweiliger prozentualer Bias (hier auch abgekürzt als pB oder pB) dargestellt werden.

$$pB(x|y) = \frac{B(x|y)}{\bar{y}} \cdot 100\% = \frac{\bar{x} - \bar{y}}{\bar{y}} \cdot 100\% \quad (4.20)$$

$$pB_s(x|y) = \frac{B_s(x|y)}{s_y} \cdot 100\% = \frac{s_x - s_y}{s_y} \cdot 100\% \quad (4.21)$$

Der absolute prozentuale Bias entspricht folglich dem Betrag des jeweiligen pB $|pB|$ bzw. $|pB_s|$.

4.2.2 Verteilungsmaße

Während Mittelwert- und Standardabweichungsbias Vergleichsmaße bzgl. der Lage und der Streuung darstellen, kann auch die Übereinstimmung der einzelnen korrespondierenden Wertepaare verglichen werden. Dies geschieht anhand des bereits in Abschnitt 4.1.2 definierten

RMSE. Liegt keine zeitliche Korrespondenz zwischen Modell- und Beobachtungsdaten vor, wie dies bei GCM-angetriebenen RCM-Daten der Fall ist, wird ein angepasster Kennwert eingeführt, der **Quantil-Root Mean Squared Error** (*QRMSE*)¹⁴. Hierfür werden beide zu vergleichenden Stichproben aufsteigend sortiert und anschließend der *RMSE* gebildet. Es werden so die Verteilungen verglichen.

$$QRMSE(x, y) = RMSE(x_s, y_s) = \sqrt{\frac{1}{n} \sum (x_s - y_s)^2}, 0 \leq RMSE < \infty \quad (4.22)$$

mit x_s und y_s als sortierte Werte von x bzw. y . Zur besseren Vergleichbarkeit wird der *QRMSE* im Verlauf der Arbeit auch als prozentualer *QRMSE* (*pQRMSE*) verwendet, wobei sich die Verhältnisbildung auf das arithmetische Mittel der Referenzwerte bezieht. Der *pQRMSE* ist also der *QRMSE* ausgedrückt als Prozentsatz des jeweiligen Referenzmittelwertes.

Ein weiteres Werkzeug zum Vergleich der Werteverteilungen sind **Q-Q-Plots**, bei denen die sortierten Werte gegeneinander aufgetragen werden. Wird z.B. die x-Achse für die Beobachtungswerte y und die y-Achse für die Modellwerte x gewählt, so zeigen Werte unterhalb der Winkelhalbierenden Unter- und solche oberhalb der Winkelhalbierenden Überschätzungen durch das Modell an.

4.3 Biaskorrektur

Wie bereits im Rahmen der Güteabschätzung (Abschnitt 4.2) angesprochen, können als Bias die Abweichungen verschiedener deskriptiver Maße zwischen zu vergleichenden Größen (Stichproben) angesehen werden. Daher existieren auch Korrekturmethode, die sich auf unterschiedliche Eigenschaften und Momente der unterliegenden Verteilungen beziehen.

Sowohl die Modellvalidierung (4.2) als auch die Biaskorrektur und die Model Output Statistics (Kapitel 4.4) sind dabei stets von den verwendeten Referenz- bzw. Beobachtungsdaten abhängig (z.B. MARAUN & WIDMANN 2018; CHRISTENSEN *et al.* 2008). Deren Qualität ist bereits im

¹⁴Im Vergleich zum Bias (MW und SD), ist hier die vorherige Festlegung von Referenz- und Vergleichsdaten nicht notwendig. Aufgrund der Definition können x und y vertauscht werden und der *QRMSE* wird daher nicht als Fehler von x im Bezug auf y (also $RMSE(x|y)$) sondern als Fehler zwischen x und y (oder y und x) ausgedrückt.

Abschnitt 3.1 kurz thematisiert worden und wird im Rahmen der Diskussion (Kapitel 7) noch näher erörtert.

In den Übersichtsarbeiten von TEUTSCHBEIN & SEIBERT (2012), MARAUN (2016) sowie MARAUN & WIDMANN (2018) werden verschiedene Biaskorrekturmethode vorgestellt. Neben den in dieser Arbeit verwendeten (s.u.) sowie einigen variablenspezifischeren Verfahren ist dies vor allem die Delta Change Methode. Hierbei wird das Veränderungssignal (Delta Δ) des jeweiligen Klimamodells x auf einen Beobachtungswert der Vergangenheit (y_p) addiert: $x_{DC,f} = y_p + \Delta x = y_p + (\bar{x}_f - \bar{x}_p)$ (mit p Vergangenheit und f Zukunft, auch multiplikative Variante möglich). Auch wenn anstatt des Zukunftszeitraums ebenso eine zweite Vergangenheitsperiode verwendet werden könnte, entspricht diese Methode nicht den Zielen dieser Arbeit. Durch die Veränderung langjähriger mittlerer Veränderungssignale ist keine Evaluierung der Ergebnisse hinsichtlich Variabilität und Verteilungsübereinstimmung möglich, die Schwankungen entstammen ausschließlich den Beobachtungsdaten. Da Güteabschätzung und -vergleich verschiedener Methoden jedoch ein zentrales Ziel dieser Arbeit ist, wird Delta Change hier nicht verwendet.

Eine spezielle trenderhaltende Korrekturmethode wurde von HEMPEL *et al.* (2013) sowie LANGE (2017) entwickelt (weitere Ansätze siehe z.B. GRILLAKIS *et al.* (2017) oder WATANABE *et al.* (2012)). Um die monatlichen Trends zu erhalten, wird zu jedem Tageswert eines Monats der gleicher Korrekturwert addiert (Linearskalierung s.u., nicht-negative Variablen multipliziert (dann Erhaltung des relativen Trends)). Anschließend wird die Variabilität der täglichen Daten um das jeweilige Monatsmittel mit parametrischem Quantilmapping (s.u.) angepasst. Diese Methode ist auf die hier verwendeten Kennwerte (außer DMI) jedoch nicht anwendbar, da sie auf täglicher Basis lediglich binär (Ereignis ja oder nein) sind. Zudem kann eine Korrektur des Trends durchaus gewünscht sein, wenn dieser auf gleiche Weise wie die korrigierte statistische Eigenschaft fehlerbehaftet ist. Da die hier angewandte Methodik Instationaritäten der Modellabweichungen durch Kreuzvalidierung Rechnung trägt (siehe 4.4.4.3), wird eine durch die Biaskorrektur implizierte Veränderung der Trends als sinnvoll erachtet (vgl. MARAUN 2016).

Alle nachfolgend vorgestellten (und durchgeführten) Methoden haben gemeinsam, dass jeweils bestimmte Eigenschaften der Modelldaten an Beobachtungsdaten angeglichen werden. Diese Eigenschaften sind stets Statistiken des betrachteten Zeitraums (Kalibrationsperiode) (PAETH & DIEDERICH 2011; MARAUN 2016). Alle Korrekturen erfolgen einzeln pro Index, Gitterzelle und (falls vorhanden) Monat.

4.3.1 Linearskalierung

Die einfachste Biaskorrektur stellt die Linearskalierung dar. Hierbei werden zwei Varianten verwendet:

Additive Linearskalierung Die simple oder additive Linearskalierung (LS)¹⁵ ist eine reine Mittelwertkorrektur: Der Bias (des Kalibrierungszeitraumes) wird von den Einzelausprägungen von x subtrahiert (z.B. MARAUN 2016; MARAUN & WIDMANN 2018; TEUTSCHBEIN & SEIBERT 2012; PIANI *et al.* 2010b; IVANOV & KOTLARSKI 2017):

$$x_{LS} = x - B(x|y) = x - (\bar{x} - \bar{y}) \quad (4.23)$$

Multiplikative Linearskalierung Die Division durch den relativen Bias wird multiplikative Linearskalierung (LSM) genannt. Sie korrigiert Mittelwert und Varianz im gleichen Verhältnis (konstanter Variationskoeffizient) und wird häufig für rein positive Variablen verwendet (z.B. MARAUN 2016; MARAUN & WIDMANN 2018; IVANOV & KOTLARSKI 2017; LAFON *et al.* 2013):

$$x_{LSM} = \frac{x}{rB(x|y)} = \frac{x}{\frac{\bar{x}}{\bar{y}}} \quad (4.24)$$

4.3.2 Verteilungskorrekturen

Beim Quantilmapping oder PDF-Matching (Anpassung der Probability Density Function (PDF) also Wahrscheinlichkeitsdichtefunktion) wird die simulierte Verteilung an die beobachtete Verteilung angepasst. Hierfür gibt es grundsätzlich zwei Möglichkeiten: Eine parametrische Durchführung unter Annahme einer speziellen Verteilung der Daten oder eine empirische bzw. nicht-parametrische Durchführung ohne Verteilungsannahme anhand der Quantile.

4.3.2.1 Nicht-parametrisches Quantilmapping

Das nicht-parametrische Quantilmapping (folgend Quantilmapping (QM)) verwendet die in Abschnitt 4.1.1 beschriebenen empirischen Quantile. Es wird also anhand der Quantile die kumu-

¹⁵Der Begriff *Linearskalierung* ohne weitere Zusätze steht im Folgenden für die additive Linearskalierung

lierte Wahrscheinlichkeitsfunktion der Modelldaten geschätzt und an diejenige der Beobachtungsdaten angeglichen. Jede Ausprägung der Modellvariable x besitzt die kumulierte Wahrscheinlichkeit $p(x)$, sodass $x = Q_{p(x),sim}$. Das Quantil der Beobachtungsdaten, welches dieser Wahrscheinlichkeit entspricht $Q_{p(x),obs}$, wird dann als korrigierter Wert angenommen (BOÉ *et al.* 2007; IVANOV & KOTLARSKI 2017; MARAUN 2016; MARAUN & WIDMANN 2018). Da $Q = p^{-1}$ bzw. $p = Q^{-1}$ und die Quantile für die kumulierte Wahrscheinlichkeit stehen, lässt sich schreiben:

$$x_{QM} = F_{obs}^{-1}(F_{sim}(x)) = p_{obs}^{-1}(p_{sim}(x)) = Q_{obs}(p_{sim}(x)) = Q_{p(x),obs} \quad (4.25)$$

Vor der Durchführung muss die Anzahl der Quantile nq , also die Klassenanzahl des kumulierten Histogramms, festgelegt werden, welche Einfluss auf das Ergebnis hat (z.B. IVANOV & KOTLARSKI 2017; LAFON *et al.* 2013). Im Rahmen dieser Arbeit wurden Durchläufe mit verschiedenen Quantilanzahlen berechnet (jeweils das erste Quantil als Minimum und das nq -te Quantil als Maximum definiert) und die Anzahl mit den besten Ergebnissen¹⁶ weiter verwendet ($nq = 11$, daher Benennung QM11)¹⁷.

Grundsätzlich wird das höchste Quantil $Q_{j,obs}$ für das gilt $Q_{j,sim} \leq x$ als korrigierter Wert angenommen. Entspricht das Quantil nicht dem nq -ten Quantil ($j \neq nq$), wird zudem ein Korrekturwert addiert (Interpolation zwischen Quantilen):

$$x_{QM} = Q_{j,obs} + c = Q_{j,obs} + (x - Q_{j,sim}) \frac{Q_{j+1,obs} - Q_{j,obs}}{Q_{j+1,sim} - Q_{j,sim}} \quad (4.26)$$

Für Werte unterhalb des Minimums der Beobachtungsdaten wird die Differenz der ersten Quantile von Beobachtungs- und Modelldaten verwendet, um damit eine Linearskalierung durchzuführen (siehe 4.3.1). Analog wird für Werte oberhalb des beobachteten Maximums mit der Differenz der nq -ten Quantile verfahren. Sowohl die Interpolation zwischen Quantilen als auch die Extrapolation außerhalb des beobachteten Wertebereichs erfolgt also in linearer Form (vgl. BOÉ *et al.* 2007; IVANOV & KOTLARSKI 2017).

¹⁶Übereinstimmung hinsichtlich Mittelwert, Standardabweichung, Q10, Q90, Median sowie QRMSE untersucht.

¹⁷Die weitere Indizierung j der Quantile bezieht sich nicht auf die entsprechende Wahrscheinlichkeit sondern auf die Durchnummerierung: $j = 1, \dots, nq$

4.3.2.2 Parametrisches Quantilmapping

Wie beim nicht-parametrischen Quantilmapping, gilt auch beim parametrischen Quantilmapping (nachfolgend PDF-Matching, PM):

$$x_{PM} = F_{obs}^{-1}(F_{sim}(x)) \quad (4.27)$$

Allerdings wird hier explizit eine Verteilung der untersuchten Daten angenommen. F bzw. F^{-1} stehen also nicht für empirische Quantile und Wahrscheinlichkeiten, sondern für Ausprägungen definierter kumulierter Verteilungsfunktionen (TEUTSCHBEIN & SEIBERT 2012; PIANI *et al.* 2010a; PAETH & DIEDERICH 2011).

Für Niederschlagsdaten wird dabei in anderen Studien auf eine Gammaverteilung (TEUTSCHBEIN & SEIBERT 2012; PIANI *et al.* 2010a) oder eine Kombination aus Gamma- und Generalisierter Pareto-Verteilung (PAETH & DIEDERICH 2011; IVANOV & KOTLARSKI 2017) zurückgegriffen, während für Temperaturdaten die Normalverteilungsannahme gilt (TEUTSCHBEIN & SEIBERT 2012). Die hier untersuchten Kennwerte sind jedoch komplexer als Durchschnittswerte von Temperatur und Niederschlag, daher werden Berechnungen mit Gamma-, Exponential- und Pearson III-Verteilung durchgeführt und verglichen. Die besten Ergebnisse (Verteilungsannahme bei Kolmogorov-Smirnov-Tests mit $\alpha = 0,05$ für die meisten Situationen) werden durch die Verwendung einer Pearson III-Verteilung erreicht.

Pearson III-Verteilung Die Pearson III-Verteilung stellt eine Verallgemeinerung der Gamma-Verteilung (Gleichung 4.64) unter Verwendung eines dritten Verteilungsparameters dar. Ihr Wahrscheinlichkeitsdichtefunktion lautet (WILKS 2011):

$$f(x) = \frac{\left(\frac{x-\zeta}{\beta}\right)^{\alpha-1} \exp\left(-\frac{x-\zeta}{\beta}\right)}{|\beta|\Gamma(\alpha)}, \quad x > \zeta \text{ für } \beta > 0 \text{ oder } x < \zeta \text{ für } \beta < 0 \quad (4.28)$$

mit der Gammafunktion Γ (siehe Gleichung 4.65). Neben dem Formparameter α und dem Skalenparameter β enthält diese im Gegensatz zur Gammaverteilung noch den Lageparameter ζ , mit welchem die Verteilung verschoben wird (nach rechts für positive ζ , definiert für $x > \zeta$). Hierdurch wird ihre Flexibilität erhöht. Sie wird häufig für hydrologische Häufigkeitsuntersuchungen, v.a. von Extremwerten, verwendet (WILKS 2011; UL REHMAN KHAN *et al.* 2021; HOSKING & WALLIS 1997).

Die Parameterschätzung erfolgt nach dem Ansatz von HOSKING & WALLIS (1997) und HOSKING (1996). Hierfür werden die drei aus der Stichprobe berechneten Verteilungsmomente μ ,

σ und γ genutzt. Diese sind analog zu den konventionellen Momenten Mittelwert $\mu = \bar{x}$, Standardabweichung $\sigma = s$ und Schiefe γ (vgl. 4.1.1) interpretierbar, werden allerdings aus den so genannten L-Momenten berechnet.

L-Momente Bei der Parameterschätzung der Pearson III-Verteilung werden in der Studie von UL REHMAN KHAN *et al.* (2021) erst für sehr große Stichprobenumfänge gute Ergebnisse mittels Maximum Likelihood-Schätzung (vgl. Abschnitt 4.4.2.4) erzielt. Anderenfalls wird die Verwendung von alternativen Methoden wie etwa den so genannten L-Momenten empfohlen. Als drei-parametrische Verteilung, bei der höhere Momente wie etwa die Schiefe relevant für die Verteilungsdefinition sind, können hiermit bessere Schätzungen erreicht werden (VON STORCH & ZWIERS 2003).

L-Momente stellen „Linearfunktionen der erwarteten Ordnungsstatistiken“ (HOSKING 1990) dar. Für die Stichprobe $x = x_1, x_2, \dots, x_n$ wird die sortierte Stichprobe durch $x_{1:n} \leq x_{2:n} \leq \dots \leq x_{n:n}$ dargestellt. Die erwartungstreuen Schätzer l_r der L-Momente λ_r werden berechnet durch (HOSKING 1996):

$$l_r = n^{-1} \sum_{j=1}^n w_{j:n}^{(r)} x_{j:n} \quad (4.29)$$

mit den Gewichten $w_{j:n}^{(r)}$, wobei gilt:

$$w_{j:n}^{(1)} = 1 \quad (4.30)$$

$$w_{j:n}^{(2)} = \frac{2(j-1)}{n-1} - 1 \quad (4.31)$$

$$(r-1)(n-r+1)w_{j:n}^{(r \text{ für } r \geq 3)} = (2r-3)(2j-n-1)w_{j:n}^{(r-1)} - (r-2)(n+r-2)w_{j:n}^{(r-2)} \quad (4.32)$$

und

$$w_{j:n}^{(r)} = (-1)^{r-1} w_{n+1-j:n}^{(r)} \quad (4.33)$$

Während die Lage und der Umfang (Streuung) durch die ersten beiden L-Momente beschrieben werden, geschieht die Beschreibung der Schiefe (drittes Moment) und des Exzesses (viertes Moment) im Rahmen der L-Momente durch so genannte L-Moment-Ratios τ . Diese sind definiert als das Verhältnis des jeweiligen L-Moments zum zweiten L-Moment. Ausdrückt durch die Schätzer t (HOSKING 1990; HOSKING & WALLIS 1997):

$$t_r = \frac{l_r}{l_2} \quad (4.34)$$

Für nähere Informationen zu L-Momenten und deren Schätzung inkl. Herkunft der Gewichtgleichungen wird auf HOSKING (1990), HOSKING (1996) sowie HOSKING & WALLIS (1997) verwiesen.

Ähnlich den sonst gebräuchlichen Momenten (Mittelwert, Standardabweichung, ...) sind auch L-Momente Maßzahlen für Verteilungseigenschaften und können zur Parameterschätzung der Wahrscheinlichkeitsverteilung herangezogen werden. Aufgrund ihrer Definition hat hier die Stichprobenvariabilität jedoch weniger Einfluss, weswegen eine bessere Beschreibung der jeweiligen Verteilung (auch bei kleineren Stichprobengrößen) möglich ist (HOSKING 1990; HOSKING & WALLIS 1997; HOSKING 1996). Für die Schätzung der drei-parametrischen Pearson III-Verteilung werden die ersten drei L-Momente (drittes Moment als Ratio) benötigt.

Parameterschätzung durch L-Momente nach HOSKING & WALLIS (1997) und HOSKING (1996) Die Schätzung von μ , σ und γ erfolgt anhand folgender Formeln:

$$\mu = l_1 = \bar{x} \quad (4.35)$$

$$\sigma = l_2 \sqrt{\pi} \sqrt{\alpha} \frac{\Gamma(\alpha)}{\Gamma(\alpha + \frac{1}{2})} \quad (4.36)$$

$$\gamma = \frac{2}{\sqrt{\alpha}} \text{sign}(t_3) \quad , \quad (4.37)$$

wobei gilt:

a) Für $0 < |t_3| < \frac{1}{3}$: $z = 3\pi t_3^2$ und $\alpha \approx \frac{1+0,2906z}{z+0,1882z^2+0,0442z^3}$

b) Für $\frac{1}{3} \leq |t_3| < 1$: $z = 1 - |t_3|$ und $\alpha \approx \frac{1+0,2906z}{z+0,1882z^2+0,0442z^3}$

Für $\gamma = 0$ entspricht die Pearson III-Verteilung einer Normalverteilung (Gleichung 4.61). Ansonsten findet folgende Parametrisierung Anwendung $\alpha = \frac{4}{\gamma^2}$, $\beta = \frac{1}{2}\sigma|\gamma|$ und $\zeta = \mu - 2\frac{\sigma}{\gamma}$, somit kann im Nenner von 4.28 $|\beta|$ durch β ersetzt werden. Für $\gamma > 0$ gilt $\zeta \leq x < \infty$ und die obige PDF-Formel (4.28). Für $\gamma < 0$ gilt $-\infty < x \leq \zeta$ und $x - \zeta$ in 4.28 wird zu $\zeta - x$. Die entsprechenden Verteilungsfunktionen sind:

$$F(x) = \frac{G(\alpha, \frac{x-\zeta}{\beta})}{\Gamma(\alpha)} \text{ bzw. } F(x) = 1 - \frac{G(\alpha, \frac{\zeta-x}{\beta})}{\Gamma(\alpha)} \quad (4.38)$$

mit der unvollständigen Gammafunktion $G(\alpha, x) = \int_0^x t^{\alpha-1} e^{-t} dt$.

Für dieses PDF-Matching mittels Pearson III-Verteilung wird das Kürzel PMPE verwendet, es gilt also:

$$x_{PMPE} = F_{obs}^{-1}(F_{sim}(x)) \quad , \quad (4.39)$$

wobei F für die kumulative Wahrscheinlichkeitsfunktion der Pearson III-Verteilung steht.

Für $F_{sim}(x) \leq e^{-7}$ bzw. $F_{sim}(x) \geq 1 - e^{-7}$ werden lineare Extrapolationen unter Verwendung der Differenzen der Minima bzw. Maxima durchgeführt ($x_{PMPE} = x + min_{obs} - min_{sim}$ und entsprechend mit den Maxima).

4.3.3 Bootstrapping und Auswahlverfahren

Um trotz interner Variabilität möglichst robuste Ergebnisse zu erhalten, wird ein Kreuzvalidierungsansatz mit $n = 1001$ Bootstrapping-Iterationen durchgeführt (nähere Ausführungen hierzu siehe 4.4.4.3, S. 82). Der verfügbare Zeitraum 1951–2005 wird dafür in einen Kalibrationszeitraum von 25 Jahren sowie einen Validierungszeitraum von 30 Jahren unterteilt¹⁸. Dies geschieht 1000 mal durch Ziehen ohne Zurücklegen, wobei sichergestellt wird, dass kein Zeitraum mehrfach definiert ist. Die Bootstrapiteration 1001 behandelt die Kombination 1951–1975 und 1976–2005. Der Kalibrationszeitraum (cal) wird jeweils zum Aufstellen der etwaigen Transferfunktion genutzt, während die Güte ($skill(bs)$ für bs -te Iteration) der jeweiligen Iteration aus einer Kombination der jeweils sortierten Werte beider Zeiträume abgeschätzt wird (vgl. KEUPP *et al.* 2019; KASPAR-OTT *et al.* 2019).

$$skill(bs) = MSSS_{cal} + MSSS_{val} + r_{cal}^2 + r_{val}^2, \quad (4.40)$$

wobei $skill(bs) = 0$ gesetzt wird, falls einer der $MSSS$ s negativ ist. Die Iteration bs für die $skill(bs) = max$ wird weiterverwendet. Falls so keine beste Iteration gefunden werden kann, wird zunächst anhand der Güte des Gesamtzeitraums $skill_2(bs) = MSSS_{gesamt} + r_{gesamt}^2$, bei weiterer Uneindeutigkeit anhand des verbleibenden Mittelwertbiases für den Gesamtzeitraum gesucht. Liegt der maximale $skill$ aller 1001 Iterationen bei 0, so wird keine Iteration gewählt und die entsprechende Gitterzelle als ungültig erklärt.

¹⁸Es ist zu beachten, dass (im Gegensatz zu den in Kapitel 4.4 beschriebenen Model Output Statistics) keine zeitliche Korrespondenz der Daten vorliegt. Die Zeiträume für Kalibrierung und Validierung müssen also genügend lang sein, um die Verteilung der Daten zu betrachten. Aufgrund interner Variabilitäten sowohl der Beobachtungs- als auch der Modelldaten können auch 25 bzw. 30 Jahre dafür knapp sein (z.B. HURRELL & LOON 1997; ILES & HEGERL 2017; WOOLLINGS *et al.* 2014 bzw. MAHER *et al.* 2020; SCHINDLER *et al.* 2015; SORTEBERG & KVAMSTØ 2006), die insgesamt verfügbare Zeitspanne ermöglicht jedoch nicht mehr.

4.3.4 Nachgelagerte Wertebereichkorrekturen

Jeder anhand der beschriebenen Verfahren korrigierte Wert wird (innerhalb des Bootstrapping-Prozesses) auf seine Übereinstimmung mit dem jeweiligen Wertebereich hin geprüft. Alle Indizes sind ausschließlich nicht-negativ definiert. Des Weiteren ist nur der Index der maximalen Trockenperiodendauer MCD nach oben unbegrenzt. Als Ereignistage entsprechen die Maximalwerte von R1mmn, R95n, Frost-, Eis- und Hitzetagen der Anzahl der Tage im betrachteten Monat. Der De Martonne-Index ist bis einschließlich 100 definiert. Die Anzahl der Spätfrosttage hat insofern eine obere Grenze, als dass nur das erste Halbjahr betrachtet wird (Maximum ist also die Anzahl der Tage bis zum 30. Juni). Wird der Spätfrost hinsichtlich der monatsdefinierten Vegetationsperiode betrachtet, verkürzt sich die maximale Anzahl der Auftretenstage auf die Anzahl der Tage ab dem 1. April. Bei Unter- bzw. Überschreitung des definierten Bereiches, wird der Wert auf das jeweilige Minimum bzw. Maximum gesetzt.

4.4 Model Output Statistics

„Als MOS definieren wir jede Methode, die eine statistische Transferfunktion zwischen Modell- und Beobachtungsdaten aufstellt und diese Transferfunktion dann zur Nachbearbeitung der Modelldaten verwendet.“ (MARAUN & WIDMANN 2018)

Durch Model Output Statistics (MOS) werden beobachtete Parameter anhand von Modellparametern simuliert und damit korrigiert. Dies entspricht einer Regressionsanalyse derselben: Die Regressionsanalyse untersucht den Zusammenhang zwischen einer Zielgröße (abhängige Variable, Prädiktand) und einer oder mehrerer erklärender Variablen (Kovariablen, unabhängig, Prädiktoren). Dabei soll die funktionale Beziehung möglichst exakt in Form einer Gleichung (Transferfunktion) beschrieben werden, um wie z.B. im vorliegenden Fall (Zukunfts-)Simulationen zu ermöglichen. Dabei setzt sich der wahre Wert des Prädiktanden y zusammen aus dem (bedingten) Erwartungswert $\mu = E(y|x_1, \dots, x_p)$ (also dem simulierten Wert) sowie dem von den Prädiktanden x_i unabhängigen Störterm e (Residuum):

$$y = E(y|x_1, \dots, x_p) + e = \mu + e = f(x) + e \quad (4.41)$$

(z.B. DUNN & SMYTH 2018; FAHRMEIR *et al.* 2009; KRAPP & NEBEL 2011; SCHÖNWIESE 2006; VON STORCH & ZWIERS 2003; WILKS 2011). Das Residuum e ist somit definiert als $e = y - \mu$.

Bei Model Output Statistics wird also die Transferfunktion zwischen modellierten Prädiktoren x_i und beobachtetem Prädiktanden y gesucht.

Hiermit können zwei Ziele verfolgt werden:

- Statistisches Downscaling: Die Simulation eines höher aufgelösten Prädiktanden durch größer aufgelöste Prädiktoren (nur wenn Auflösungsunterschiede bestehen)
- Biaskorrektur: Simulation eines nicht (zufriedenstellend) modellierten Prädiktanden durch verlässlichere Prädiktoren (implizit enthalten, daher auch bei Auflösungsunterschieden)

Abzugrenzen hiervon ist das sogenannte Perfect-Prognosis-Downscaling (Perfect Prog), bei dem die Transferfunktion allein aus beobachteten (Prädiktanden- und Prädiktoren-)Daten aufgestellt wird. Diese wird zwar anschließend ebenfalls auf Modelldaten angewandt, beinhaltet aber keine Korrektur der Modelldaten, es wird daher von perfekt simulierten Prädiktoren ausgegangen (MARAUN & WIDMANN 2018; GLAHN *et al.* 1972).

Die im vorangegangenen Kapitel vorgestellten Biaskorrekturmethode können ebenfalls als MOS angesehen werden. Es bestehen allerdings einige deutliche Unterschiede, die in Tabelle 4.1 aufgeführt sind (vgl. MARAUN & WIDMANN 2018). Daher wird zur Unterscheidung die Benennung *Biaskorrektur (BK)* für Korrekturverfahren auf Basis von Linearskalierungs- und Quantilmappingmethoden (parametrisch und nicht-parametrisch) sowie *Model Output Statistics (MOS)* für Korrektur- bzw. Simulationsmethoden mithilfe von Regressionstechniken (Multiple Lineare Regression und Generalisierte Lineare Modelle, siehe Kapitel 4.4.1 und 4.4.2) verwendet.

Sowohl für MOS als auch für die Biaskorrektur gelten folgende, von BENESTAD (2010) genannte Annahmen für statistisches Downscaling¹⁹ (vgl. MARAUN & WIDMANN 2018):

- Zeitlich konstante Prädiktor-Prädiktand-Beziehung: Die Regressionsgleichung bzw. Biaskorrekturfunktion ist auf andere Zeiträume übertragbar (vgl. Kreuzvalidierung Abschnitt 4.4.4.3)
- Klimaänderungssignal in Prädiktor(en) enthalten
- Starker Zusammenhang zwischen Prädiktor(en) und Prädiktand (vgl. Abschnitt 4.4.4.3)
- Realitätsnahe Prädiktorsimulation durch verwendetes Klimamodell (v.a. für Perfect-Prog-Downscaling, da MOS bzw. Biaskorrektur die jeweilige Korrektur mitbeinhaltet).

¹⁹Hierbei entspricht bei der Biaskorrektur der Prädiktor der modellierten Variable und der Prädiktand der beobachteten Variable.

Tabelle 4.1: Vergleich Biaskorrektur und Modell Output Statistics.

| | Biaskorrektur | MOS |
|------------------------------------------------------------------------------------|----------------------|------------------|
| zeitliche Korrespondenz (Phasenbeziehung) | nein | ja |
| Korrektur auf Ereignisebene | nein | ja |
| Korrektur auf Verteilungs- oder Momentenebene* | ja | nein |
| Prädiktor = Prädiktand (homogen) | ja | möglich |
| mehrere Prädiktoren | nein (univariat) | ja (multivariat) |
| Down-/Upscaling | nein | ja |
| Simulation nicht implizit vom RCM modellierter Variablen | nein | ja |
| hier angewandte Methoden | LS, LSM, QM, PM | MLR, GLM |
| * Moment: Lage-, Form-, Streuungsparameter etc. z.B. Mittelwert, Quantile, Varianz | | |

MOS haben ihre Ursprünge in der numerischen Wettervorhersage (GLAHN *et al.* 1972), bei der eine zeitliche Korrespondenz zwischen beobachteten und simulierten Daten vorliegt. Diese Bindung ist für die Erstellung der Transferfunktionen zwingend notwendig, liegt allerdings für Klimamodelle mit freiem Antrieb nicht vor (z.B. EDEN *et al.* 2012, 2014a; MARAUN *et al.* 2010). Bisherige MOS-Studien mit Klimamodellen nutzen daher Modelle, deren Randbedingungen auf Beobachtungs- oder Reanalysedaten basieren (teilweise noch mit zusätzlichem Nudging (vgl. VON STORCH *et al.* 2000))²⁰, um die Übereinstimmung zu gewährleisten (PAETH & HENSE 2003; PAETH 2011; STEININGER *et al.* 2020; EDEN *et al.* 2012, 2014b,a; MARAUN *et al.* 2010; WONG *et al.* 2014). Klimamodelldaten, die nicht an solche Referenzdaten gebunden sind, können also nur statistisch, aber nicht anhand von Einzelwerten betrachtet und korrigiert werden. Um die MOS-Anwendung auf diese – und damit auf Zukunftsprojektionen – dennoch zu ermöglichen, wird hier ein exploratives Verfahren erprobt:

Für die Aufstellung der Transferfunktion werden Reanalyse-angetriebenen RCM-Daten (mit Phasenbeziehung) genutzt, so dass Korrekturen auf Ereignisebene möglich sind. Näheres hierzu wird im Abschnitt 4.4.4 besprochen. Die Transferfunktion wird anschließend unter Einbezug von Korrekturen auf GCM-angetriebene RCM-Daten übertragen (Abschnitt 4.4.5). Es sei erwähnt, dass aufgrund der unterschiedlichen Auflösungen von Prädiktoren (REMO-Daten

²⁰Daher sind keine Zukunftsprojektionen möglich

auf CORDEX EUR11-Gitter) und Prädiktanden (E-OBS Gitter bzw. Landkreise Unterfrankens bzw. ein Wert für das Frankenweingebiet) durch jeden hier angewandten MOS-Fall eine statistische Umskalierung (teils Down- teils Upscaling) vorgenommen wird.

Im Folgenden werden zunächst Verfahren zur Berechnung der entsprechenden Transferfunktionen erläutert (Kapitel 4.4.1, 4.4.2), bevor näher auf die MOS-Durchführung eingegangen wird. Es werden ausschließlich gleichgewichtete Prädiktoren verwendet.

4.4.1 Lineare Regression

Es soll zunächst die lineare Regressionsanalyse behandelt werden. Hierbei besteht (d.h. sie wird angenommen) eine lineare Beziehung der jeweiligen unabhängigen Variablen zur abhängigen Variablen und die Einflüsse der einzelnen Prädiktoren addieren sich. Die Erläuterungen zur einfacher und multipler linearer Regression basieren – soweit nicht anders gekennzeichnet – auf den Werken von DUNN & SMYTH (2018), FAHRMEIR *et al.* (2009), KRAPP & NEBEL (2011), MCCULLAGH & NELDER (1989), VON STORCH & ZWIERS (2003) sowie WILKS (2011) (in alphabetischer Reihenfolge).

4.4.1.1 Einfache Lineare Regression

Der einfachste Fall, die simple lineare Regression (SLR), besitzt nur eine erklärende Variable x und simuliert $E(y)$ als Gerade:

$$f(x_t) = \mu_t = \beta_0 + \beta_1 x_t \quad (4.42)$$

mit Index z.B. $t = 1, \dots, n$ für die betrachteten Zeitschritte und den beiden Regressionskoeffizienten β_0 und β_1 , wobei ersterer den y-Achsenabschnitt und letzterer die Steigung der Regressionsgeraden darstellt. Anhand der näheren Erläuterung der einfachen linearen Regression können die Grundprinzipien der multiplen linearen Regression (mehrere Prädiktoren, MLR) veranschaulicht werden. Für die Schätzung der Regressionskoeffizienten β kommt – meist und auch hier – die **Methode der kleinsten Quadrate** (engl. Least Squares, Least-Squares Estimation (LSE) oder Ordinary Least-Squares (OLS)) auch KQ-Schätzung zum Einsatz. Ziel hierbei ist es, mithilfe der Prädiktorwerte x diejenige Regressionsgerade zu bilden, die am wenigsten von

den gegebenen Werten von y abweicht. Ziel ist also die Minimierung der Summe der quadrierten Abweichungen (also Fehler, Sum of Squared Errors (SSE)) zwischen y und μ .

$$SSE = \sum_{t=1}^n (y_t - \mu_t)^2 = \sum_{t=1}^n [y_t - (\beta_0 + \beta_1 x_t)]^2 \quad (4.43)$$

Die Minimierung der SSE erfolgt durch Ableitung und Nullsetzen:

$$\frac{\partial SSE}{\partial \beta_0} = 2 \sum_{t=1}^n [y_t - (\beta_0 + \beta_1 x_t)] = 0 \quad (4.44)$$

$$\frac{\partial SSE}{\partial \beta_1} = 2 \sum_{t=1}^n x_t [y_t - (\beta_0 + \beta_1 x_t)] = 0 \quad (4.45)$$

Durch Umformung ergeben sich die sogenannten Normalgleichungen, die nach den Regressionsparametern aufgelöst werden können (mit Mittelwert $\bar{x} = \frac{1}{n} \sum_{t=1}^n x_t$).

Aus Gleichung 4.44:

$$2 \sum_{t=1}^n [y_t - (\beta_0 + \beta_1 x_t)] = 0$$

$$\sum_{t=1}^n y_t = n \beta_0 + \beta_1 \sum_{t=1}^n x_t \quad (4.46)$$

$$\beta_0 = \bar{y} - \beta_1 \bar{x} \quad (4.47)$$

bzw. aus Gleichungen 4.44 und 4.47:

$$2 \sum_{t=1}^n x_t [y_t - (\beta_0 + \beta_1 x_t)] = 0$$

$$\sum_{t=1}^n (x_t y_t) = \beta_0 \sum_{t=1}^n x_t + \beta_1 \sum_{t=1}^n x_t^2 \quad (4.48)$$

$$\beta_1 = \frac{n \sum_{t=1}^n (x_t y_t) - \sum_{t=1}^n y_t \sum_{t=1}^n x_t}{n \sum_{t=1}^n x_t^2 - (\sum_{t=1}^n x_t)^2} \quad (4.49)$$

4.4.1.2 Multiple Lineare Regression

Analog zur SLR wird μ bei der multiplen linearen Regression (MLR) als Linearkombination der p erklärenden Variablen x_i dargestellt:

$$E(y_t | x_{1t}, \dots, x_{pt}) = \mu_t = \beta_0 + \sum_{i=1}^p \beta_i x_{it} \quad (4.50)$$

Es werden also $p' = p + 1$ Regressionskoeffizienten für p Prädiktoren x_i gesucht. In Matrixbe-
trachtung sind die einzelnen Bestandteile:

Der Vektor \mathbf{y} der abhängigen Variable y_t mit Länge n :

$$\mathbf{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix},$$

der Vektor $\boldsymbol{\beta}$ der Regressionskoeffizienten β_i mit Länge $p' = p + 1$:

$$\boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}$$

sowie die $n \times p'$ -Matrix \mathbf{X} :

$$\mathbf{X} = \begin{pmatrix} 1 & x_{11} & \dots & x_{1p} \\ 1 & x_{21} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \dots & x_{np} \end{pmatrix},$$

in der die Zeilen die n Zeitschritte und die Spalten die $p' = p + 1$ Prädiktoren enthalten.

Daraus folgt:

$$\boldsymbol{\mu} = \mathbf{X}\boldsymbol{\beta} \tag{4.51}$$

Somit ergibt sich die Summe der kleinsten Quadrate der Residuen (vgl. Gleichung 4.43):

$$SSE = (\mathbf{y} - \boldsymbol{\mu})^\top (\mathbf{y} - \boldsymbol{\mu}) = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})^\top (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) \tag{4.52}$$

mit den Schätzungen $\hat{\boldsymbol{\beta}}$ für $\boldsymbol{\beta}$.

Die Koeffizientenschätzungen werden wiederum durch Ableiten und Nullsetzen der SSE berechnet:

$$\frac{\partial(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})^\top(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})}{\partial\hat{\boldsymbol{\beta}}} = 0 \quad (4.53)$$

$$\frac{\partial(\mathbf{y}^\top\mathbf{y} - 2\hat{\boldsymbol{\beta}}^\top\mathbf{X}^\top\mathbf{X}\mathbf{y} + \hat{\boldsymbol{\beta}}^\top\mathbf{X}^\top\mathbf{X}\hat{\boldsymbol{\beta}})}{\partial\hat{\boldsymbol{\beta}}} = 0$$

$$-2\mathbf{X}^\top\mathbf{y} + 2\mathbf{X}^\top\mathbf{X}\hat{\boldsymbol{\beta}} = 0 \quad (4.54)$$

$$\mathbf{X}^\top\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}^\top\mathbf{y} \quad (4.55)$$

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^\top\mathbf{X})^{-1}\mathbf{X}^\top\mathbf{y} \quad (4.56)$$

Durch die Matrixberechnungen erfolgt so eine simultane Lösung von p' Gleichungssystemen.

4.4.1.3 Voraussetzungen

Um eine lineare Regressionsanalyse durchführen (und interpretieren) zu können, müssen einige Annahmen – zumindest näherungsweise – erfüllt sein:

- **Keine Multikollinearität:** Diese Voraussetzung ergibt sich aus der KQ-Schätzung der Regressionsparameter. Der Schritt von Gleichung 4.55 zu 4.56, also die Auflösung nach $\boldsymbol{\beta}$ ist nur möglich, wenn $\mathbf{X}^\top\mathbf{X}$ invertierbar ist. Daher muss \mathbf{X} vollen Spaltenrang aufweisen ($\text{rgs}(\mathbf{X})=p'$), was bedeutet, dass keine lineare Abhängigkeit der Spalten (also der einzelnen Prädiktoren) vorliegen darf.
- **Linearität:** Es besteht ein linearer Zusammenhang zwischen $E(y) = \mu$ und den Prädiktoren x_i
- **(Approximativ) normalverteilte (=Gauß-verteilte) Fehler v.a. für kleine Stichprobengrößen**
- **Konstante Fehlervarianz (Homoskedastizität):** Die Größe der Fehler e wird nicht von der Größe von y (oder einem bzw. mehreren x_i) beeinflusst. Anders ausgedrückt: Die Streuung von μ um y erhöht oder verringert sich nicht bei kleinerem oder größerem y .
- **Unabhängige Störgrößen e mit Erwartungswert $E(e) = 0$**
- **Unabhängige Beobachtungen:** Es liegt keine Abhängigkeit zwischen den Ausprägungen der Prädiktanden vor.

Das Vorliegen einer Multikollinearität lässt sich durch die Prädiktorenauswahl bzw. das Verwerfen korrelierter Prädiktoren vermeiden (siehe 4.4.4.3, S. 81) und auch die Unabhängigkeit

von Prädiktandenausprägungen ist durch geeignete Methoden mitunter abwendbar (z.B. Entfernung Jahresgang, einzelne Monatsbetrachtung). Ebenso kann die Linearität des Zusammenhangs zwischen μ und den Prädiktoren x_i , je nach Daten, durch Transformation des Prädiktanden herbeigeführt werden (z.B. $y' = \log y$). Die übrigen Voraussetzungen jedoch sind datenabhängig und wenig beeinflussbar. In den folgenden Abschnitten wird daher ein erweitertes Verfahren vorgestellt. Dieses bietet sich vor allem aufgrund der Annahmen bzgl. der Residuen bzw. Fehler für die hier zu untersuchenden Zielgrößen als zusätzliche oder alternative Analysemethode an.

4.4.2 Generalisierte Lineare Modelle

Die im vorherigen Kapitel vorgestellten multiplen linearen Regressionsmodelle sind weit verbreitet, jedoch nicht für die sinnvolle Analyse und Simulation aller Daten geeignet. Ob die Voraussetzungen für eine normale MLR erfüllt sind, kann sich bereits durch die genauere Betrachtung der Zielvariablen anhand ihrer Merkmale erschließen (Tabelle 4.2).

Tabelle 4.2: Merkmale der Indizes (BOG = bekannte obere Grenze).

| Zielgrößen | Kontinuität | Definitionsbereich |
|--------------------------------------------------------------------------|----------------|--------------------|
| R1mmn, R95n, Frosttage, Eistage, Hitzetage, Spätfrost VPT, Spätfrost VPM | diskret | [0,BOG] |
| MCD | diskret | \mathbb{N}_0^+ |
| DMI | kontinuierlich | [0,100] |
| LW, FW | kontinuierlich | \mathbb{R}_0^+ |

Es handelt sich bei den zu untersuchenden Größen also entweder um Zähldaten, die allerdings in allen Fällen außer MCD nach oben begrenzt sind (Anzahl der Tage in einem Monat bzw. Anzahl der Periode, in denen Frost als Spätfrost aufgefasst wird) und somit als Raten bzw. Proportionen aufgefasst werden können. Oder der Wertebereich ist positiv kontinuierlich (inkl. Null), wobei im Bezug auf den de Martonne-Index eine künstliche obere Grenze von 100 besteht. In allen Fällen bedingt somit die Variablendefinition, dass die Voraussetzung der konstanten Varianz sowie der Normalverteilung der Fehler für die normale MLR nicht erfüllt sein kann:

Durch die Begrenzung der Daten auf mindestens einer Seite muss die Varianz bei Annäherung an die jeweilige Grenze gegen Null gehen, da weiter innerhalb des Wertebereichs eine größere Streuung erlaubt ist. Für eine Normalverteilung der Fehler müsste ebenfalls ein unbegrenzter

(und kontinuierlicher) Wertebereich vorliegen, was auch eine Voraussetzung für einen linearen Zusammenhang ist (vgl. DUNN & SMYTH 2018).

Es ist somit ratsam, die Simulation der Zielgrößen (zusätzlich zur MLR) durch alternative Regressionsmethoden vorzunehmen.

Ein Ansatz, der mehrere alternative Verfahren vereint, sind die sogenannten Generalisierten Linearen Modelle (engl. Generalized Linear Models) – kurz GLMs (MCCULLAGH & NELDER 1989). Die folgenden Erläuterungen zu GLMs (inkl. Unterabschnitte) sind soweit nicht genauer gekennzeichnet eine Zusammenstellung von Informationen aus MCCULLAGH & NELDER (1989), DUNN & SMYTH (2018), CRAWLEY (2013), FAHRMEIR *et al.* (2009) sowie WILKS (2011).

GLMs setzen sich aus einer systematischen und einer zufälligen Komponente zusammen. Die **systematische Komponente** (Strukturannahme) eines GLMs besteht aus dem Linearprädiktor η sowie der Linkfunktion $g(\cdot)$, die dessen Beziehung zum Erwartungswert $\mu = E(y)$ der Zielgröße darstellt.

$$\eta_i = \sum_j (x_{ij}\beta_j) \quad \text{bzw. in Matrixschreibweise} \quad \boldsymbol{\eta} = \mathbf{X}\boldsymbol{\beta} \quad (4.57)$$

Der Linearprädiktor η entspricht einer (multiplen) linearen Regression. Die zwischengeschaltete monotone und differenzierbare Linkfunktion g erlaubt die Betrachtung nicht-linearer Zusammenhänge. Sie wird entsprechend der Eigenschaften des Prädiktanden gewählt und legt den möglichen Wertebereich der simulierten Daten fest. Die Umkehrfunktion der Linkfunktion $g(\cdot)$ wird Responsefunktion $h(\cdot)$ genannt und veranschaulicht die Transformation des Linearprädiktors.

$$g(\mu) = \eta \quad (4.58)$$

$$\mu = h(\eta) = g^{-1}(\eta) \quad (4.59)$$

Für klassische lineare Modelle als Spezialfall der GLMs gilt $\eta = \mu$ und man spricht vom Identity-Link. Somit entspricht der Wertebereich (von η und μ) der Gesamtheit der reellen Zahlen. Soll nun aber sichergestellt werden, dass μ innerhalb eines begrenzten Wertebereichs liegt, sind andere Linkfunktionen notwendig. Der log-Link ($\eta = \log(\mu)$ und daher $\mu = \exp(\eta)$) z.B.

sorgt auch bei negativem Linearprädiktor für positive Erwartungswerte μ . Generell ist die Link-Funktion so zu wählen, dass die Abweichungen der simulierten Daten möglichst gering wird (CRAWLEY 2013).

Die **zufällige Komponente** (random component) des GLMs wird durch die angenommene Verteilung bestimmt. Während die multiple lineare Regression von normalverteilten Fehlern ausgeht, stellen GLM eine Verallgemeinerung der (multiplen) linearen Regression unter Verwendung von Verteilungen der Dispersions-Exponentialfamilie (engl. exponential dispersion model family, EDM) dar. Unter letztere fallen neben der Gaußverteilung unter anderem Gamma-, Poisson- und Binomialverteilung.

Die EDM-Wahrscheinlichkeitsfunktion (kanonische Form) lautet:

$$\mathcal{P}(y; \theta, \phi) = a(y, \phi) \exp \left\{ \frac{y\theta - \kappa(\theta)}{\phi} \right\} \quad (4.60)$$

mit dem kanonischen Parameter θ , der (bekannten) Kumulantfunktion $\kappa(\theta)$, dem Dispersionsparameter $\phi > 0$, dem Mittelwert μ als bekannte Funktion des kanonischen Parameters θ und der normalisierenden Funktion $a(y, \phi)$, die dafür sorgt, dass die Gleichung immer einer Wahrscheinlichkeitsfunktion entspricht (Sicherstellung, dass Gesamtintegral (kontinuierlich) bzw. -summe (diskret) immer 1). Nähere Informationen zu EDM sind in JØRGENSEN (1987) zu finden.

Für Gauss-EDM gilt folgende kanonische Form (die gleichzeitig der üblichen Schreibweise für die Normalverteilung entspricht):

$$f(y) = \mathcal{P}(y; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left(-\frac{(y - \mu)^2}{2\sigma^2} \right) \quad (4.61)$$

mit $a(y, \phi) = (2\pi\sigma^2)^{-1/2} \exp \left(\frac{-y^2}{2\sigma^2} \right)$, der Kreiszahl π sowie der Varianz der Grundgesamtheit σ^2 (wobei hier gilt $\phi = \sigma^2$). Der kanonische Parameter θ sowie die Kumulantfunktion $\kappa(\theta)$ sind in Tabelle 4.3 aufgeführt.

Basis für die Wahl der verwendeten Verteilung kann die Art der Zielvariable oder die Varianzfunktion ($V(y)$) sein. Da die Varianzfunktion die Kumulantfunktion $\kappa(\theta)$ festlegt, bestimmt sie die Wahl der Verteilung. Tabelle 4.3 zeigt für bestimmte Datenarten übliche EDMs.

Um ein GLM zu definieren sind somit neben Prädiktand und Prädiktoren eine Linkfunktion sowie eine Fehlerverteilungsfunktion festzulegen.

Tabelle 4.3: Geläufige EDMs. Varianzfunktion $V(\mu)$, Kumulantfunktion $\kappa(\theta)$, kanonischer Parameter θ .

| Daten | EDM | $V(\mu)$ | $\kappa(\theta)$ | θ | $y \in$ | $\mu \in$ |
|------------------------|---------------|----------------|-------------------------|-----------------------------------------------|-------------------------|----------------|
| kontinuierlich | Gauss | 1* | $\frac{\theta^2}{2}$ | μ | \mathbb{R} | \mathbb{R} |
| Zählraten** | Poisson | μ | $\exp \theta$ | $\log \mu$ | \mathbb{N}_0 | \mathbb{R}^+ |
| Proportionen | Binomial | $\mu(1 - \mu)$ | $\log(1 + \exp \theta)$ | $\log \frac{\mu}{1 - \mu}$ | $\frac{0,1,\dots,m}{m}$ | $(0, 1)$ |
| positiv-kontinuierlich | Gamma | μ^2 | $-\log(-\theta)$ | $-\frac{1}{\mu}$ bzw. $\frac{1}{\mu}$ | \mathbb{R}^+ | \mathbb{R}^+ |
| | Inverse Gauss | μ^3 | $-\sqrt{-2\theta}$ | $-\frac{1}{2\mu^2}$ bzw. $\frac{1}{\mu^2}$ | | |

* konstante Varianz, kein Zusammenhang zwischen Mittelwert und Varianz

** ohne obere Begrenzung

Wird die Linkfunktion so gewählt, dass $\theta = \eta = g(\mu)$, der kanonische Parameter aus Gleichung 4.60 und Tabelle 4.3 also dem Linearprädiktor entspricht, spricht man von der kanonischen Linkfunktion.

Für die Verwendung von GLMs werden folgende Annahmen getroffen. Diese müssen (und werden) nicht komplett erfüllt sein, was jedoch Auswirkungen auf Modellgüte und -interpretierbarkeit hat.

- Der Prädiktand ist eine kategoriale, metrische oder Zählvariable und seine Beobachtungen sind unabhängig (unkorreliert).
- Sein Erwartungswert $\mu = E(y)$ besitzt einen linearen Zusammenhang zum transformierten Linearprädiktor $h(\eta)$.
- Es wird ein zu den Daten passendes EDM (mit dazugehöriger passender konstanter Fehlerverteilung bzw. Varianzfunktion) sowie eine passende Linkfunktion gewählt.

Die in dieser Studie betrachteten Zielgrößen sind typische Prädiktanden für die Anwendung von GLMs. Die gängigen EDMs hierbei sind die Poissonverteilung für Zählraten (ohne obere Grenze), die Binomialregression für Proportionen (aus Zählraten und ihrer oberen Grenze) sowie die Gamma- und die inverse Gaussverteilung für positiv-kontinuierliche Daten.

Gerade für letztgenannte Variablen kann je nach Lage des Verteilungsschwerpunktes und Streuung (sehr geringe Wahrscheinlichkeiten für negative Werte) auch eine Normalverteilungsannahme zielführend sein. Möglich ist auch ein Gauß-EDM mit log-Link.

Folgende Abschnitte gehen detaillierter auf die jeweiligen EDMs und passende Linkfunktionen ein.

4.4.2.1 Zähldaten

Zähldaten besitzen einige Eigenschaften, die einer klassischen multiplen Regression widersprechen:

- Sie können keine negativen Werte annehmen
- Durch die untere Begrenzung ist die Varianz nicht konstant (höhere Mittelwerte erlauben höhere Streuung)
- Die Residuen folgen keiner Gauß'schen Verteilung (v.a. bei geringen Häufigkeiten) und ihre Verteilung wird von der Ganzzahligkeit der Daten beeinflusst.

Hier sind im Speziellen solche Zählvariablen angesprochen, die keine obere Grenze besitzen bzw. deren obere Grenze deutlich überhalb existenter Ausprägungen liegt (seltene Ereignisse). Dies entspricht im Falle dieser Arbeit ausschließlich der maximalen Anzahl konsekutiver Trockentage (MCD), da alle anderen Zählindizes durch die Anzahl der Tage im Monat bzw. die Länge der Periode in der Frost als Spätfrost aufgefasst wird, begrenzt sind. Des Weiteren beschreiben die übrigen behandelten Zählindizes das Eintreten von Ereignissen, das im Vergleich zum jeweiligen Nicht-Eintreten gesehen werden kann. In einem 31-tägigen Monat mit zehn Frosttagen z.B. stehen auf der anderen Seite 21 Tage ohne Frost. Sie können daher auch als das Verhältnis von Eintreten zu Nicht-Eintreten beschrieben werden. Ihre Analyse wird daher im Abschnitt Verhältniszahlen (S. 63) thematisiert.

Typischerweise wird für Zähldaten (seltener Ereignisse) eine Poissonverteilung der Residuen angenommen.

$$f(y) = \mathcal{P}(y; \theta, \phi) = \frac{e^{-\mu} \mu^y}{y!} = \exp\{y \log \mu - \mu - \log(y!)\} \quad (4.62)$$

mit $\phi = 1$ und $a(y, \phi) = \frac{1}{y!}$, vgl. Gleichung 4.60 und Tabelle 4.3.

Um negative Werte auszuschließen, ist die häufigste (und kanonische) Linkfunktion der log-Link:

$$g(\mu) = \log(\mu) \text{ bzw. } \mu = h(\eta) = \exp(\eta)$$

Die Umkehrfunktion zeigt, dass selbst negative Werte des Linearprädiktors zu positiven Erwartungswerten führen. Additive Effekte auf η wirken multiplikativ auf μ , da $\exp(a + b) = \exp(a) \cdot \exp(b)$. Auch möglich ist der Quadratwurzel-Link (squareroot-Link) $g(\mu) = \sqrt{\mu}$, dessen Umkehrfunktion $\mu = h(\eta) = \eta^2$ ebenfalls positive Erwartungswerte sicherstellt.

Eine Besonderheit dieser Verteilung ist, dass die Varianz gleich dem Mittelwert ist ($\sigma^2 = V(\mu) = \mu$) und allein dieser Parameter die Verteilung definiert. Der Dispersionsparameter in der kanonischen Form ist $\phi = 1$. Dies kann als idealtypisches Modell angesehen werden, welches jedoch häufig nicht zur Erfassung der Daten ausreicht. Übersteigt die Varianz der Daten ihren Mittelwert, spricht von Überdispersion (Overdispersion). Um dieser zu begegnen, wird anstelle des beschriebenen Poissonmodells ein Quasi-Poissonmodell mit einem anhand der Daten geschätzten (Über-)Dispersionsparameter angepasst (vgl. auch HEDDERICH & SACHS 2016). Näheres hierzu wird weiter unten erläutert (S. 69). Letzterer skaliert die Varianz im Verhältnis zum Erwartungswert ($V(\mu) = \phi \cdot \mu$). Hierdurch ändern sich im Vergleich zum Poisson-GLM die Fehler bzw. Residuen, nicht aber die geschätzten Koeffizienten.

4.4.2.2 Verhältniszahlen und nach oben begrenzte Zählvariablen

Wie bereits im vorherigen Abschnitt beschrieben, können Zählraten mit oberer Grenze, die eine Ereignishäufigkeit abbilden, als Verhältnis zwischen Eintreten und Nicht-Eintreten behandelt werden. Dies betrifft in dieser Arbeit zum Einen die monatlichen Indizes R1mmn, R95n sowie Anzahl der Frost-, Eis- und Hitzetage. Die obere Grenze stellt hier die Anzahl der Tage im jeweiligen Monat dar. Zum Anderen kann die Spätfrosthäufigkeit relativ zur maximalen Anzahl der Tage, an denen Spätfrost erfasst wird, betrachtet werden (VPM 91 Tage im Zeitraum April–Juni, VPM ab thermischem Vegetationsbeginn bis einschließlich Juni, wobei der thermische Vegetationsbeginn frühestens am 1. Januar des jeweiligen Jahres datiert wird, somit 181 bzw. in Schaltjahren 182 Tage).

So umgewandelt, können sie ausschließlich Werte zwischen Null und Eins annehmen und aufgrund der oberen und unteren Begrenzung weder eine konstante Varianz noch normalverteilte

Fehler aufweisen. Eine geeignete Fehlerverteilung stellt hier die im Folgenden erläuterte Binomialverteilung dar²¹:

$$f(y) = \mathcal{P}(y; \mu, m) = \binom{m}{my} \mu^{my} (1 - \mu)^{m(1-y)} \quad (4.63)$$

mit bekannter oberer Grenze der Ereignishäufigkeit m , y als Verhältnis zwischen beobachteter Auftretenshäufigkeit und m (my ist also die absolute Ereignisanzahl) und erwartetem Auftretensverhältnis (Wahrscheinlichkeit) μ .

Für die kanonische Form gilt damit $\phi = \frac{1}{m}$ und $a(y, \phi) = \binom{m}{my}$.

Die gewählte Linkfunktion soll sicherstellen, dass $0 < \mu < 1$ für $-\infty < \eta < \infty$ gilt, häufig verwendet werden daher:

- Logit-Link (kanonischer Link): $\eta = g(\mu) = \log \frac{\mu}{1-\mu}$ ergo $\mu = h(\eta) = \frac{\exp(\eta)}{1+\exp \eta}$

Man spricht hierbei auch von logistischer Regression (wobei die logistische Regression an sich nicht die Annahme binomialverteilter Fehler voraussetzt). Der logit-Link ist hinsichtlich seiner Interpretation interessant, da er dem Log-Odds-Ratio entspricht. Der Odds-Ratio (auch Chance genannt) ist das Verhältnis der Eintretenswahrscheinlichkeit μ zur Wahrscheinlichkeit des Nicht-Eintretens $1 - \mu$. Aus dem logit-Link resultiert eine exponentiell-multiplikative Wirkung der Prädiktoren auf die Odds.

- Probit-Link: $\eta = g(\mu) = \Phi^{-1}$ also $\mu = h(\eta) = \Phi(\eta)$, wobei Φ die kumulative Normalverteilung ist
- Komplementärer log-log-Link (cloglog): $\eta = g(\mu) = \log(-\log(1 - \mu))$ ergo $\mu = h(\eta) = 1 - \exp(\exp(\mu))$.

Die beiden erstgenannten Linkfunktionen zeigen hinsichtlich ihrer Ergebnisse geringe Unterschiede und sind beide symmetrisch um $\mu = 0,5$, letztere ist unsymmetrisch und entfernt sich mit steigendem μ von den anderen beiden, da sie langsamer gegen unendlich geht. In der Praxis hängt die Wahl der Linkfunktion von der Güte der Regressionsergebnisse ab.

Die Gleichung 4.63 zeigt, dass die Binomialverteilung, ebenso wie die Poissonverteilung, keinen Dispersionsparameter ϕ enthält. Sie wird ausschließlich von m und μ bestimmt. Es wird von $\phi = 1/m$ ausgegangen. Wie bei der Poissonverteilung entspricht dies aber auch hier nicht

²¹Der Binomialkoeffizient ist definiert als $\binom{N}{x} = \frac{N!}{x!(N-x)!}$ (z.B. SCHÖNWIESE 2006)

immer den vorliegenden Daten. Weicht also die Varianz vom Produkt aus Wahrscheinlichkeit und Gegenwahrscheinlichkeit $V(\mu) = \mu(1 - \mu)$ ab, liegt Überdispersion vor und ein Quasi-Binomialmodell mit geschätztem Dispersionsparameter ist anzuwenden (siehe S. 69).

4.4.2.3 Positiv-kontinuierliche Daten

Positiv-kontinuierliche Daten sind nach unten begrenzt und können daher keine konstante Varianz und keine normalverteilten Fehler aufweisen. Häufig zeigen sie aufgrund der unteren Begrenzung eine mit dem Mittelwert ansteigende Varianz (mit konstantem Variationskoeffizient $\frac{V(\mu)}{\mu^2} = \text{konst.}$) und eine rechtsschiefe Verteilung (viele niedrige und wenige hohe Werte, vgl. 4.1.1). Die Verwendung einer Regression mit Normalverteilungsannahme (mit log-Link, was negative Werte ausschließt) kann in manchen Fällen ausreichen, allerdings wird dies der Varianz- und Fehlerstruktur der Daten häufig nicht gerecht. Dann kann die Annahme Gammaverteilter Residuen zielführend sein:

$$f(y) = \frac{y^{\nu-1}}{k^\nu \Gamma(\nu)} e^{-\frac{y}{k}} = \left(\frac{y}{k}\right)^\nu \frac{1}{y} \exp\left(-\frac{y}{k}\right) \frac{1}{\Gamma(\nu)}, y, \nu, k > 0 \quad (4.64)$$

mit dem Formparameter ν , dem Skalenparameter k und der Gammafunktion Γ :

$$\Gamma(k) = \int_0^\infty t^{k-1} e^{-t} dt \quad (4.65)$$

Durch $\nu = \phi^{-1}$ (somit $\phi = \nu^{-1}$) und $k = \mu\phi$ ergibt sich (vgl. Gleichung 4.60 und Tabelle 4.3):

$$\mathcal{P}(y; \mu, \phi) = \left(\frac{y}{\mu\phi}\right)^{1/\phi} \frac{1}{y} \exp\left(-\frac{y}{\mu\phi}\right) \frac{1}{\Gamma(1/\phi)}, y < 0, \mu > 0, \phi > 0 \quad (4.66)$$

Anders als bei den bisher genannten GLMs, stellt die reziproke oder inverse Linkfunktion als kanonischer Link für das Gamma-EDM nicht für alle $x \in \mathbb{R}$ sicher, dass für alle $\mu \in \mathbb{R}^+$ gilt:

$$\eta = g(\mu) = \frac{1}{\mu} \text{ und somit } \mu = h(\eta) = \frac{1}{\eta}.$$

Da dies zu Einschränkungen hinsichtlich der Regressionskoeffizienten führt, wird meist ein log-Link verwendet. Der multiplikativ-exponentielle Einfluss der Prädiktoren stellt so einen positiven Erwartungswert μ sicher (siehe Zählvariablen, S. 62): $g(\mu) = \log(\mu)$ bzw. $\mu = h(\eta) = \exp(\eta)$.

Auch ein direkt-linearer Ansatz (Identity-Link $g(\mu) = \mu$) ist möglich, führt jedoch auch zu Problemen hinsichtlich des Definitionsbereichs von μ .

Für noch schiefere Daten ist eine inverse Gaussverteilung ein gängiges EDM. Da der kanonische Link $g(\mu) = \eta = \mu^{-2}$ Einschränkungen für den Linearprädiktor η impliziert, wird wie bei Gamma-GLMs auch hier meist eine log-Linkfunktion verwendet.

$$\mathcal{P}(y; \mu, \phi) = (2\pi y^3 \phi)^{-1/2} \exp\left(-\frac{1}{2\phi} \frac{(y - \mu)^2}{y\mu^2}\right), \quad y > 0, \mu > 0, \phi > 0, \quad (4.67)$$

wobei für den Dispersionsparameter ϕ ein Schätzwert angenommen wird (siehe Gleichung 4.85) (DUNN & SMYTH 2018; MCCULLAGH & NELDER 1989).

Trotz seiner oberen Grenze fällt der Trockenheitsindex nach de Martonne in die Kategorie der positiv-kontinuierlichen Daten. Die obere Grenze ist künstlich gesetzt und der üblichen Verwendung des DMI in klassierter Weise geschuldet.

4.4.2.4 GLM-Parameterschätzung

Die zur Parameterschätzung für die multiple lineare Regression Anwendung findende Methode der kleinsten Quadrate ist für generalisierte lineare Modelle nicht anwendbar (außer beim Identity-Gauss-Modell, das ja der MLR entspricht). Stattdessen wird die sogenannte Maximum Likelihood-Schätzung benutzt (MCCULLAGH & NELDER 1989; FAHRMEIR *et al.* 2009; DUNN & SMYTH 2018):

Die Parameterschätzung erfolgt hierbei so, dass die Wahrscheinlichkeit bzw. Dichte für die beobachteten Prädiktandenwerte maximiert wird, anders gesagt: Für welche β besitzt ein gegebenes y die höchste Plausibilität?

Die Likelihood-Funktion entspricht hierbei der Wahrscheinlichkeits- bzw. Dichtefunktion von y , wobei sich die Betrachtungsweise ändert. Entgegen der Wahrscheinlichkeit für y bei gegebenen Parametern θ und ϕ bei der Wahrscheinlichkeits- bzw. Dichtefunktion, liegt der Augenmerk bei der Likelihood-Funktion auf der Wahrscheinlichkeit für θ bei gegebenem y und ϕ , wie in Gleichungen 4.68 für die Normalverteilung und 4.69 für den allgemeinen EDM-Fall erkennbar.

$$L(\theta; y, \phi) = f(y; \theta, \phi) = f(y; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y - \mu)^2}{2\sigma^2}\right) \quad (4.68)$$

$$L(\theta; y, \phi) = \mathcal{P}(y; \theta, \phi) = a(y, \phi) \exp \left\{ \frac{y\theta - \kappa(\theta)}{\phi} \right\} \quad (4.69)$$

Für Prädiktoren mit unterschiedlicher Gewichtung gilt:

$$L(\theta; y, \phi/w) = a(y, \phi) \exp \left\{ w \frac{y\theta - \kappa(\theta)}{\phi} \right\}$$

mit Gewichtsvektor w . Es wird folgend jedoch von gleichgewichteten Prädiktoren, also von $w_i = 1$ für alle $i = 1, \dots, p$ Prädiktoren, ausgegangen.

Aus Gründen der einfacheren Berechnung ($\log \prod x = \sum \log x$), wird in der Praxis die log-Likelihood verwendet, wobei die Maximierung der log-Likelihood gleichzeitig die Likelihood maximiert:

$$l(\theta; y, \phi) = \log L(\theta; y, \phi) = -\frac{1}{2} \log(2\pi\sigma^2) - \frac{(y - \mu)^2}{2\sigma^2} \quad (4.70)$$

bzw.

$$l(\theta; y, \phi) = \log L(\theta; y, \phi) = \log(a(y, \phi)) + \left\{ \frac{y\theta - \kappa(\theta)}{\phi} \right\} \quad (4.71)$$

Da von einer bedingten Unabhängigkeiten der $y_i|x_i$ ausgegangen wird und zusätzlich β und θ über μ voneinander abhängen (da $\mu = \kappa'(\theta) = h(x\beta)$), gilt:

$$l(\beta; y, \phi) = \sum l_i(\beta_i; y_i, \phi) = \sum l_i(\theta_i; y_i, \phi) \quad (4.72)$$

Da die EDM-(log-)Likelihood aufgrund der EDM-Definition unimodal und nach θ ableitbar ist, kann durch Ableitung und Nullsetzen das Maximum der Funktion und so die Maximum Likelihood gefunden werden. Die erste Ableitung der log-Likelihood wird Score-Funktion genannt. Ihr Erwartungswert ist immer Null, da ja der Scheitelpunkt der Funktion gesucht wird. Um nun alle gesuchten Regressionsparameter β zu finden müssen $p + 1$ Score-Funktionen aufgestellt, nullgesetzt und nach der jeweiligen Unbekannten aufgelöst werden, um den Maximum-Likelihood-Schätzer zu erhalten.

Die Aufstellung der Score-Funktion(en) für β erfolgt in drei Schritten. Dabei entfällt der konstante Faktor $a(y, \phi)$ durch die Differenzierung.

1) Erste Ableitung der log-Likelihood nach θ mit $\mu = \frac{d\kappa(\theta)}{d(\theta)}$:

$$\frac{\partial l(\theta; y, \phi)}{\partial \theta} = \frac{\partial \left(\log(a(y, \phi)) + \left\{ \frac{y\theta - \kappa(\theta)}{\phi} \right\} \right)}{\partial \theta} = \frac{y - \mu}{\phi} \quad (4.73)$$

2) nach μ mit $V(\mu) = \frac{d\mu}{d\theta}$:

$$\frac{\partial l(\theta; y, \phi)}{\partial \mu} = \frac{\partial l(\theta; y, \phi)}{\partial \theta} \frac{d\theta}{d\mu} = \frac{y - \mu}{V(\mu)\phi} \quad (4.74)$$

3) nach β

$$\frac{\partial l(\theta; y, \phi)}{\partial \beta_j} = \frac{\partial l(\theta; y, \phi)}{\partial \mu} \frac{\partial \mu}{\partial \beta_j} = \frac{y - \mu}{V(\mu)\phi} \frac{x_j}{d\eta/d\mu} = \frac{\partial l(\beta; y, \phi)}{\partial \beta_j} \quad (4.75)$$

Aus Gleichung 4.75 folgt die **Score-Funktion U** mit den Arbeitsgewichten W_i :

$$W_i = \frac{w_i}{V(\mu_i)(d\eta_i/d\mu_i)^2} = \frac{1}{V(\mu_i)(d\eta_i/d\mu_i)^2} \quad , \quad (4.76)$$

wobei in dieser Arbeit gleichgewichtete Prädiktoren verwendet werden, daher $w_i = 1$.

$$U(\beta_j) = \frac{\partial l(\beta_0, \dots, \beta_p, \phi; y)}{\partial \beta_j} = \frac{\partial \sum_{i=1}^n \log \mathcal{P}(y_i; \mu_i, \phi)}{\partial \beta_j} = \frac{1}{\phi} \sum_{i=1}^n W_i \frac{d\eta_i}{d\mu_i} (y_i - \mu_i) x_{ji} \quad (4.77)$$

mit $j = 0, \dots, p$ und $x_{0i} = 1$ sowie konstantem ϕ .

In Matrixschreibweise:

$$\mathbf{U} = \frac{1}{\phi} \mathbf{X}^T \mathbf{W} \mathbf{M} (\mathbf{y} - \boldsymbol{\mu}) \quad (4.78)$$

mit $\mathbf{U} = [U_0, \dots, U_p]^T$ für $\boldsymbol{\beta}$, \mathbf{W} Diagonalmatrix der Arbeitsgewichte W_i , \mathbf{M} Diagonalmatrix der Linkableitungen $\frac{d\eta_i}{d\mu_i}$

Für die simultane Lösung der p Score-Gleichungen wird das so genannte Fisher-Scoring mit Hilfe einer iterativ gewichteten KQ-Schätzung (engl. Iteratively (Re-)weighted Least Squares Estimation, kurz IWLS oder IRLS) angewandt.

Hierfür wird die zweite Ableitung der log-Likelihood nach β gebildet:

$$\begin{aligned} \frac{\partial^2 l(\beta; y, \phi)}{\partial \beta_k \partial \beta_j} &= \frac{\partial (y - \mu) \frac{x_j}{V(\mu)\phi \frac{d\eta}{d\mu}}}{\partial \beta_k} \\ &= \left(\frac{x_j}{V(\mu)\phi \frac{d\eta}{d\mu}} \right) \frac{\partial (y - \mu)}{\partial \beta_k} + (y - \mu) \frac{\partial \left(\frac{x_j}{V(\mu)\phi \frac{d\eta}{d\mu}} \right)}{\partial \beta_k} \end{aligned} \quad (4.79)$$

Da $y - \mu \stackrel{!}{=} 0$ folgt als Erwartungswert E :

$$\begin{aligned} E \left(\frac{\partial^2 l(\beta; y, \phi)}{\partial \beta_k \partial \beta_j} \right) &= \left(\frac{x_j}{V(\mu)\phi \frac{d\eta}{d\mu}} \right) \left(\frac{\partial (y - \mu)}{\partial \beta_k} \right) \\ &= \left(\frac{x_j}{V(\mu)\phi \frac{d\eta}{d\mu}} \right) \left(\frac{x_k}{(d\eta/d\mu)} \right) \\ &= - \frac{1}{V(\mu)\phi} \frac{x_j x_k}{(d\eta/d\mu)^2} \end{aligned} \quad (4.80)$$

und die **Fisher-Information** wird definiert als negative zweite Ableitung:

$$\mathcal{I}_{jk}(\beta) = \frac{1}{\phi} \sum_{i=1}^n W_i x_{ji} x_{ki} \quad \text{bzw.} \quad \mathcal{I} = \frac{1}{\phi} \mathbf{X}^T \mathbf{W} \mathbf{X} \quad (4.81)$$

in Matrixschreibweise \mathcal{I} für β mit $\mathcal{I}_{jk}(\beta)$.

Die **Parameterschätzung durch Fisher-Scoring** erfolgt durch:

$$\hat{\beta}^{(r+1)} = \hat{\beta}^{(r)} + \mathcal{I}(\hat{\beta}^{(r)})^{-1} U(\hat{\beta}^{(r)}) = \hat{\beta}^{(r)} + (\mathbf{X}^T \mathbf{W} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} \mathbf{M}(\mathbf{y} - \boldsymbol{\mu}) \quad , \quad (4.82)$$

wobei $\hat{\beta}^{(r)}$ für den Schätzwert von β in der r -ten Iteration steht. Durch $\mathcal{I}(\hat{\beta})^{-1} U(\hat{\beta})$ wird ϕ aus der Gleichung entfernt und ist somit für die Parameterschätzung nicht von Relevanz. Für $U(\hat{\beta}) \rightarrow 0$ konvergiert der Algorithmus, weitere Iterationen verändern also die Parameterschätzungen nicht mehr (über ein ausreichend kleines Maß hinaus). Da \mathbf{W} und $\mathbf{M}(\mathbf{y} - \boldsymbol{\mu})$ bzw. \mathbf{z} von β bzw. dessen/deren jeweiligem momentanen Schätzwert abhängen, werden auch ihre Werte für jede Iteration angepasst.

Die Invertierbarkeit der Fisher-Information setzt positive Gewichte voraus, was hier gegeben ist.

In umgewandelter Form unter Zuhilfenahme der sogenannten Arbeitsbeobachtungen z ergibt sich die **iterativ gewichtete KQ-Schätzung**:

$$\hat{\beta}^{(r+1)} = (\mathbf{X}^T \mathbf{W} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} \mathbf{z} \quad (4.83)$$

mit

$$z_i = \hat{\eta}_i + (y_i - \hat{\mu}_i) \frac{d\hat{\eta}_i}{d\hat{\mu}_i} \quad \text{bzw.} \quad \mathbf{z} = \hat{\boldsymbol{\eta}} + \mathbf{M}(\mathbf{y} - \hat{\boldsymbol{\mu}}) \quad (4.84)$$

Denn im Falle der maximalen Likelihood gilt: $\mathbf{X}^T \mathbf{W} \mathbf{X} \hat{\beta} = \mathbf{X}^T \mathbf{W} \mathbf{z}$.

4.4.2.5 Dispersionsparameter und Quasi-Likelihood

Die gängigste – wenn auch nicht einzige – Methode, einer Überdispersion von Poisson- und Binomialmodellen zu begegnen, ist die Anwendung einer Quasi-Likelihood-Schätzung. Diese setzt keine Fehlerverteilung voraus, sondern ist ausschließlich über das Verhältnis von Mittelwert und Varianz definiert.

Hierfür wird der Dispersionsparameter durch den generalisierten Pearson-Schätzer berechnet. Die gleiche Schätzformel findet auch für die Dispersionsparameter von Gamma-GLMs Anwendung:

$$\phi = \frac{\chi^2}{n-p} = \frac{1}{n-p} \sum \frac{(y - \hat{\mu})^2}{V(\hat{\mu})} = \frac{1}{n-p} \sum W_i (z_i - \hat{\eta}_i)^2 \quad (4.85)$$

mit der generalisierten Pearson-Statistik $\chi^2 = \sum \frac{(y - \hat{\mu})^2}{V(\hat{\mu})}$

Anschließend erfolgt die Parameterschätzung analog zum Maximum Likelihood-Verfahren mit Quasi-Score-Funktionen und Quasi-Fisher-Informationsmatrix. Hierin ist – anders als bei der MLE – der Dispersionsparameter enthalten, und zwar durch Verwendung einer angepassten Varianzfunktion (Arbeitsvarianz) $\hat{V}(\mu) = \phi V(\mu)$. Die Arbeitsgewichte W_i und so ihre Diagonalmatrix \mathbf{W} werden modifiziert, indem die Varianz- durch die Arbeitsvarianzfunktion ersetzt wird.

$$W_i = \frac{w_i}{\hat{V}(\mu_i)(d\eta_i/d\mu_i)^2} = \frac{1}{\hat{V}(\mu_i)(d\eta_i/d\mu_i)^2} = \frac{1}{\phi V(\mu_i)(d\eta_i/d\mu_i)^2} \quad (4.86)$$

Hierdurch ändern sich im Vergleich zum regulären GLM nicht die geschätzten Koeffizienten, jedoch deren Standardfehler.

4.4.3 Prädiktorenvorbereitung

4.4.3.1 Prädiktorvariablen

Wie bereits in Kapitel 1.2.2 angesprochen, wird das regionale Klima und seine Extreme sowohl dynamisch als auch thermodynamisch geprägt. Dabei spielen großräumige, synoptische Prozesse ebenso wie kleinräumige Einflussfaktoren eine Rolle. Um also die physikalische Entstehung der regionalen klimatischen Kennwerte widerzuspiegeln, sollten die verwendeten Prädiktoren dies repräsentieren.

KEUPP *et al.* (2019) simulieren in ihrer Studie Niederschlagsextreme (R1mmn, MCD, R95n sowie die Niederschlagssummen aus R95n-Tagen) durch Perfect Prog-Downscaling. Hierbei finden dynamische (geopotenzielle Höhe, meridionale und zonale Windgeschwindigkeitskomponente je in versch. Luftdruckniveaus, Luftdruck auf Meereshöhe) sowie thermodynamische Prädiktoren (relative und spezifische Feuchtigkeit in versch. Luftdruckniveaus) Anwendung (vgl. auch CAVAZOS & HEWITSON 2005; HERTIG *et al.* 2014; SACHINDRA *et al.* 2014). Kli-

Modelle zeigen, verglichen zum Wasserkreislauf, meist eine deutlich bessere Performance im Bezug auf die atmosphärische Zirkulation und thermodynamische Prozesse (siehe Kapitel 1.2, vgl. auch PAETH 2011), weshalb in genannter Arbeit nicht-hydrologische Prädiktoren eingesetzt werden. Da (anders als in KEUPP *et al.* (2019)) hier jedoch kein Perfect-Prog-Downscaling durchgeführt, besteht nicht die Annahme perfekt simulierter Prädiktoren (vgl. MARAUN & WIDMANN 2018). Es kann also auch der Zusammenhang zwischen nicht perfekt simulierten Modellprädiktoren und beobachteten Variablen in die Simulation mitaufgenommen werden. Deshalb werden neben den genannten (relative Luftfeuchtigkeit ist für REMO nicht verfügbar) weitere atmosphärische und zusätzliche bodennahe Prädiktoren in die Modellierung einbezogen. Dies sind zum Einen thermische (verschiedene Aspekte der Lufttemperatur, sensible Wärmeflüsse), thermodynamische (latente Wärmeflüsse, Evaporation), aber auch hydrologische und niederschlagsabhängige Größen (Niederschlag, Abfluss, Bodenfeuchte) sowie Bewölkung und Windgeschwindigkeit. Diese bodennahen Variablen sind zum Einen das Ergebnis großräumiger atmosphärischer Bedingungen, spiegeln aber gleichzeitig Oberflächenprozesse auf kleinräumiger Ebene wider und sind daher wichtige Bestandteile der regionalen Klimadynamik.

Während für die klimatischen (Extrem-)Indizes einschließlich Spätfrost sowohl (höher) atmosphärische als auch bodennahe Prädiktorvariablen Verwendung finden, werden für die Simulation der Ertragszahlen ausschließlich bodennahe Variablen (inkl. Wolkenbedeckung) zugelassen. Dies ist dadurch begründet, dass das Auftreten von Wetterextremen direkt durch atmosphärische Einflüsse mitbestimmt wird, während diese auf die Erträge nur indirekt über bodennahe Prozesse einwirken. In Tabelle 4.4 sind die verwendeten möglichen Prädiktorvariablen aufgeführt.

Die Anzahl der gelisteten Variablen mag sehr groß und redundanzbehaftet wirken. Im Abschnitt 4.4.4 wird erläutert, wie diese Redundanzen verringert werden, während diejenigen Prädiktoren mit größtem Zusammenhang zum jeweiligen Prädiktanden erhalten bleiben. Da es sich bei den betrachteten Prädiktanden um klimatische (oder landwirtschaftliche) Kennwerte handelt, die durch ein komplexes Zusammenspiel vieler Faktoren bedingt werden, wurde bewusst eine große Auswahl möglicher Prädiktoren gewählt.

Um sowohl die synoptische als auch die regionale Raumskala zu integrieren, gehen die genannten Prädiktorvariablen in Anlehnung an PAETH (2011) auf zwei unterschiedliche Arten in die jeweilige Regressionsanalyse ein: In Form von Hauptkomponenten über das gesamte CORDEX EUR11-Gebiet (Europa) sowie als lokale Prädiktoren in einem 3×3 -Fenster um die jeweils be-

Tabelle 4.4: Verwendete Prädiktorvariablen (Indizes inkl. Spätfrost, LW Landwirtschaft inkl. Frankenwein).

| Variable | Kürzel | Indizes | LW |
|------------------------------------------------|---------------|----------------|-----------|
| Luftdruck auf Merreshöhe | psl | × | × |
| Niederschlag | pr | × | × |
| Evaporation am Boden | evspsbl | × | × |
| Bodennahe Lufttemperatur (2 m) | tas | × | × |
| Tagesmaximum bodennaher Lufttemperatur | tasmax | × | × |
| Tagesminimum bodennaher Lufttemperatur | tasmin | × | × |
| Bodennahe spezifische Luftfeuchtigkeit | huss | × | × |
| Wolkenbedeckung | clt | × | × |
| Latente Wärmeflüsse von der Oberfläche | hfls | × | × |
| Sensible Wärmeflüsse von der Oberfläche | hfss | × | × |
| Gesamtabfluss | mrro | × | × |
| Oberflächenabfluss | mrros | × | × |
| Bodenfeuchte | mrso | × | × |
| Bodennahe Windgeschwindigkeit (10 m) | sfcWind | × | × |
| Tagesmax. der bodennahen Windgeschwindigkeit | sfcWindmax | × | × |
| Bodennaher u-Wind (ostwärtige Windkomponente) | uas | × | × |
| Bodennaher v-Wind (nordwärtige Windkomponente) | vas | × | × |
| Spezifische Luftfeuchtigkeit in 850 hPa | hus850 | × | |
| Geopotenzielle Höhe in 500 hPa | zg500 | × | |
| v-Wind in 500 hPa | va500 | × | |
| v-Wind in 850 hPa | va850 | × | |
| u-Wind in 500 hPa | ua500 | × | |
| u-Wind in 850 hPa | ua850 | × | |
| Lufttemperatur in 500 hPa | ta500 | × | |
| Lufttemperatur in 850 hPa | ta850 | × | |

trachtete Prädiktandengitterzelle. Darauf sowie auf weitere Schritte der Vorverarbeitung wird in den nächsten Abschnitten eingegangen.

4.4.3.2 Hauptkomponentenanalyse

Neben lokalen Prädiktoren (siehe 3×3 -Fenster), gehen in die MOS-Simulationen auch solche Prädiktoren ein, die großräumige Muster atmosphärischer oder bodennaher Variablen darstellen. Diese sind das Ergebnis von Hauptkomponentenanalysen der jeweiligen Klimavariablen über das gesamte CORDEX-EUR11-Gebiet.

Neben diesem Zweck – Muster bzw. atmosphärische Variabilitätsmoden herauszustellen – dient die Hauptkomponentenanalyse (engl. Principal Component Analysis, PCA) der Redundanzreduktion. Letzere basiert darauf, aus wechselseitig korrelierten Daten miteinander unkorrelierte Hauptkomponenten (Principal Components, PCs) herauszuarbeiten, die entsprechend ihrem Varianzanteil an der Gesamtvarianz absteigend sortiert werden. Die erste Hauptkomponente beinhaltet also den größten Anteil der Gesamtvarianz der Ursprungsdaten, die letzte (wobei für p in die PCA eingehende Variablen p PCs resultieren) den geringsten. Alle Hauptkomponenten stehen orthogonal aufeinander, sind also unkorreliert. Somit kann – wenn eine Dimensionsreduktion angestrebt wird – ein großer Teil der gesamten Variabilität durch deutlich weniger Variablen dargestellt werden. Je höher die ursprüngliche Korrelation, desto weniger Hauptkomponenten sind hierfür nötig (also desto mehr Varianz wird von den ersten PCs abgedeckt) (VON STORCH & ZWIERS 2003; JOLLIFFE 2002; SCHÖNWIESE 2006; BORTZ & SCHUSTER 2010).

Anders ausgedrückt: „Sie versucht in das Durcheinander von mehr oder weniger korrelierten Variablen Ordnung zu bringen.“ (DORMANN 2017)

Im vorliegenden Fall ist nicht die Dimensionsverringering, sondern die Identifikation verschiedener Variabilitätsmuster das Ziel.

Geometrisch veranschaulichen lässt sich die PCA als Drehung des Koordinatensystems der gegeneinander aufgetragenen Daten. Im zweidimensionalen Fall (z.B. Zeitreihen zweier Raumpunkte als Daten) werden also zunächst die Daten einer Variable (Datenpunkt 1) auf der x-Achse, die der anderen Variable (Datenpunkt 2) auf der y-Achse angetragen. Je nach (linearer) Korrelation der beiden ergibt sich eine Punktwolke ohne erkennbares Muster oder es ist ein linearer Zusammenhang (mit mehr oder weniger großer Streuung) erkennbar. Durch die PCA werden die Koordinatenachsen so gedreht, dass eine Achse (PC1) in Richtung der größten

Variabilität zeigt und die zweite (PC2) senkrecht darauf in Richtung der größten verbleibenden Variabilität, die nicht durch PC1 abgedeckt ist. Dass die Achsen senkrecht (= orthogonal) aufeinander stehen impliziert, dass keine Korrelation zwischen PC1 und PC2 vorliegt. Auf p Dimensionen übertragen, ergeben sich p Hauptkomponenten, die allesamt orthogonal also unkorreliert sind, und jeweils in Richtung maximaler verbleibender Varianz zeigen (DORMANN 2017; SCHÖNWIESE 2006; BORTZ & SCHUSTER 2010; WILKS 2011). Somit ist die Hauptkomponentenanalyse eine „sukzessiv varianzmaximierende, orthogonale Rotationstransformation“ (BORTZ & SCHUSTER 2010).

Die neuen Achsen – also Hauptkomponenten – sind Linearkombinationen der Ursprungsdaten. Im vorliegenden Fall ist die Datenmatrix \mathbf{X} eine $n \times p$ -Matrix, wobei n für die Anzahl der Beobachtungen (Zeitpunkte) und p für die Anzahl der betrachteten Raumpunkte ($p = nx \cdot ny$) steht.

$$\mathbf{X} = \begin{array}{c|cccc} & \text{Raum } (i = 1, \dots, p) & & & \\ \hline & & & & \\ \mathbf{X} = & \left(\begin{array}{cccc} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n3} & \dots & x_{np} \end{array} \right) & & & \\ & & & & \text{Zeit } (t = 1, \dots, n) \end{array}$$

Die $n \times p$ -Matrix der Hauptkomponenten \mathbf{U} ergibt sich als:

$$\mathbf{U} = \mathbf{E}^T \mathbf{X} \quad \text{bzw.} \quad u_m(t) = \sum_{i=1}^p e_{i,m} x_i(t) \quad (4.87)$$

mit der $p \times p$ -Rotationsmatrix \mathbf{E} .

Die Rotationsmatrix \mathbf{E} enthält also die Gewichte (Ladungen), mit der die Originaldaten in die Hauptkomponenten eingehen. Sie wird auch Orthogonalmatrix genannt und muss die Voraussetzung erfüllen, dass durch sie eine orthogonale Rotationstransformation mit fortlaufender Varianzmaximierung gewährleistet wird. Dies ist gegeben, wenn \mathbf{E} die Matrix der nach den entsprechenden Eigenwerten λ absteigend sortierten (auf Einheitslänge skalierten) Eigenvektoren \mathbf{e} der Korrelationsmatrix²² \mathbf{R} von \mathbf{X} ist (JOLLIFFE 2002; WILKS 2011; SCHÖNWIESE 2006; BORTZ & SCHUSTER 2010; DORMANN 2017):

²²Dies entspricht einer Kovarianzmatrix der standardisierten Variablen (WILKS 2011; BORTZ & SCHUSTER 2010; DORMANN 2017). Eine Kovarianzmatrix der rohen Daten wäre ebenfalls möglich, was jedoch denjenigen Spalten mit größerer Varianz mehr Gewicht verleiht (WILKS 2011; DORMANN 2017)

Die Korrelationsmatrix \mathbf{R} ($p \times p$) enthält die Produkt-Moment-Korrelationskoeffizienten (r_p siehe Kapitel 4.1.1) der p Variablen (Raumpunkte) über deren t Ausprägungen (Zeitschritte):

$$\mathbf{R} = \begin{pmatrix} r(x_1, x_1) = 1 & r(x_1, x_2) & \dots & r(x_1, x_p) \\ r(x_2, x_1) & r(x_2, x_2) = 1 & \dots & r(x_2, x_p) \\ \vdots & \vdots & \ddots & \vdots \\ r(x_p, x_1) & r(x_p, x_2) & \dots & r(x_p, x_p) = 1 \end{pmatrix}$$

Zur Berechnung der Eigenvektoren werden zunächst die Eigenwerte λ der quadratischen Matrix \mathbf{R} benötigt:

$$\det(\mathbf{R} - \lambda \mathbf{I}) = 0 \quad (4.88)$$

mit Einheitsmatrix \mathbf{I}

$$\mathbf{I} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{pmatrix}$$

Die p Eigenvektoren \mathbf{e} ergeben sich aus:

$$\begin{aligned} \mathbf{R}\mathbf{e} &= \lambda\mathbf{e} \\ (\mathbf{R} - \lambda\mathbf{I})\mathbf{e} &= 0 \end{aligned} \quad (4.89)$$

Hierbei gilt $\mathbf{e} \neq 0$ und $\|\mathbf{e}\| = \sqrt{\mathbf{e}^T \mathbf{e}} = \sqrt{\sum_{i=1}^p e_i^2} = 1$ (Einheitslänge²³) (WILKS 2011, vgl. SCHÖNWIESE 2006).

Aufgrund der Einheitslänge von \mathbf{e} und der Symmetrie von \mathbf{R} ($r_{ji} = r_{ij}$) gilt $\mathbf{e}_i^T \mathbf{e}_j = 0$ (für $i \neq j$, ansonsten $\mathbf{e}_i^T \mathbf{e}_i = 1$). Dies bedeutet, dass die entsprechenden Hauptkomponenten **orthogonal** sind (WILKS 2011; BORTZ & SCHUSTER 2010).

Die **Varianzmaximierung** wird dadurch sichergestellt, dass die Eigenvektoren (auch Empirische Orthogonalfunktionen, EOF, genannt) nach der Größe der Eigenwerte, die gleichzeitig ihrer Varianz entspricht, sortiert werden (JOLLIFFE 2002; WILKS 2011; BORTZ & SCHUSTER 2010; DORMANN 2017).

²³Hierdurch existiert eine, bis auf das Vorzeichen, eindeutige Lösung

Die Rotationsmatrix \mathbf{E} enthält somit die sortierten Eigenvektoren \mathbf{e} als Spaltenvektoren:

$$\mathbf{E} = \begin{pmatrix} \mathbf{e}_1 & \mathbf{e}_2 & \dots & \mathbf{e}_p \end{pmatrix}$$

Zusammengefasst stellen die Hauptkomponenten also Linearkombinationen der Ursprungsdaten dar, wobei die Koeffizienten den nach absteigenden Eigenwerten geordneten Eigenvektoren (EOFs) der Korrelationsmatrix der Ursprungsdaten entsprechen (PCA mit Datenstandardisierung, ansonsten Kovarianzmatrix) (WILKS 2011; DORMANN 2017). Wird, wie hier, die $p \times p$ -Korrelationsmatrix verwendet, spricht man von einer S-mode PCA (im Gegensatz zur T-mode PCA mit $n \times n$ -Korrelationsmatrix auf Basis einer transponierten $p \times n$ -Datenmatrix \mathbf{X}^T) (WILKS 2011).

Aufgrund der unterschiedlichen Repräsentanz niedrigerer und höherer Breiten²⁴ wird eine Kosinusgewichtung durchgeführt. Das Gewicht w_i wird dabei berechnet als $w_i = \frac{\cos \phi_i}{\sum \cos \phi}$, mit Breitengrad ϕ .

Um möglichst viele existente Variabilitätsmuster abzubilden (also viele Informationen zu erhalten), werden die ersten 20 Hauptkomponenten verwendet. Für höhere PCs wird von einem geringen reellen Informationsgehalt ausgegangen (Rauschen)(vgl. PAETH 2011).

Diese erläuterte Hauptkomponentenanalyse mit Korrelationsmatrix und Breitengradabhängiger Kosinusgewichtung wird separat für jeden Monat und jede mögliche Prädiktorvariable durchgeführt. Wie bei der Vorstellung der Beobachtungsdaten (3.1) genannt, sind die vorhandenen Zeitreihen für die Erträge aus Landwirtschaft (1983–2012) und Weinbau (1994–2012) kürzer als für die klimatischen Zielgrößen (1980–2012). Um die vorherrschenden Varianzmustern in den betrachteten Zeiträumen abzubilden, erfolgt die PCA daher in mehreren Varianten:

- Gesamtzeitraum 1979–2012 (für alle Prädiktorvariablen, Januar erst ab 1980 verfügbar)
- Landwirtschaftszeitraum 1982–2012²⁵ (für Landwirtschaftsprädiktoren)
- Weinbauzeitraum 1993–2012²⁶ (für Weinbauprädiktoren, Begrenzung auf 19 PCs wegen Datenlänge von 19 Jahren)

²⁴Die Länge eines Längengrades skaliert mit dem Cosinus des Breitengrades, nimmt also vom Äquator in Richtung Pole ab. Somit werden polnähere Gebiete im Modell überrepräsentiert.

²⁵In Übereinstimmung mit dem in Abschnitt 4.4.3.4 erläuterten Zeitversatz werden die Zeiträume für Januar–Juli auf 1983–2012 und für Oktober–Dezember auf 1982–2011 verkürzt

²⁶In Übereinstimmung mit dem in Abschnitt 4.4.3.4 erläuterten Zeitversatz: 1993–2011 für November und Dezember, 1994–2012 für die übrigen Monate

Bei der Aufstellung der Datenmatrix finden etwaige Nullvarianz-Gitterzellen gesonderte Beachtung: Ist an einem Gitterpunkt keine Varianz vorhanden (z.B. keinerlei Niederschlag und daher auch keine Variation in Teilen der Sahara) wird dieser aus der PCA ausgeschlossen.

4.4.3.3 Fenster

Um einem möglichen räumlichen Versatz (PAETH 2011) sowie etwaigen topographiegeschuldeten räumlichen Fehlern (EDEN *et al.* 2014b) Rechnung zu tragen, werden für die lokalen Prädiktoren nicht nur der eine nächstgelegene Gitterpunkt, sondern die neun nächsten Zellen betrachtet (anschließend 3×3 -Fenster genannt). Dies sind diejenigen Zellen y deren Euklidische Distanz $d(x, y)$ zur betrachteten Prädiktandenposition am geringsten sind. Die Berechnung von $d(x, y)$ erfolgt nach WILKS (2011):

$$d(x, y) = \sqrt{(\phi_x - \phi_y)^2 + (\lambda_x - \lambda_y)^2} \quad (4.90)$$

mit Breitengrad ϕ und Längengrad λ .

Diese Definition der Fenster gilt jedoch nur für die Klimaindizes (inkl. Spätfrost), da hier die Prädiktanden in Form einzelner Gitterzellen der REMO-Daten (auf CORDEX EUR11-Gitter) vorliegen.

Die landwirtschaftlichen Ertragsdaten sind jeweils einem Landkreis in Unterfranken zugeordnet. Da die aus GEOBASIS-DE (2017) extrahierten Landkreisgrenzen eine hohe Heterogenität aufweisen, werden zunächst alle EUR11-Gitterzellen (mit Mittelpunkt) innerhalb des jeweiligen Gebietes ausgewählt (siehe Abbildung 3.1). Um diese werden dann wiederum die oben beschriebenen 3×3 -Fenster gelegt und alle Redundanzen je Landkreis entfernt.

Für die Weinerträge liegt ein Wert für das gesamte Frankenweingebiet vor. Daher werden um die Koordinaten jeder Frankenweingemeinde (jede der 139 Gemeinden durch einen Punkt in Abbildung 3.2 dargestellt) die neun nächstgelegenen EUR11-Gitterpunkte gesucht und die Gesamtliste anschließend hinsichtlich Mehrfachnennungen bereinigt.

4.4.3.4 Zeitversatz

Da Ernteerträge (LW, FW), aber auch klimatische Kenngrößen (Indizes inkl. Spätfrost) von Vorgängen in der Vergangenheit beeinflusst werden, gehen Prädiktoren verschiedener Zeitpunkte in die Analyse ein.

Für die Klimaindizes findet ein Zeitversatz von 0 bis -11 Monaten Anwendung. Gleiches gilt für den Spätfrost, wobei der Juni als letzter in Betracht kommender Monat als Referenz gilt.

Hinsichtlich der LW-Erträge werden die verwendeten Zeiträume anhand der üblichen Saat- und Erntetermine gewählt (RAUH 2020), wie in Tabelle 4.5 aufgeführt.

Tabelle 4.5: Saat- und Erntekalender (-1 steht für das Vorjahr der Ertragszahl).

| Feldfrucht | Aussaat | Ernte |
|--------------|----------------|-----------|
| Hafer | März | August |
| Silomais | April | September |
| Sommergerste | März | August |
| Wintergerste | September (-1) | Juli |
| Winterraps | August (-1) | August |
| Winterweizen | September (-1) | August |

Analog reichen die möglichen Prädiktorenwerte der Frankenweinerträge vom November des Vorjahres bis zum Oktober des Erntejahres (BOCK *et al.* 2011).

4.4.4 MOS REMO-Eval

4.4.4.1 MLR oder GLM?

In den Kapiteln 4.4.1 und 4.4.2 wurden miteinander verwandte Verfahren vorgestellt, die jedoch unterschiedliche Anforderungen an die behandelten Daten mit sich bringen. Sowohl PRUSCHA (2006) als auch FAHRMEIR *et al.* (2009) empfehlen zunächst die Durchführung einer MLR mit anschließender Prüfung der Voraussetzungen (die sich ja größtenteils auf die Residuen beziehen, also nicht einfach anhand des Prädiktors zu kontrollieren sind) in Form visueller Verfahren. Von der ausschließlichen Verwendung statistischer Tests zur Diagnose wird abgeraten (vgl. KASPAR-OTT *et al.* 2019, wo eine rechnerische Residuenuntersuchung durchgeführt wird). Diese Empfehlung ist insofern problematisch, als dass die hier untersuchten Prädiktoren einen vieldimensionalen Raum aufspannen:

- Monatliche Klimaindizes: Sieben Indizes mit jeweils zwölf Monaten und 720 Gitterzellen:

$$n = 7 \times 12 \times 720 = 60480$$

- Spätfrost: Zwei Indizes mit je 720 Gitterzellen: $n = 2 \times 720 = 1440$

- Landwirtschaftserträge: Sechs Feldfrüchte für je zwölf Landkreise: $n = 6 \times 12 = 72$
- Frankenweinerträge: Drei Unterteilungen für je das gesamte Frankenweingebiet: $n = 3$.

Es müssten somit 61995 Residualplots (und evtl. weitere Plots je Situation) untersucht werden. Da dies kaum realisierbar ist, werden gemäß dem Vorschlag von DORMANN (2017) unterschiedliche Regressionsmodelle je Situation aufgestellt und hinsichtlich ihrer Güte verglichen. Anders ausgedrückt:

„The best model is the model that produces the least unexplained variation“
(CRAWLEY 2013)

Es werden also für alle Kennwerte (inkl. Ertragsdaten) multiple lineare Regressionen und GLM-Regressionen durchgeführt. Für die Indizes inkl. Spätfrost werden vor der eigentlichen GLM-Aufstellung Modelle mit möglichen EDMs und Linkfunktionen (ohne Bootstrapping s.u.) berechnet und anhand von RMSE, AIC²⁷ sowie dem Verhältnis aus Devianz und Nulldevianz²⁸ die am besten zu den jeweiligen Daten passende EDM-Link-Kombination gewählt. Aufgrund der geringeren Dimensionalität der Landwirtschafts- und Frankenweinertragsdaten werden hierfür im Rahmen der unten beschriebenen Durchführung mögliche EDM-Link-Kombination getestet und zusammen mit den anderen Varianten evaluiert.

Wie bereits im vorangegangenen Kapitel 4.4.2 genannt, kommen folgende GLM-Varianten zum Einsatz:

²⁷Akaike's Information Criterion $AIC = -2l(\hat{\beta}_{1-p}; y, \phi) + 2p$, mit $l(\hat{\beta}_{1-p}; y, \phi)$ maximale log-Likelihood (also Likelihood bei Verwendung aller Parameter des Modells) und p Anzahl unbekannter Parameter. Bei unbekanntem Dispersionparameter ϕ wird dessen MLE-Schätzer verwendet und als weiterer unbekannter Parameter behandelt, also $p + 1$ statt p verwendet. Die Einbindung der Anzahl der Modellparameter führt dazu, dass Modelle mit einer höheren Prädiktorzahl bei gleicher log-Likelihood höhere (=schlechtere) AIC-Bewertungen erhalten (AKAIKE 1974; FAHRMEIR *et al.* 2009; CRAWLEY 2013; DUNN & SMYTH 2018).

²⁸Die Devianz D ist dabei definiert als: $D = -2[l(\mu, y) - l(y, y)]$, mit $l(\mu, y)$ log-Likelihood des untersuchten Modells und $l(y, y)$ log-Likelihood des gesättigten, also perfekten, Modells. Je niedriger die Devianz, desto besser das Modell. Die Nulldevianz entspricht dem Modell ohne Prädiktoren, also nur einem Mittelwert. Das Verhältnis zeigt somit die Güte des Modells im Vergleich zur reinen Mittelwertverwendung. Je niedriger der Wert, desto höher ist der Mehrwert des jeweiligen Modells im Vergleich zum Nullmodell (MCCULLAGH & NELDER 1989; CRAWLEY 2013; FAHRMEIR *et al.* 2009; vgl. DUNN & SMYTH 2018).

- MCD (Zähl­daten ohne obere Begrenzung): Poisson-GLM mit log-Link oder Quadratwurzel-Link
- R1mmn, R95n, Frosttage, Eistage, Hitzetage, Spätforst VPT und VPM (Zähl­daten mit oberer Begrenzung): Binomial-GLM mit logit-, probit- oder komplementärem log-log-Link
- DMI: Gauß-, Gamma- oder inverses Gauß-GLM, jeweils mit log-Link²⁹
- Erträge aus Landwirtschaft und Weinbau: Wie DMI, allerdings unter Einschluss von inversen Gauß-GLMs mit $\frac{1}{\mu^2}$ -Linkfunktionen.

4.4.4.2 Optionen

Die MLR-Regression wird in verschiedenen Varianten und Kombinationen davon durchgeführt (vgl. PAETH 2011; PAETH & HENSE 2003):

- Ohne weitere Verarbeitungen
- preco oder preco07: Absolute Korrelation zwischen den Prädiktoren $|r_p| < 0,5$ (preco) bzw. $|r_p| < \sqrt{0,5}$ (siehe 4.4.4.3)
- ztrans2: Standardisierte Prädiktoren (bzgl. Gesamtzeitraum)
- pcalw bzw. pcaf w: PCs aus PCA mit datenspezifischem Zeitraum für LW bzw. FW (siehe Abschnitt 4.4.3.2)
- Unterschiedliche Unterteilung Zeitraum
- Nur für MLR: Manuelle Wertebereichsbegrenzung der Ergebnisse wie in Abschnitt 4.3.4, LW und FW nicht-negativ.

Nur die (jeweils zusammengefasst für Indizes, Spätfrost) beste Variante wird zusätzlich mit jeweils auf die Prädiktandendaten passend erscheinenden GLMs (vgl. Abschnitt 4.4.2) wiederholt³⁰.

²⁹Gauß-GLMs mit Identity-Link (keine Begrenzung auf positive Werte) sind durch MLR abgedeckt; Gamma-GLMs mit inverser Linkfunktion (keine Begrenzung auf positive Werte) wurden ebenfalls in Betracht gezogen; wurden aber nie als beste Variante gewählt; inverse Gauß-GLMs mit $\frac{1}{\mu^2}$ -Linkfunktionen bringen Einschränkungen mit sich und können je nach Prädiktorenkonstellation ungültige Werte hervorrufen, da $\mu = h(\eta) = \frac{1}{\sqrt{\eta}}$. Dies war für den DMI häufig der Fall, so dass diese GLM-Art verworfen wurde.

³⁰Der Grund für dieses Vorgehen ist pragmatischer Natur: Die Berechnung der GLMs erfolgt mit der Statistiksoftware R und benötigt deutlich mehr Zeit als die MLR-Berechnungen, welche in Fortran programmiert werden.

Für die Wahl der besten Optionskonstellation werden Punkte für folgende Kriterien vergeben (jeweils ausschließlich für den unabhängigen Kontrollzeitraum):

- MSSS = Maximum aller Methoden (monatlich aufgelöst), Summe je Methode über alle Indizes (und Monate)
- R^2 = Maximum aller Methoden (monatlich aufgelöst), Summe je Methode über alle Indizes (und Monate)
- Mittleres MSSS über alle (Monate und) Indizes = Maximum aller Methoden
- Mittleres R^2 über alle (Monate und) Indizes = Maximum aller Methoden
- Positiver MSSS, Summe über alle Indizes (und Monate)

Hierbei finden für die Klimaindizes inkl. Spätfröste räumlich gemittelte MSSS- und R^2 -Werte Verwendung. Anschließend wird sowohl die Summe der jeweiligen Summen als auch das Produkt der Summen betrachtet und die Optionenkombination(en) mit den höchsten Werten weiterverwendet.

Für Landwirtschafts- und Frankenweinerträge werden je Situation alle möglichen genannten Optionen durchgeführt und anschließend die beste (Mittelwert aus MSSS und R^2) selektiert.

4.4.4.3 Durchführung

Die Model Output Statistics werden in einer kreuzvalidierten schrittweisen multiplen Regression (hier sind MLR und GLM gemeint) mit Vorwärtsauswahl (Forward Selection) durchgeführt (vgl. PAETH 2011; PAETH & HENSE 2003). Hierbei wird (soweit hinsichtlich des Prädiktanden vorhanden) jeder Monat und jede Gitterzelle einzeln betrachtet. Die folgenden Erläuterungen gelten in gleicher Weise für MLR- und GLM-basiertes MOS. Jedoch werden aufgrund der Nicht-Annahme der Normalverteilung für GLM immer Rangkorrelationen nach Spearman ($r = r_s$) berechnet, während für MLR Pearson-Produktmomentkorrelationen ($r = r_p$) Anwendung finden.

Prädiktorenbegrenzung Wie von PAETH (2011) vorgeschlagen, gehen nur diejenigen Prädiktoren (vorverarbeitete PCs und lokale 3×3 -Fenster) in die weitere Analyse ein, die auf den Gesamtzeitraum bezogen eine signifikante Korrelation zum Prädiktanden aufweisen ($\alpha < 0,05$). Des Weiteren findet eine Redundanzreduktion statt, in dem die Korrelation zwischen

den Prädiktoren untersucht wird (vgl. KEUPP *et al.* 2019; KASPAR-OTT *et al.* 2019). Liegt (über den jeweiligen Gesamtzeitraum) eine absolute Korrelation von $|r| \geq 0,5$ (oder optional $|r| \geq \sqrt{0,5}$) vor, so wird derjenige Prädiktor verworfen, der einen schwächeren Korrelationskoeffizienten zum Prädiktanden aufweist. Durch dieses Vorgehen wird zusätzlich einer Multikollinearität entgegengewirkt (vgl. 4.4.1.3, S. 57, DUNN & SMYTH 2018; VON STORCH & ZWIERS 2003).

Kreuzvalidierung Um auch für Zukunftssimulationen robuste Ergebnisse zu erhalten, Überanpassungen zu vermeiden und möglichen Instationaritäten der Prädiktoren-Prädiktand-Beziehung Rechnung zu tragen, wird eine Kreuzvalidierung durchgeführt. Hierfür erfolgen die Berechnungen der schrittweisen multiplen Regression (s.u.) in einem Bootstrapping-Verfahren mit $n = 1000$ Iterationen (vgl. KEUPP *et al.* 2019; KASPAR-OTT *et al.* 2019; PAETH & HENSE 2003; PAETH 2011; HERTIG & JACOBET 2015; MARAUN & WIDMANN 2018; WILKS 2011). Dabei wird der insgesamt verfügbare Zeitraum zweimal unterteilt.

$$\text{Gesamtzeitraum} = \underbrace{\text{Kalibration} + \text{Validierung}}_{\text{Training}} + \text{Kontrolle}$$

Der Kontrollzeitraum ist fest definiert (letzte nk Jahre des Gesamtzeitraums mit Länge ng), die 1000 Kalibrations- (cal, Länge nc) und Validationszeiträume (val, Länge nv) werden durch Ziehen ohne Zurücklegen bestimmt: $\binom{ng}{nc}$ (s. Fußnote 21 (Seite 64); 1000 Durchläufe, wobei kein Zeitraum doppelt vorkommen darf). Wie erwähnt werden verschiedene Varianten zur Einteilung der Zeiträume durchgeführt³¹. Tabelle 4.6 zeigt die jeweiligen Einteilungen:

Innerhalb des Bootstrappings wird der jeweilige Kalibrationszeitraum zum Modellfitting verwendet. Daraus werden dann für den dazugehörigen Validationszeitraum unabhängige Simulationen erstellt, um die Modellgüte zu bestimmen (s.u.).

Schrittweise multiple Regression Die schrittweise Regression mit Vorwärtsauswahl zielt darauf ab, ein möglichst gutes Modell mit möglichst wenigen Prädiktoren aufzustellen. Letzteres ist wichtig, um Überanpassung (engl. overfitting) zu vermeiden. Hierbei wird mit einem

³¹Aus Gründen der Rechenzeit erfolgt die Berechnung mit verschiedenen Zeiträumen nur für die MLR. Im Falle der Indizes inkl. Spätfrost wird die Zeiteinteilung 23-5-5 zudem nur für die beste der anderen oben genannten Varianten als Zusatzoption getestet, erzielt aber schlechtere Ergebnisse und wird daher nicht weiter verfolgt.

Tabelle 4.6: Anzahl der Jahre in den Kalibrations- (*nc*), Validations- (*nv*) und Kontrollzeiträumen (*nk*) der betrachteten Größen.

| Prädiktanden | nc | nv | nk |
|-------------------------|-----------|-----------|-----------|
| Indizes inkl. Spätfrost | 25 | 4 | 4 |
| | 23 | 5 | 5 |
| Landwirtschaftserträge | 20 | 5 | 5 |
| | 22 | 4 | 4 |
| Frankenweinerträge | 11 | 4 | 4 |
| | 12 | 4 | 3 |

Prädiktor (oder dem y-Achsenabschnitt, der bei null Prädiktoren dem Prädiktandenmittelwert entspricht) begonnen und das Modell nach und nach um neue Prädiktoren erweitert. Vor der Hinzunahme neuer erklärender Variablen ist stets ihr Mehrwert für die Modellgüte zu untersuchen (z.B. PAETH 2011; PAETH & HENSE 2003; GLAHN *et al.* 1972; VON STORCH & ZWIERS 2003; MARAUN & WIDMANN 2018; SCHÖNWIESE 2006; WILKS 2011). Sie steht damit im Gegensatz zur rückwärtigen Eliminierung (backward elimination), bei der zunächst ein Modell mit allen Prädiktoren aufgestellt und schrittweise der am wenigsten relevante Prädiktor entfernt wird (z.B. VON STORCH & ZWIERS 2003; MARAUN & WIDMANN 2018; WILKS 2011). Auch Kombinationsformen beider Verfahren existieren (z.B. KEUPP *et al.* 2019; KASPAR-OTT *et al.* 2019)

Die hier angewandte Vorgehensweise ist folgende (angelehnt an PAETH 2011 und PAETH & HENSE 2003):

- a) Als erster Prädiktor wird derjenige festgelegt, welche den höchsten absoluten Korrelationskoeffizienten zum Prädiktanden aufweist (Kalibrationszeitraum).
- b) Das Regressionsmodell wird für den ersten Prädiktor aufgestellt (Kalibrationszeitraum) und eine entsprechende Simulation mit den Prädiktorwerten des Validierungszeitraum durchgeführt. Für den Validationszeitraum wird der RMSE (Val-RMSE) berechnet.
- c) Als zweiter Prädiktor wird derjenige mit dem höchsten absoluten Korrelationskoeffizienten zum Residuum (siehe S. 51) aus der Regression mit dem ersten Prädiktoren gewählt (Kalibrationszeitraum).
- d) Schritt b) wird für das multiple Regressionsmodell mit den beiden gewählten Prädiktoren wiederholt

- e) Das Vorgehen wird so lange iteriert, bis das erste (lokale) Minimum des Val-RMSE auftritt. Die Prädiktoren des entsprechenden Modells werden für die jeweilige Bootstrapping-Iteration als Auswahl festgelegt.

Die Qualitätsabschätzung der jeweiligen Bootstrapping-Iteration geschieht wie für die Biaskorrektur (4.3.3) anhand eines kombinierten Gütemaßes ($skill(bs)$ für bs -te Iteration) aus den Mean Squared Skill Scores ($MSSS$, Gleichung 4.15) und Determinationskoeffizienten (R^2 , siehe 4.1.2) der Kalibrations- und Validierungszeiträume (vgl. KEUPP *et al.* 2019; KASPAR-OTT *et al.* 2019).

$$skill(bs) = MSSS_{cal} + MSSS_{val} + R_{cal}^2 + R_{val}^2 \quad , \quad (4.91)$$

wobei $sk(bs) = 0$ gesetzt wird, falls einer der $MSSS$ s negativ ist.

So wird die beste Bootstrapping-Iteration und mit ihr die beste Prädiktorenkombination ausgewählt. Für diese Prädiktoren wird dann ein Modell für den gesamten Trainingszeitraum aufgestellt und $MSSS$ sowie R^2 als Gütemaße für Trainings- und Kontrollzeitraum berechnet. $MSSS$ und R^2 des unabhängigen Kontrollzeitraums werden als Indikatoren für die Modellgüte hinsichtlich MOS REMO-Eval verwendet.

4.4.5 Übertragung MOS auf REMO-MPI-Prädiktoren

Simulierte Hauptkomponenten Die REMO-MPI-Hauptkomponenten werden nicht berechnet, sondern anhand der REMO-Eval-EOFs simuliert (vgl. KEUPP *et al.* 2019). Wie bei der PCA wird je Monat die Datenmatrix gebildet. Anschließend wird jedoch keine EOF-Analyse dieser Datenmatrix durchgeführt. Anstattdessen werden die Daten auf die REMO-Eval-EOFs projiziert, also eine Matrixmultiplikation durchgeführt, sodass gilt (vgl. Gleichung 4.87):

$$\mathbf{U}_{MPI} = \mathbf{E}^T \mathbf{X}_{MPI} \quad (4.92)$$

Vorverarbeitung und Durchführung Diese simulierten Hauptkomponenten ebenso wie die lokalen REMO-MPI-Prädiktoren (3×3 -Fenster) werden zunächst bezüglich der entsprechenden REMO-Eval-Daten biaskorrigiert. Hierfür findet die innerhalb der Biaskorrektur erfolgreichste Methode (QM11) Anwendung. Die Verteilungen werden hinsichtlich des Basiszeitraums 1981–

2010 (vgl. verfügbare Zeiträume, Abschnitt 3.2³²) angeglichen. Anschließend erfolgt optional eine Standardisierung der Prädiktoren auf Basis des REMO-Eval-Zeitraumes. Die Transferfunktionen aus den REMO-Eval-basierenden Model Output Statistics werden dann auf die vorverarbeiteten REMO-MPI-Prädiktoren angewandt (historischer Zeitraum und Zukunftsszenario). Diese Vorgehensweise gilt für MLR ebenso wie für GLM.

³²Falls für LW oder FW die PCA mit verkürztem Zeitraum gewählt wurde, findet das Quantilmapping der PC-Prädiktoren auf Basis der entsprechenden Zeiträume statt (1982–2011, 1983–2012 bzw. 1993–2012).

5 Klimatische Kennwerte

Bevor die Ergebnisse von Biaskorrekturen und Model Output Statistics der klimatischen Indizes dargelegt werden, erfolgt eine Gütebewertung der rohen, also unveränderten Modelldaten. Diese zeigen die Notwendigkeit der Korrektur vor der Untersuchung zukünftiger Projektionen auf.

Um die Stärken und Schwächen der Modelldaten zu verdeutlichen, werden für die Abschätzung der Rohdatenqualität Kartenabbildungen der Mittelwerte über alle Monate bzw. Quantil-Quantil-Plots gezeigt und in textlicher Form weitere Details besprochen (Abschnitt 5.1). Die sich anschließenden Ergebnisdarstellungen der unterschiedlichen Biaskorrekturverfahren (5.2) erfolgen v.a. in Form von regionalen Mittelwerten und Verteilungen der Veränderungen der zeitlichen Mittelwerte, Standardabweichungen und Verteilungen. Durch die Betrachtung der Veränderungen kann der Erfolg der jeweiligen Methode direkt erkennbar gemacht werden. Hinsichtlich der Model Output Statistics (5.3) werden zunächst die gewählten Optionen und Prädiktoren sowie die Modellgüte hinsichtlich der Simulation mit Reanalyse-getriebenen REMO-Daten dargelegt (5.3.1). Die darauf folgende Betrachtung der REMO-ESM-MOS-Ergebnisse (5.3.2) erfolgt ähnlich derer der Biaskorrektur, jedoch ohne Bezug zu Ursprungsdaten. Die Veränderungen durch die Biaskorrektur werden je Gitterzelle berechnet und anschließend gemittelt bzw. die Verteilung betrachtet. Dies ist für die MOS-Werte nicht möglich, da aufgrund der Simulation aus verschiedenen Prädiktoren mit eingebautem statistischem Downscaling keine Rohdaten als Vergleichsbasis existieren.

In der Synthese (Abschnitt 5.4) schließlich werden die Resultate zusammengefasst und verglichen, um die Methode mit den besten Korrektur- bzw. Simulationserfolgen zu bestimmen. Diese wird anschließend auf die projizierte Entwicklung der klimatischen Kennwerte im 21. Jahrhundert angewendet und die Ergebnisse untersucht.

Kartendarstellungen der monatlich aufgelösten Kennwerte finden sich in den Modellevaluierungs- und Ergebnisabschnitten (hinsichtlich der Mittelwerte über alle Monate), solche der

Spätfrosthäufigkeit im Syntheseteil³³. Erstere werden zur Vergleichbarkeit zwischen den Kennwerten mit einer einheitlichen Farbskala für alle Indizes dargestellt. Eine Beschreibung der somitunter nicht erkennbaren räumlichen Unterschiede erfolgt im Text. Es werden die gängigen Abkürzungen der Himmelsrichtungen (z.B. NW für Nordwest) verwendet.

5.1 Modellvalidierung

5.1.1 Durchschnittswerte: Prozentualer Bias der arithmetischen Mittel




Abbildung 5.1: Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: Prozentualer Bias der Mittelwerte. Karten der Mittelwerte über alle Monate je Index.

Bei der Betrachtung der über das Jahr gemittelten prozentualen Mittelwertfehler (Abbildung 5.1) zeigt sich für die Trockentage und -perioden (Anzahl R1mmn, maximale konsekutive Anzahl MCD) sowie für die Anzahl der Frosttage eine geringe prozentuale Unterschätzung der Mittelwerte (im Durchschnitt über alle Gitterzellen -6,2 %, -15,5 % bzw. -31,8 %). Am geringsten und dort z.T. in Überschätzungen übergehend sind diese in den höheren Lagen (Maxima 23,7 %, 20,4 %, -2,8 %). Ähnlich ist das Bild für die monatlichen Ergebnisse, wobei für R1mmn die stärksten regionalen Gegensätze im November und Dezember deutlich werden und in diesen Monaten der Mittelwert leicht positiv ist (3,2 % (-14,2–32,4 %) bzw. 1,7 % (-19,3–40,1 %)). Für MCD sind im Januar, Februar und Mai–August (bis -45,8 % im Juli) stärkere Unterschätzungen erkennbar, im November ist das Regionalmittel durch stärkere Überschätzungen in den höheren Lagen mit 0,1 % leicht positiv. Auch die Häufigkeit der Frosttage im April, Mai, September und Oktober ist deutlich geringer als beobachtet (bis -88,4 % im Mai;

³³Die räumlichen Differenzen sind für alle betrachteten statistischen Werte gering und werden daher in den Modellvalidierungs-, Biaskorrektur- und MOS-Kapiteln nicht gezeigt, sondern nur im Text beschrieben

in Höhenlagen z.T. geringere Abweichungen), im Januar überwiegen zu hohe Anzahlen leicht (regionales Mittel 0,5 %).

Sehr deutliche topographische Gegensätze sind hinsichtlich der Starkregentage (R95n) und des Trockenheitsindex (DMI, höhere Werte stehen für feuchtere Bedingungen) erkennbar. Die tiefer gelegenen Bereiche des Untersuchungsgebietes zeigen starke Überschätzungen (zu feucht, im Jahresmittel maximal 241,9 % bzw. 103,2 %), die höher gelegenen schwächere Unterschätzungen (zu trocken, Minima -80,1 % bzw. -48,2 %). Im regionalen Mittel werden beide Kennwerte zu hoch simuliert (entspricht zu feuchten Bedingungen, 33,6 % bzw. 16,2 %, alle Monate positiver Mittelwert). Dieses Bild spiegelt sich in allen Monaten wieder, ist allerdings im Winter stärker ausgeprägt als im Sommer (R95n), für den DMI überwiegen die positiven Abweichungen von Mai–August in größeren Teilen des Gebietes, sind aber weniger stark ausgeprägt als von Januar bis April.

Die Anzahl der jährlichen Eistage wird fast ausschließlich überschätzt (im regionalen Mittel um 74,8 % (-1,4–240,5 %)), wobei für die höher gelegenen Regionen bessere Ergebnisse sichtbar werden, als für niedrigere Regionen. Auch die Monatsbetrachtung bestätigt dies mit den stärksten Abweichungen in März und November (für Monate mit gesamter Gebietsabdeckung, Maxima 742,9 % bzw. 217,2 % wieder v.a. in tieferen Lagen). Für die Monate, in denen nur zellenweise Eistage auftreten (Apr. und Okt.), überwiegt durch hohe Maxima (beide 350 %) im Mittel eine Überschätzung. Jedoch treten für diese Monate ebenso wie für März auch zu niedrige Werte auf (Mär. (Min. -3,6 %) und April (-45,5 %) je 3, Oktober (-50,0 %) 2 Gitterzellen), jeweils am NW-Rand des im Untersuchungsgebiet befindlichen Thüringer Waldes.

Die Güte der Hitzetageerfassung unterscheidet sich insofern von allen übrigen betrachteten Kennwerten, als dass deutlichere monatliche Unterschiede erkennbar sind. Über das Jahr und das gesamte Gebiet betrachtet werden zu wenige heiße Tage simuliert (-6,3 % (-87,9–172,3 %)). Die topographische Prägung ist hierbei nicht so klar erkennbar wie für andere Variablen, zu hohe Werte treten eher im Kraichgau, am Untermain, in Wetterau und Regnitzsenke sowie im östlichsten Unterfranken auf. Werden nun die Monate (heiße Tage treten hierbei Mai–September auf) einzeln untersucht, ergeben sich für Mai und September im regionalen Durchschnitt Überschätzungen (25,2 % bzw. 78,2 %). Im Mai sind diese Überschätzungen (bis 500,0 %) in den Gebieten Wetterau, Untermain, Kraichgau, Haßberge, Grabfeld und Mittelfränkisches Becken zu finden (Regionen vgl. 2.2), in den Bereichen Frankenhöhe, Fränkische Alb und Hohenlohe sowie Teilen der Mainfränkischen Platten werden die Hitzetage unterschätzt (bis -85,7 %).

In höheren Lagen treten keine Hitzetage auf. Im September sind starke Überschätzungen (bis 640 %) v.a. in Westunterfranken, Ostunterfranken inkl. Untermain, Limburger Becken und Kraichgau erkennbar. Auch sonst überwiegen zu hohe Werte leicht. Großteile der NW-Hälfte des UGs erfahren im September keine Hitzetage (Ausnahme Mittelfränkisches Becken, Ausläufer Thüringer Becken und Vogtland). Im Juni (stärker) und im August ist die modellierte Anzahl der heißen Tage durchschnittlich zu gering (-56,9 % bzw. -27,2 %). Am schwächsten sind die Unterschätzungen im Juni in Kraichgau und Untermainebene, am hessischen Untermain werden die Häufigkeiten vereinzelt auch überschätzt. Im August sind die Abweichungen geringer und es treten häufiger leicht positive Fehler auf. Im Juli sind die Abweichungen relativ ausgeglichen (MW -4,1 %), wobei grob unterteilt in der SO-Gebietshälfte mehr negative und in der NW-Hälfte mehr positive Werte auftreten.

Die Anzahl der Spätfrosttage wird für alle Gitterzellen unterschätzt. Im Regionaldurchschnitt ist dies bei Verwendung der monatsbezogenen Vegetationsperiode stärker ausgeprägt als bei der thermischen. Die prozentualen Fehler sind für höhere Lagen schwächer. Für die thermische Vegetationsperiode (VPT) sind die Abweichungen zudem im SW des Gebietes geringer. Der mittlere Bias bzgl. VPT beträgt -68,7 %, bzgl. VPM -73,5 %. Alle Abweichungen (aller Spätfrostindizes) liegen im Betrag zwischen 25,1 % und 87,4 %.

5.1.2 Streuung: Prozentualer Bias der Standardabweichungen




Abbildung 5.2: Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: Prozentualer Bias der Standardabweichungen. Karten der Mittelwerte über alle Monate je Index.

Die Fehler hinsichtlich der über alle Monate gemittelten Standardabweichung (Abbildung 5.2) verhalten sich teilweise ähnlich derer der Mittelwerte: Für Trockentage und -perioden sowie Frosttage überwiegen negative Vorzeichen. Die R1mmn-Standardabweichung (mittlerer Bias -3,8 %) wird in den Bereichen Kraichgau-Oberheingraben-Wetterau, sowie Mittelfränkisches

Becken-Obermain besser simuliert oder überschätzt (Max. 14,2 %), in Höhenlagen finden sich die größten absoluten Fehler (Min. -33,4 %). Monatlich betrachtet liegen von Januar bis März v.a. überschätzte Standardabweichungen vor, in Höhenlagen auch unterschätzte, gleiches gilt abgeschwächt für August, September und November. Im April ist das Bild noch ausgeglichener (mit positiven Fehlern in Beckenlagen), von Mai bis Juli sowie im Oktober und Dezember ähnelt die Verteilung im Groben der des Gesamtjahres. Für die maximale Anzahl konsekutiver Trockentage (MW -18,8 %) finden sich nur sehr wenige Variabilitätsüberschätzungen (Max. 6,2 %), auch die unterschiedlichen Unterschätzungen (Min. -34,5 %) zeigen kein klares Muster. Im Januar, Mai-August, Oktober und November sind v.a. zu niedrige Standardabweichungen sichtbar. In den übrigen Monaten wird eine stärkere Differenzierung sichtbar, wobei eine topographische oder naturräumliche Verortung der überschätzten Variabilitäten nicht klar ist (Feb. diffus, Mär. tendenziell Höhenlagen und Bauland, Apr. NW-, SO- und NO-Rand, Sep. Kraichgau-Bauland, Nov. NW und Thüringer Wald).

Hinsichtlich der Frosttage zeigen sich meist geringe absolute Fehler (-4,2 % (-19,2 %–5,8 %)). Zu niedrige Standardabweichungen finden sich sowohl im Oberrheingraben, als auch in Rhön und Thüringisch-Fränkischem Wald, lassen also keine klare topographische Tendenz erkennen. Diese geringen Fehler im Gesamtjahr setzen sich zusammen aus Einzelmonaten mit klaren Vorzeichen tendenzen: Positive Dezember–Februar (mit Ausnahme einiger Höhenlagen) sowie März außer SW im Gegensatz zu negativen März (nur SW), April, Mai und Oktober (wieder mit Ausnahme einiger Höhenlagen). Nur die Novemberabweichungen sind differenzierter (Überschätzung in Großteilen Unterfrankens, am O- und NO-, sowie NW-Rand des Untersuchungsgebietes, Unterschätzungen SW bis Wetterau und westlich der Rhön).

Für die Starkregentage und den DMI liegt wie beim Mittelwertbias eine starke topographische Prägung mit zu hohen Werten (Max. 109,5 % bzw. 37,1 %) in niedrigen und zu geringen Werten (Min. -61,4 % bzw. -38,2 %) in höheren Höhenlagen vor (MW 10,0 % bzw. -2,0 %). Diese Gegensätze sind für R95n auch in den Monaten sichtbar, wenn auch von November bis März stärker ausgeprägt (höhere Abweichungsbeträge), für DMI schwimmt das Bild für die Einzelmonate zum Teil, mit stärker negativen Abweichungen im Januar, mehr positiven Abweichungen im März, April, August (letzterer v.a. Süden und Westen) und November und ausgeglicheneren Werten etwa im Dezember.

Die Standardabweichung der Hitzetage wird im regionalen Mittel gut simuliert (-0,2 % Abweichung), was sich jedoch ähnlich der Mittelwertfehler (auch bzgl. der räumlichen Verteilung)

aus Gegensätzen von Unterschätzungen (Min. -68,6) und Überschätzungen (Max. 112,9 %) zusammensetzt. Auch die monatlichen Abweichungen entsprechen im groben denen des Mittelwertbias, nur im Juli tritt eine stärkere Verbreitung von zu hohen Variabilitäten auf.

Für die Häufigkeit der Eistage simuliert REMO allgemein zu hohe Schwankungen (MW 40,8 %, Max. 118,5 %), in höheren Lagen sind die Fehler tendenziell geringer und im Thüringer Wald vereinzelt negativ (Min. -6,8 %). Letzteres wird v.a. durch den Januar bedingt, ansonsten sind hier niedrige Abweichungsbeträge erkennbar. Die stärksten prozentualen Fehler (negativen Vorzeichens) finden sich im März (SW und andere Beckenlagen) und April (wo vorhanden außerhalb des Thüringer Waldes). Diese entstehen durch die relative Betrachtung bei geringen beobachteten Häufigkeiten.

Die simulierten Standardabweichungen der Spätfrosthäufigkeit sind durchweg zu niedrig (VPT -45,3 % (-77,8 bis -4,5 %), VPM -33,0 % (-56,7 bis -1,6 %)). Bezüglich VPT werden sie im Gebiet Fränkische Alb-Haßberge-Grabfeld sowie in den Ausläufern der Thüringer Beckens und im Taunus am schlechtesten, am SW-Rand des Gebietes, am Vogelsberg sowie im Thüringer Wald am besten repräsentiert. Hinsichtlich VPM ist das räumliche Bild weniger deutlich, die schwächsten Abweichungen sind oft in höheren Lagen zu finden, das beste Ergebnis dabei im Taunus.

5.1.3 Verteilung: Prozentualer Quantil-RMSE




Abbildung 5.3: Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: Prozentualer Quantil-RMSE. Karten der Mittelwerte über alle Monate je Index.

Bei der monatsgemittelten Betrachtung (Abbildung 5.3) finden sich die geringsten prozentualen QRMSE-Werte für R1mmn (regionales Mittel 12,1 %, 6,3–25,8 %), MCD (26,4 %, 18,4–38,2 %) und DMI (34,1 %, 11,7–110,13 %). Für die beiden erstgenannten Indizes liegen die maximalen monatlichen pQRMSE-Werte (aller Gitterzellen) bei 42,4 (R1mmn Dezember) bzw.

61,6 % (MCD Juli), höhere Abweichungen treten tendenziell in niedriger gelegenen Regionen auf (nicht für alle Monate).

Für die Anzahl der Frosttage (MW 115,8 % (28,6–202,0 %)) ergeben sich in den Übergangsmo-
naten deutlich höhere Verteilungsabweichungen (April 79,4 % (26,6–102,6 %), Mai 202,7 %
(57,5–586,3 %, Werte nur in höheren Lagen im UG-Norden und -Osten), September 397,2 %
(164,8–1048,8 %, Auftreten nur in Fichtelgebirgsregion), Oktober 100,8 % (20,3–157,1 %)).

Die Regionalmaxima der Verteilungsabweichungen des DMI (außer Nov. 99,4 %) sowie der
übrigen betrachteten Kennwerte liegen sowohl für das Gesamtjahr als auch alle Einzelmonate
über 100 % (Ausnahme Eistage im Jan. max. 85,2 %).

Die größte räumliche Differenzierung mit erkennbarer topographischer Prägung ist für R95n
und DMI zu verzeichnen, mit tendenziell höheren Fehlerwerten in niedriger gelegenen Gebie-
ten. Hierbei liegen die Mittel-, Minimal- und Maximalwerte von R95n (Mittel über alle Monate
78,2 % (35,8–266,7 %)) für alle Monate über denen des DMI (s.o.). Im Winterhalbjahr treten
für beide höhere Abweichungen großräumiger auf.

Eis- und Hitzetage zeigen die größten Abweichungen tendenziell dann und dort, wo die nied-
rigsten Auftretenshäufigkeiten zu erwarten sind. Dies sind für die Eistage (MW 251,2 % (63,4–
796,0 %)) v.a. niedrigere Höhenlagen, wobei die Fehler im Januar am geringsten sind. Im März
hebt sich das Band Vogelsberg-Rhön-Thüringer Wald-Frankenwald-Fichtelgebirge mit niedrige-
ren pQRMSE-Werten ab. In diesem Monat, ebenso wie in April und November, in denen Eista-
ge nicht flächenhaft auftreten, werden Verteilungsabweichungen von bis über 1000 % registriert
(Max. 4571,7 % Mär.). Letzteres gilt auch für die Hitzetage (MW 241,8 % (59,3–1050,3 %)), für
die in den Übergangsmo-
naten Mai und September keine Ereignisse in höheren Lagen auftreten,
ansonsten aber Verteilungsabweichungen bis maximal 2872,3 bzw. 2966,5 % zu verzeichnen
sind.

Die prozentualen QRMSE-Werte der beiden Spätfrostkennwerte sind im regionalen Mittel ähn-
lich. Bei Bezug auf die thermische Vegetationsperiode (82,2 %, 41,8–112,1 %) finden sich die
niedrigsten Abweichungen im SW des Untersuchungsgebiets, kontrastierend zu höheren Ab-
weichungen in einem Keil vom Grabfeld bis in den gesamten SO. Hinsichtlich der monatlichen
Vegetationsperiode (81,9 %, 26,4–101,6 %) sind die geringsten Fehler im Bereich des Thü-
ringer und Frankenwaldes sowie der Rhön zu finden, im SW sind die Abweichungen dagegen
höher.

5.1.4 Verteilung: Q-Q-Plots

Die Abweichung der Verteilungen von Modell- und Beobachtungsdaten können (ohne räumliche Differenzierung) auch mittels Quantil-Quantil-Plots wie in Abbildung 5.4 untersucht werden. Dies liefert Rückschlüsse darauf, wie gut etwa Extrema repräsentiert werden. Mit den Beobachtungsdaten auf der x- und den Modelldaten auf der y-Achse, impliziert ein Wert unterhalb der Winkelhalbierenden eine Unterschätzung durch das Modell.

Hier wird erkennbar, dass etwa der DMI (pink) in allen Monaten außer Oktober und November auf der kompletten Verteilung überschätzt wird (zu feucht). Dies fällt bei höheren Werten stärker aus. Im Oktober werden hohe Werte unterschätzt, der übrige Bereich der Gesamtverteilung liegt nahe an den Beobachtungsdaten. Im November werden niedrige und hohe Werte eher über-, mittlere Werte unterschätzt. Für den Starkregenindex zeigt sich eine Überschätzung v.a. für höhere Werte, während niedrigere Werte nahe an den Beobachtungsdaten liegen.

Die Anzahl der Frosttage wird hinsichtlich höherer Werte gut simuliert oder leicht überschätzt, während niedrigere Werte zu gering sind. Geringe Werte (sowie in Januar und Februar sehr hohe Werte) liegen bei der Eistageanzahl nahe an den Beobachtungsdaten, ansonsten ist eine Häufigkeitsüberschätzung erkennbar. Auch für die Hitzetage werden niedrigere Werte gut angenähert, während höhere Werte in Mai, Juli und September über-, in Juni und August unterschätzt werden.

Die Simulation der Trockentagehäufigkeit ist für September und Dezember ähnlich den Beobachtungen, von Januar bis August sind die Modellierungen meist zu niedrig, wobei die Extrema z.T. näher an den Beobachtungsdaten liegen. Im Oktober zeigt sich eine Überschätzung niedriger sowie eine leichte Unterschätzung mittelhoher, im November eine Unterschätzung niedriger Werte. Für die maximale Trockenperiodenlänge liegt eine gute Simulationsqualität im niedrigen Wertebereich vor, höhere Werte werden in den meisten Monaten unterschätzt (Jan., Apr., Jun.–Dez.), im August, November und Dezember nähern sich die Modellierungen Richtung oberem Wertebereichsende den Simulationen wieder an. Insgesamt fällt der MCD durch die sehr starken Unterschätzungen im mittleren bis oberen Wertebereich einiger Monate auf.

Bei gemeinsamer Betrachtung der Werte aller Monate ergeben sich somit zu geringe Simulationswerte für R1mmn (Annäherung an Beobachtungen für höhere Werte), MCD (niedrige Werte besser, sehr hohe Werte sehr weit entfernt) und Frosttage (Annäherung an Beobachtungen für höhere Werte). Zu hoch modelliert werden R95n (deutlich zunehmende Überschätzung mit

Q-Q-Plots Monatswerte 1951–2005 vor Biaskorrektur

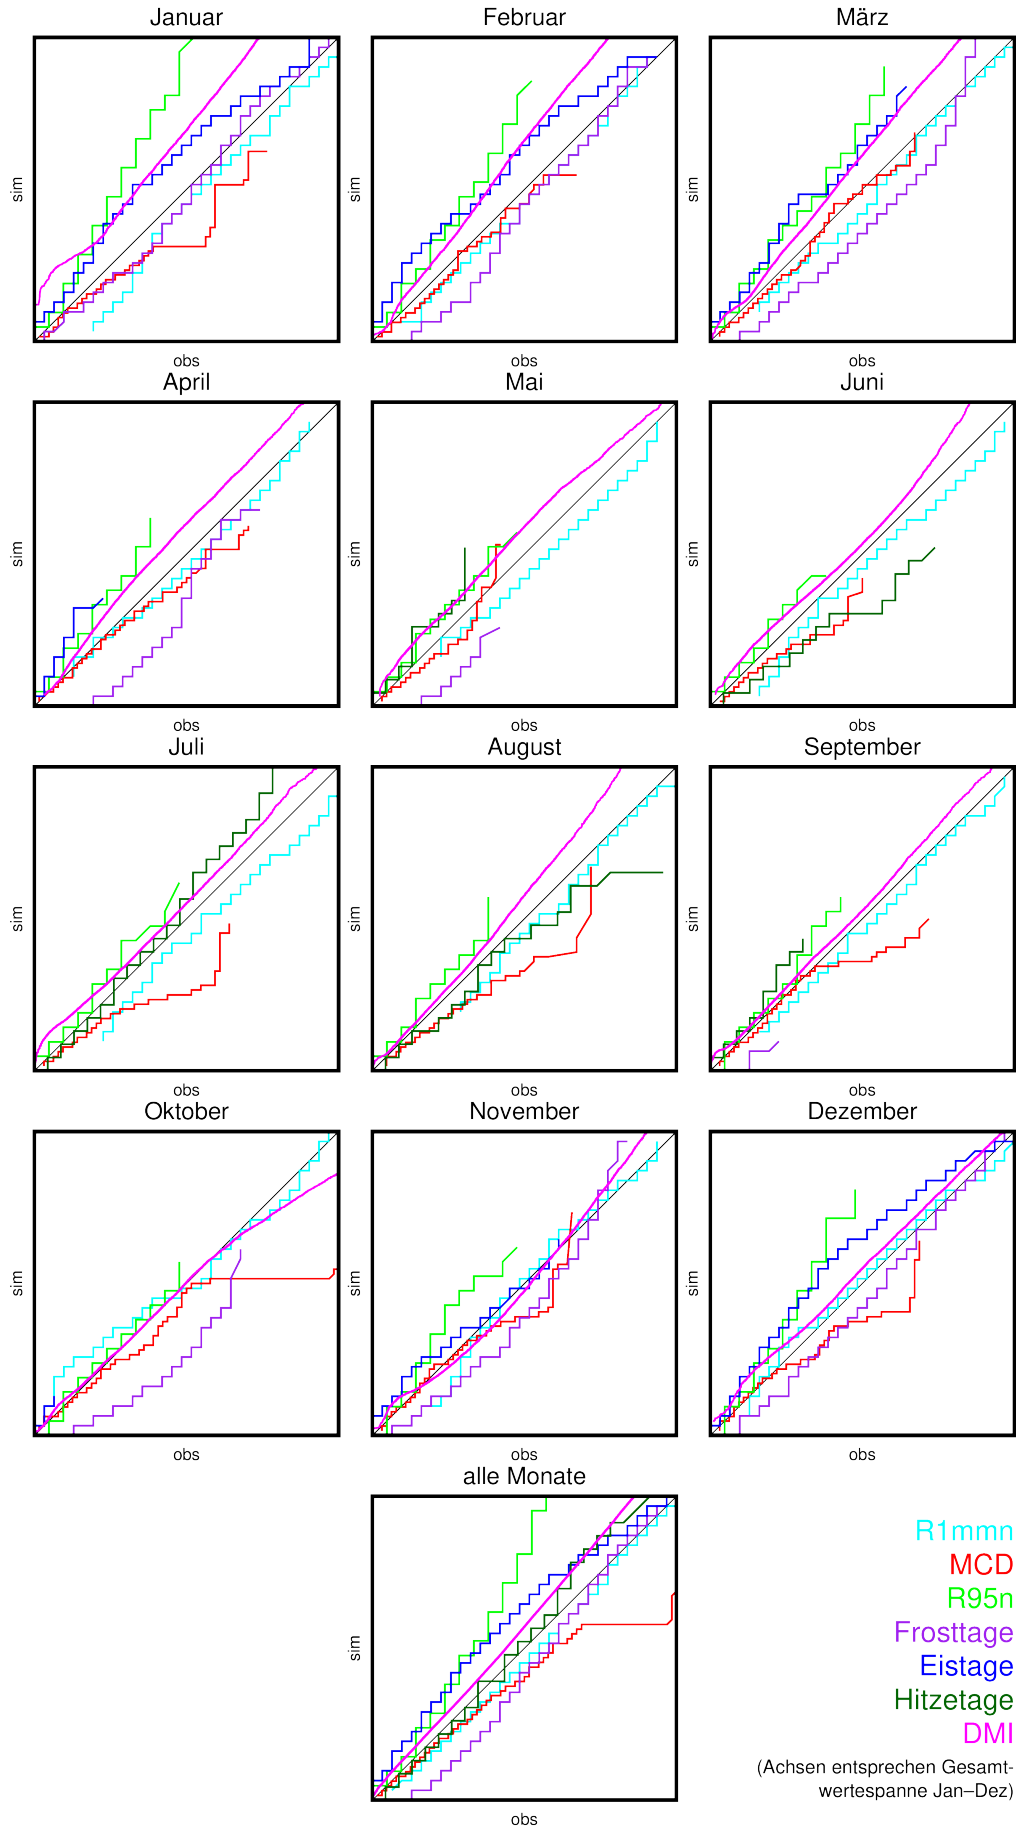


Abbildung 5.4: Modellgüte bzgl. der klimatischen Kennwerte 1951–2005: Q-Q-Plots.

zunehmenden Werten), Eistage (Extrema besser als mittlere Werte) sowie Hitzetage (niedrige Werte leicht unter-, hohe Werte überschätzt) und DMI (niedrigere Werte besser als höhere).

Die Spätfrosthäufigkeit wird – wie in Abbildung 5.5 erkennbar – für beide Varianten ausschließlich unterschätzt. Der VPT-Spätfrost wird im mittleren Wertebereich am schlechtesten, im niedrigen am besten modelliert, für VPM nähern sich höhere Werte zunächst den Beobachtungsdaten an, entfernen sich Richtung Maximum jedoch wieder.

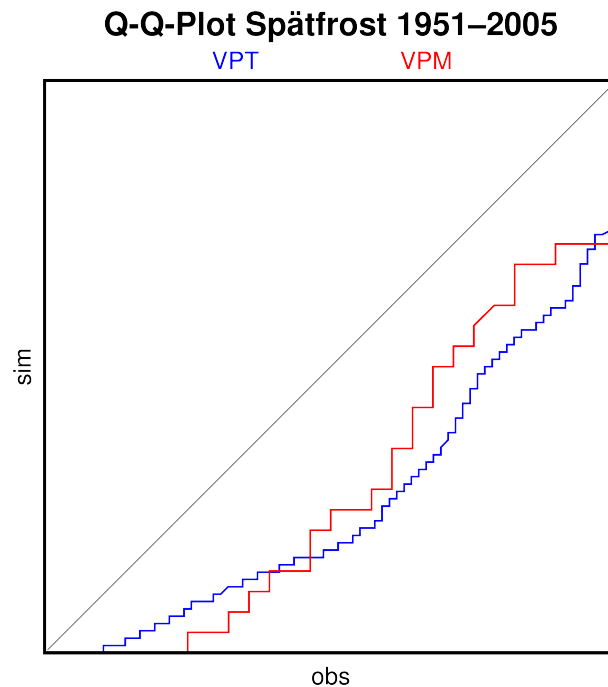


Abbildung 5.5: Modellgüte bzgl. der Spätfrosthäufigkeiten 1951–2005: Q-Q-Plots.

Die vorgestellten Ergebnisse bezüglich Mittelwert, Standardabweichung und Verteilung verdeutlichen, dass Defizite in der Repräsentation der betrachteten klimatischen Indizes bestehen. Diese zeigen sich verallgemeinert durch eine Unterschätzung der betrachteten Feuchtigkeitsverhältnisse und ihrer Variabilität in höheren sowie einer Überschätzung in niedrigeren Lagen (MCD fast überall zu niedrig). Mittelwert und Standardabweichung der Eistagehäufigkeit werden meist zu hoch simuliert, in höheren Lagen jedoch realitätsnäher. Die Anzahl der Frosttage wird meist unterschätzt, ebenso wie mit Ausnahme des südöstlichen Untersuchungsgebietes deren Standardabweichung. Auch der Spätfrost und seine Variabilität werden zu gering simuliert, für höhere Lagen (und den SW des UG für VPT) ist die Mittelwertrepräsentation etwas besser. Für die Hitzetage ist das Bild weniger klar mit Fehlern in beide Richtungen. Die Verteilungen der Temperaturkenntage weichen am stärksten von den Beobachtungen ab. Hinsichtlich R1mmn, R95n und DMI sind sie in niedrigen sowie hohen Lagen am schlechtesten, in mitt-

leren Lagen besser abgebildet. Für MCD ist das Bild unklar. Die Spätfrostverteilung wird für VPM in Rhön und Thüringer Wald, für VPT im Südwesten am besten dargestellt. Daher ist eine Korrektur der Daten vor der Untersuchung von Zukunftsprojektionen sinnvoll.

5.2 Biaskorrektur

Die folgenden Aussagen zum Erfolg der Biaskorrektur beziehen sich immer auf den jeweiligen Validierungszeitraum. Dieser ergibt sich je Kennwert, Monat, Gitterzelle und Korrekturmethode individuell, da stets diejenige der 1001 Bootstrappingiterationen mit dem dazugehörigen Kalibrierungs- und Validierungszeitraum weiterverwendet wird, die zu den besten Ergebnissen führt. Es können sich somit für dieselbe Situation (Index, Monat, Gitterzelle) unterschiedliche Abweichungen der Rohdaten von den Beobachtungswerten für jede Methode ergeben. Des Weiteren werden Gitterzellen mit $skill = 0$ für ungültig erklärt (vgl. Abschnitt 4.3.3) und für LSM solche mit Nullwerten der Beobachtungs- und/oder Modelldaten im Referenzdurchschnitt (aufgrund der Division durch Null). Im genutzten EUR11-Gitter umfasst das Untersuchungsgebiet insgesamt 373 Gitterzellen.

Für R1mmn und MCD entstehen in keinem Monat und für keine Methode ungültige Gitterzellen. Für R95n ergeben sich bei LSM-Korrektur von Oktober bis Februar teilweise keine Resultate (je max. 5 Gitterzellen), für DMI bei QM11-Korrektur für Dezember–Februar (Dez. 6, Jan. 29, Feb. 1). Für die Frost- und Eistagehäufigkeiten werden von November bis März alle möglichen Gitterpunkte von allen Methoden abgedeckt, für die Hitzetagehäufigkeiten im Juli und August. Im Gegensatz dazu können von Juni bis August keinerlei Frost-, von Mai bis September keinerlei Eis- und von Oktober bis April keinerlei Hitzetage korrigiert werden. Hinsichtlich des Frostauftretens im April und Oktober führt nur LSM zu Fehlwerten (121 bzw. 2 Gitterzellen), im Mai bleiben 38 (LSM), 51 (QM11) bzw. 70 (LS und PMPE) sowie im September 4 (LSM und QM11) bzw. 5 (LS und PMPE) gültige Werte. Für die Eistage sind es im April 55 (PMPE), 71 (LS) bzw. 72 (LSM und QM11) sowie im Oktober 3 (LSM und QM11), 4 (PMPE) bzw. 5 (LS) Gitterzellen. Die Hitzetage im Mai können an 231 (LSM, QM11), 257 (PMPE) bzw. 268 (LS) Gitterpunkten korrigiert werden, im Juni an 356 (LSM und QM11) bzw. 366 (LS und PMPE) sowie im September an 235 (PMPE), 253 (LS) bzw. 266 (LSM und QM11). Die BK der Spätfrosthäufigkeit führt nur bei LSM zu Fehlwerten, es verbleiben hierbei 372 (VPT) bzw. 164 (VPM) Werte.

Die Reihenfolge der Biaskorrekturmethoden in Text und Abbildungen unterscheidet sich zum Teil, da die multiplikative Linearskalierung erst zu einem späteren Zeitpunkt als weitere Methode hinzugenommen wurde. Sowohl für pBias MW, pBias SD als auch für pQRMSE wird je Index zunächst mit Kartendarstellungen der Durchschnittswerte über alle Monate (nicht für Spätfrost) auf die allgemeine räumliche Situation vor und nach der Korrektur eingegangen. Anschließend erfolgt eine Beschreibung der regionalen Mittelwerte und ihrer Modifikationen sowie der prozentualen Verbesserungen.

5.2.1 Durchschnittswerte: Prozentualer Bias der arithmetischen Mittel

Im regionalen Mittel führen alle BK-Methoden für alle Indizes in den meisten Monaten zu deutlichen Verbesserungen der Modelldaten. Auch ein visueller Vergleich der Fehlerkarten vor und nach der Korrekturanwendung zeigt dies (Mittel über Einzelmonate, Einzelmonate ohne Abbildung: Abbildung 5.6 im Vergleich zu Abbildung 5.1³⁴). Am wenigsten effektiv ist die Korrektur für die Anzahl der Hitzetage und hierbei für LSM (s.u., Abbildung 5.6).

Bei der Bildung regionaler Fehlermittelwerte³⁵ ist es aufgrund sich mitunter ausgleichender gegensätzlicher Fehler sinnvoll, zusätzlich die Mittelwerte der Fehlerbeträge (ohne Beachtung der Vorzeichen (VZ), nachfolgend absolut oder ohne VZ genannt³⁶) zu betrachten. Beide sind in Abbildung 5.7 für alle monatsaufgelösten Indizes hinsichtlich der jeweiligen Validierungsperioden aufgetragen. Hierbei sind die Verbesserung (als farbige Punkte) sowie die neuen Werte (als farbige Balken) gemeinsam mit dem jeweiligen Ursprungsbias (grauer Balken) dargestellt. So ist ein direkter Vergleich zwischen Ausgangsbasis und Ergebnis möglich. Aus der Abbildung wird ersichtlich, dass der regionale Biasdurchschnitt für fast alle Indizes, Monate und Korrekturmethode gesenkt werden kann (farbige Punkte > 0 , farbige Balken niedriger als graue Balken). Einige Ausnahmen hierzu ergeben sich bei Einbezug der Vorzeichen (MCD

³⁴Abbildung 5.1 bezieht sich auf den Gesamtzeitraum, die Fehlerkarten der Rohdaten im jeweiligen Validierungszeitraum (nicht gezeigt) unterscheiden sich optisch jedoch kaum. Zu beachten ist zudem die unterschiedliche Skalierung der beiden Abbildungen zur besseren Verdeutlichung der jeweiligen räumlichen Unterschiede.

³⁵Hier ist vom regionalen Mittelwert der Gitterzellenfehler die Rede, nicht vom Fehler der regionalen Mittelwerte!

³⁶Da es sich hierbei um die räumlichen Mittelwerte der absoluten prozentualen Abweichungen der zeitlichen Mittelwerte handelt und keine absoluten Abweichungen von Einzelwerten betrachtet werden, wird bewusst von der Verwendung des Begriffs der mittleren absoluten Fehler (MAE) abgesehen.

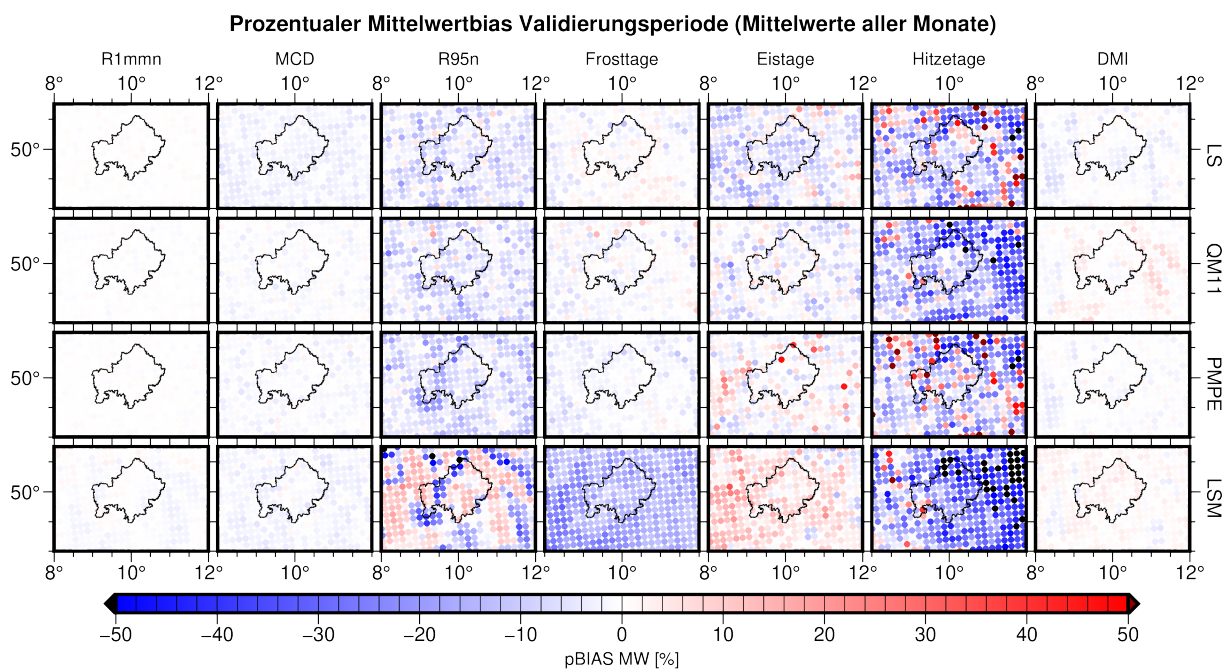


Abbildung 5.6: Modellgüte bzgl. der klimatischen Kennwerte im Validierungszeitraum nach der Biaskorrektur: Prozentualer Bias der Mittelwerte. Karten der Mittelwerte über alle Monate je Index. Werte vor der Korrektur, jedoch für den Gesamtzeitraum, siehe Abbildung 5.1.

Nov., R95n Okt., DMI Okt.) sowie für wenige Einzelsituationen. Tabelle 5.1 fasst die Ergebnisse der Abbildung 5.7 zusammen. Hierbei ist je Index die Wertespanne (in Prozentpunkten³⁷) der Einzelmonate hinsichtlich der Veränderung des regionalen Durchschnitts des prozentualen Mittelwertbias angetragen.

Die Relation des Bias der korrigierten zu dem der rohen Daten lässt sich auch ausdrücken als eine prozentuale Verbesserung (bzw. Veränderung, kurz pV) des prozentualen Mittelwertbias³⁸, was anhand der Fehlerbeträge geschieht. Hierbei ist jedoch zu beachten, dass bei der Betrachtung der prozentualen Veränderung durch die In-Relation-Setzung mit dem mitunter geringen Ursprungsbias sehr hohe negative Werte entstehen können, die den regionalen Durch-

³⁷Der prozentuale Bias besitzt keine Einheit, da diese durch die Division bei der Berechnung (siehe Gleichungen 4.20, 4.21) entfernt wird. Bei der Beschreibung der Veränderung des pBias ohne Relationierung zum Ursprungswert wird daher entweder von Prozentpunkten (PP) als Quasi-Einheit gesprochen oder keine (Quasi-)Einheit verwendet.

³⁸Beträgt der ursprüngliche Bias 0,0 %, so wird zur Ermöglichung der Division ein Bias von 1,0 % angesetzt, es sei denn der korrigierte Bias ist ebenfalls 0,0 % dann wird die prozentuale Verbesserung als 0,0 % festgelegt. Ist der korrigierte Bias – abweichend vom Rohbias – 0,0 %, so beträgt die prozentuale Verbesserung 100 %. Eine negative Verbesserung entspricht einer Verschlechterung.

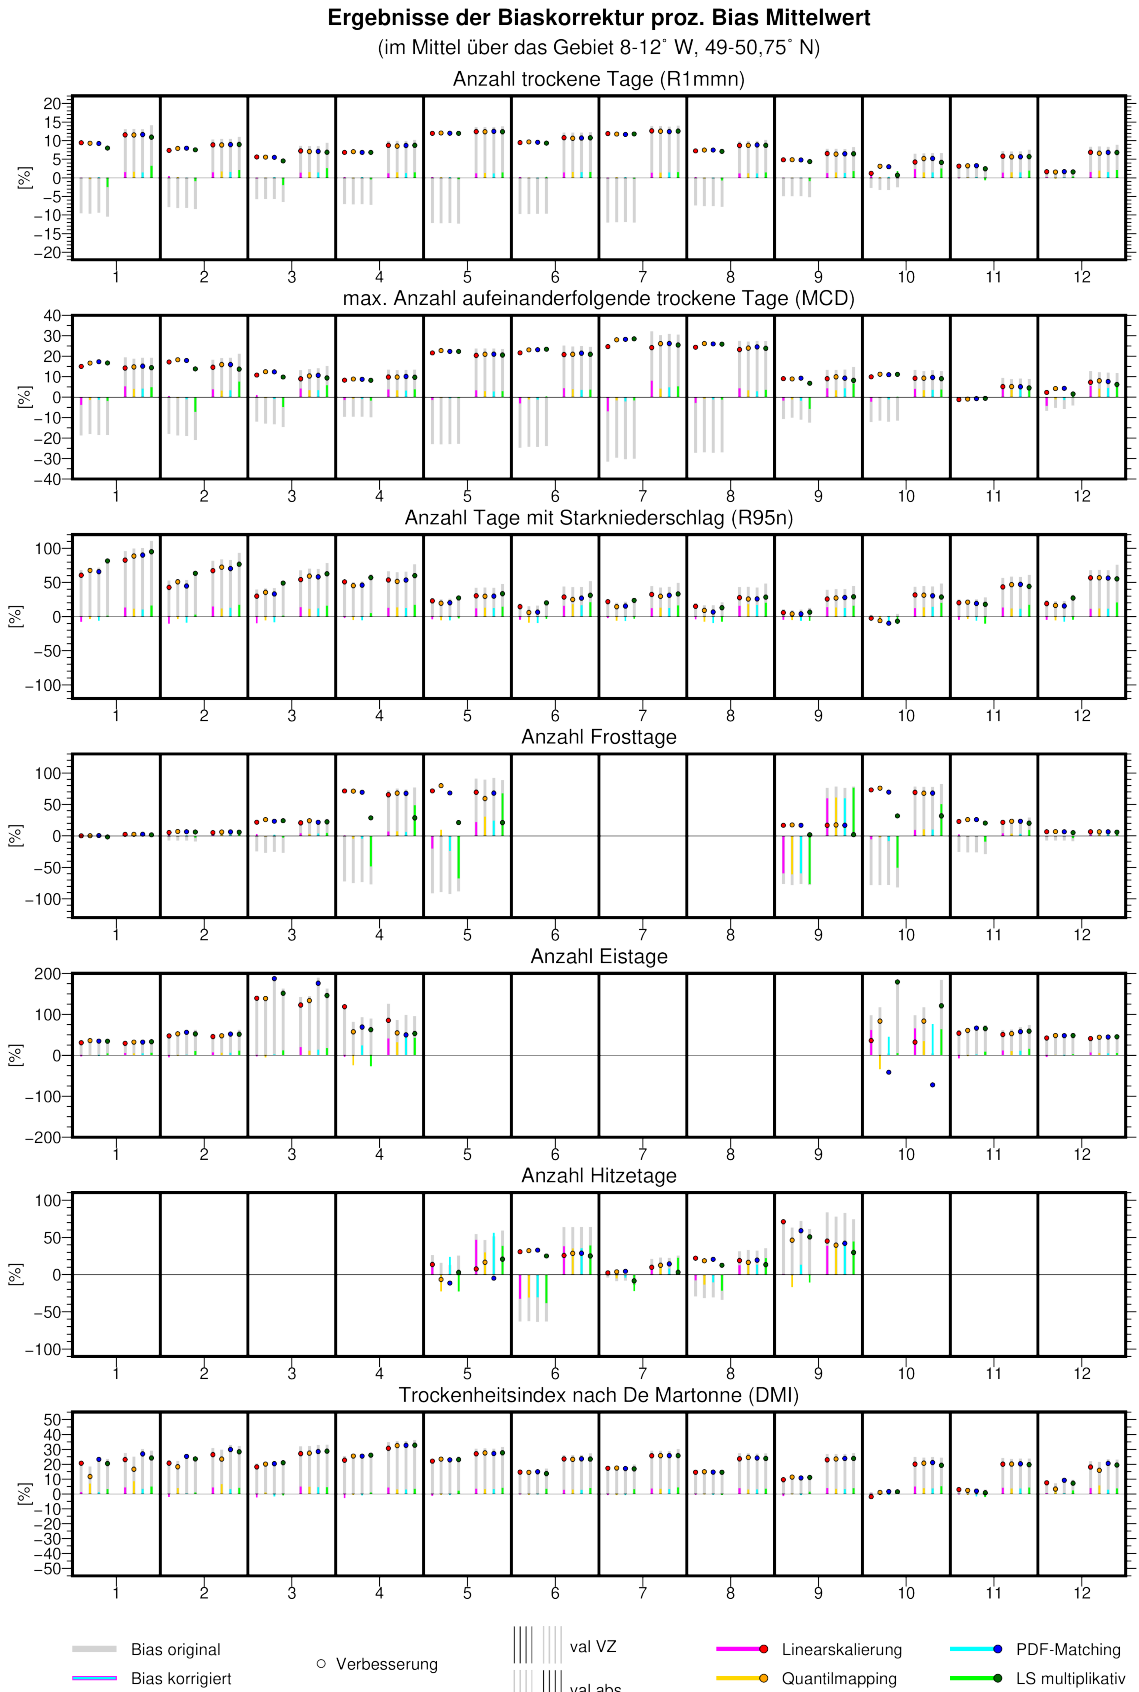


Abbildung 5.7: Biaskorrekturergebnisse prozentualer Mittelwert-Bias: Regionale Mittelwerte (Validierungsperiode) mit Vorzeichenbeachtung sowie auf Basis der Fehlerbeträge. Bias der Rohdaten als grauer Balken, Bias nach Korrektur als farbiger Balken je Korrekturmethode, Verbesserung als farbiger Kreis. Jeweils links mit und rechts ohne Vorzeichenbeachtung.

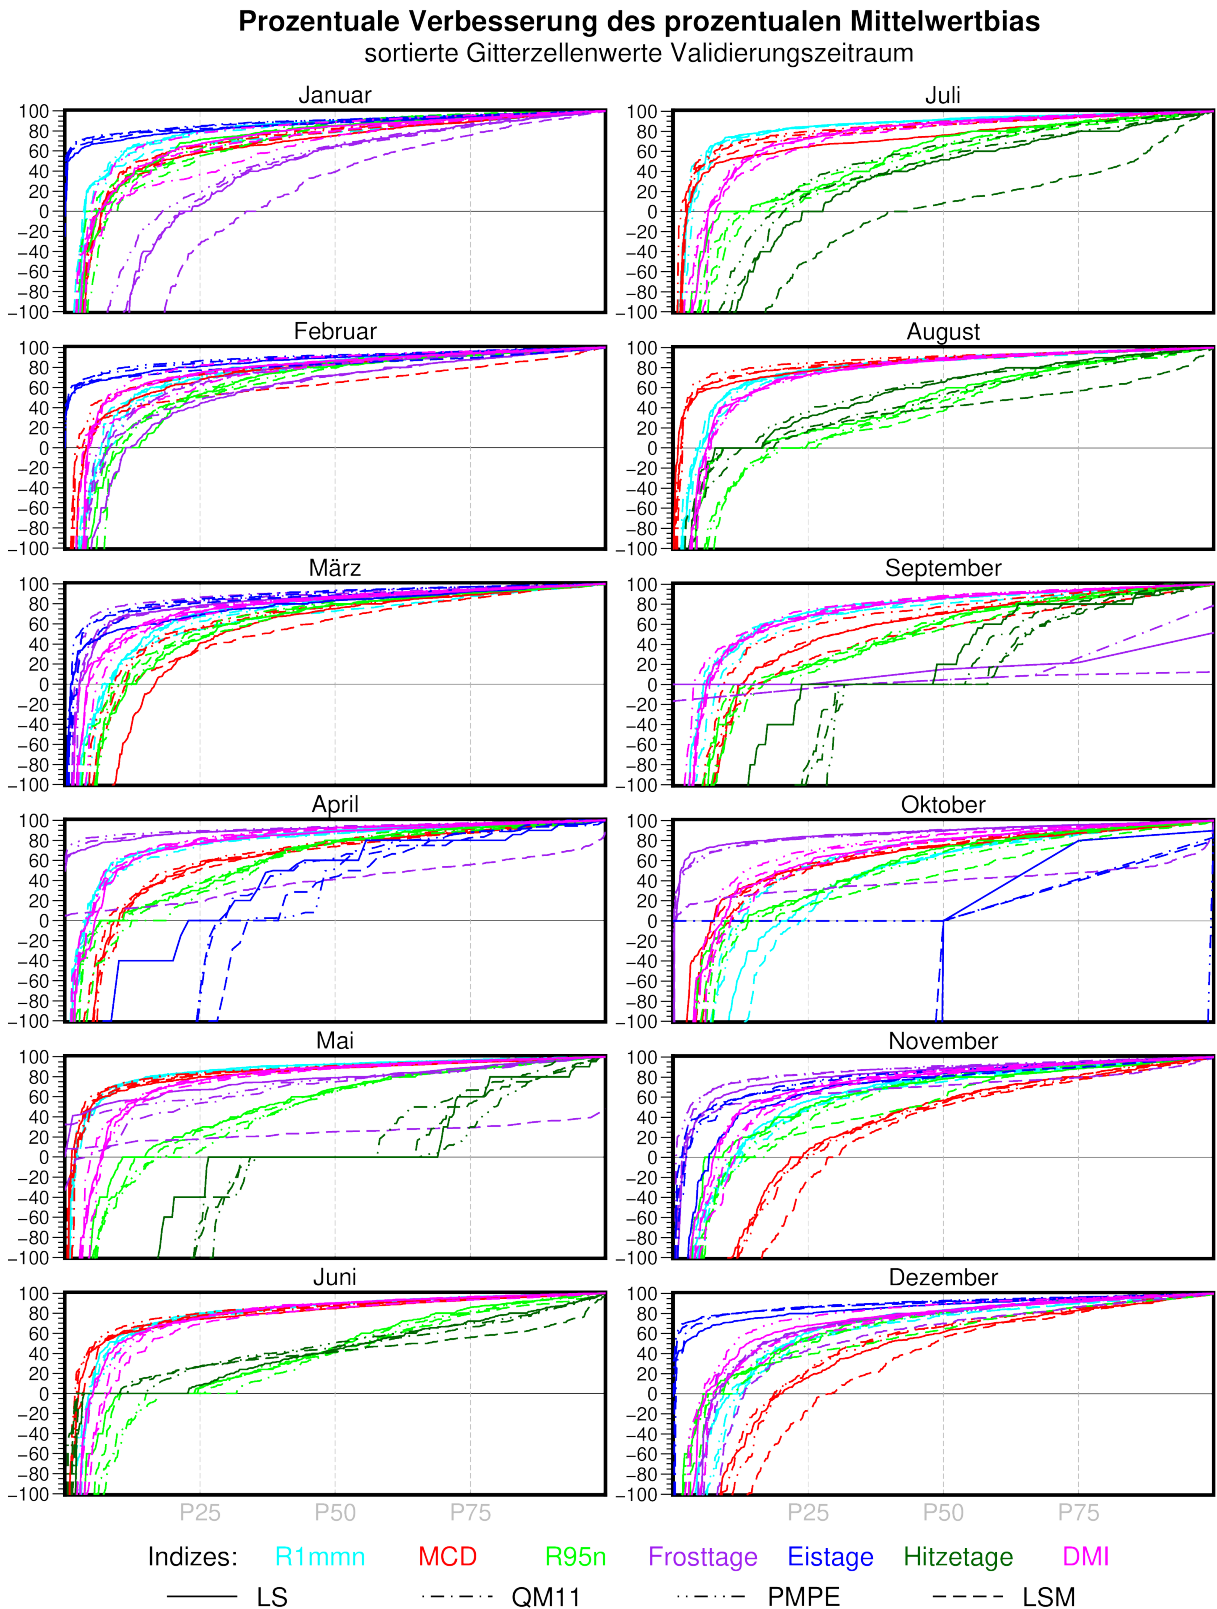


Abbildung 5.8: Biaskorrekturergebnisse prozentualer Mittelwert-Bias: Verteilung der prozentualen Verbesserung (Validierungsperiode) dargestellt durch die sortierten Werte aller Gitterzellen je Monat, Index (Farbe) und Korrekturmethode (Linienart). Die x-Achse ist auf die Anzahl der jeweils vorhandenen Werte begrenzt. Das Minimum der y-Achse entspricht nicht dem Minimum der Wert.

Tabelle 5.1: Veränderung des regionalen Mittelwerts von pBias MW durch die Biaskorrektur in Prozentpunkten (in Klammern bzgl. der absoluten pBias-Werte). Jeweils Wertespanne der Einzelmonate. Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| | LS | LSM | QM11 | PMPE |
|-------|----------------------------|----------------------------|----------------------------|------------------------------|
| R1mmn | 1,2–12,0 (4,2–12,6) | 0,7–11,9 (4,1–12,6) | 1,7–12,00 (5,8–13,0) | 1,6–12,1 (5,2–12,5) |
| MCD | -1,2–24,7 (5,2–24,2) | -0,6–28,5 (4,5–25,5) | -0,9–28,0 (5,2–26,2) | -0,7–28,2 (5,1–26,2) |
| R95n | -2,3–60,5 (25,6–82,7) | -6,8–81,6 (28,3–94,9) | -6,0–67,6 (25,0–88,7) | -0,9–65,8 (25,9–90,2) |
| Frost | 0,1–73,0 (2,5–69,2) | -1,6–31,9 (1,7–31,9) | 0,4–79,97 (2,4–68,0) | 0,4–69,5 (2,7–68,0) |
| Eis | 30,9–139,2 (29,3–122,6) | 34,4–179,2 (33,2–145,8) | 35,7–138,5 (32,3–133,4) | -41,4–187,4 (-72,3–176,9) |
| Hitze | 2,4–71,2 (7,6–45,1) | -8,3–50,6 (3,0–29,8) | -6,6–46,2 (12,6–39,4) | -11,4–58,9 (-4,9–42,0) |
| DMI | -1,8–22,7 (18,1–30,7) | 0,8–26,1 (19,3–32,7) | 2,3–26,3 (17,9–34,2) | 1,6–25,4 (20,3–32,7) |

schnitt stark beeinflussen. Um diesem Umstand Rechnung zu tragen, werden im nachfolgenden Text neben regionalen Mittelwerten auch die regionalen Mediane mitangegeben. Abbildung 5.8 zeigt eine Übersicht über die Verteilung dieser prozentualen Verbesserung des prozentualen Mittelwertbias. Hier sind je Monat, Index und Korrekturmethode die prozentualen pBias-Veränderungen (im Vergleich zu den Rohdaten) aller Gitterzellen in sortierter Form dargestellt³⁹, als Orientierung sind das 25., 50. (Median) und 75. Perzentil markiert. So wird die Höhe des Korrekturerfolgs anteilig an allen Gitterzellen sichtbar. Sind die Linien stark gebündelt und kaum unterscheidbar, sind alle Methoden ähnlich erfolgreich, weichen einzelne Linien jedoch deutlich ab, zeigen sich dadurch Diskrepanzen in der Korrekturgüte⁴⁰. Fast immer sind über 75 % der Werte positiv, über 75 % der Gitterzellen weisen also nach der Korrektur näher an den Beobachtungsdaten liegende Werte auf. Ausnahmen liegen für Frosttage im Januar (LSM), Eistage in April und Oktober, Hitzetage (Mai, September), R95n im Juni sowie MCD im November und Dezember (LSM) vor. Tabelle 5.2 gibt einen Überblick über die Ergebnisse der prozentualen Verbesserungen, indem (analog zu Tabelle 5.1) die monatlichen Wertespannen der regionalen Mittelwerte (Mediane) je Index aufgeführt werden. Der regionale Median der prozentualen Veränderungen ist nur in einem Fall – PMPE-Korrektur der Eistagehäufigkeit im Oktober mit sehr geringen Referenzwerten – negativ.

³⁹Der maximal erreichbare Wert ist 100 % (komplette Entfernung des ursprünglichen Fehlers), ein Minimum existiert nicht, die Skala der Abbildung endet jedoch bei -100 %.

⁴⁰Hierauf liegt der Fokus der Abbildung, weswegen bewusst eine hohe Datenfülle in eine Abbildung integriert wurde.

Tabelle 5.2: Regionaler Mittelwert (Median) der prozentualen Verbesserung von pBias MW durch die Biaskorrektur. Jeweils Wertespanne der Einzelmonate. Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| [%] | LS | LSM | QM11 | PMPE |
|-------|-----------------------------|-----------------------------|----------------------------|---------------------------------|
| R1mmn | -2,3–79,9 (67,5–92,0) | -27,8–79,2 (67,5–91,0) | 35,3–82,1 (79,0–92,6) | 39,6–82,5 (79,9–92,9) |
| MCD | -4,2–82,5 (56,6–88,8) | -40,9–83,9 (51,2–90,3) | -2,3–79,3 (54,5–90,7) | -11,1–84,5 (55,4–91,8) |
| R95n | 17,2–63,1 (45,7–85,5) | -19,3–63,8 (36,7–85,0) | -7,7–55,9 (42,2–88,1) | -15,6–63,9 (45,1–90,2) |
| Frost | 1,6–90,8 (15,0–92,7) | -50,0–68,1 (4,5–85,1) | -0,2–91,3 (4,5–92,8) | 17,6–92,7 (12,0–94,1) |
| Eis | -4726,0–86,8 (60,0–90,1) | -1190,0–87,5 (43,7–91,5) | -871,6–89,0 (62,2–93,3) | -7409,0–90,3 (-8911,8*–93,0) |
| Hitze | -1450,1–37,3 (0,0–65,5) | -1152,2–33,6 (0,0–41,6) | -901,2–41,1 (0,0–56,3) | -1580,2–42,7 (0,0–67,8) |
| DMI | 15,1–69,9 (81,7–90,2) | -1981,7–65,8 (79,7–91,6) | -364,6–77,0 (74,6–92,7) | -352,8–76,2 (86,6–92,0) |

*-8911,8 Oktober sonst minimaler Median 51,3

Die Ergebnisse werden nachfolgend näher vorgestellt, dabei wird je Index einleitend die Ursprungsgüte der Daten aufgegriffen und anschließend auf die Korrekturfolgen eingegangen. Die räumliche Verteilung der Fehler und Veränderungen wird dabei nur kurz beschreibend dargelegt, um danach die regionalen Mittelwerte (und im Falle der prozentualen Verbesserungen die regionalen Mediane) näher zu betrachten. Die Ausführungen beziehen sich auf die Abbildungen 5.6–5.2, ohne dass diese in den einzelnen Abschnitten explizit genannt werden.

R1mmn Ganz allgemein wird die Anzahl der Trockentage von REMO in den Höhenlagen über-, ansonsten unterschätzt. Von August bis Oktober ist die Unterschätzung schwächer, im November und Dezember ist die Überschätzung stärker ausgeprägt (was im Mittel zu einem leicht positiven Bias führt). Nach der Korrektur sind diese Fehler deutlich abgeschwächt. Die höchsten Restfehler verbleiben für LSM.

Alle Biaskorrekturverfahren resultieren ungeachtet des betrachteten Monats im regionalen Mittel in einer Verbesserung der Werte (vgl. Tabelle 5.1): Während der ursprüngliche Fehler je nach Methode und Monat zwischen -12,2 % und 3,4 % liegt (absolut 6,5–14,1 %), beträgt er nach der Korrektur -2,7–1,8 % (absolut 1,0–3,1 %, höchste Restfehler LSM). Vor allem im Oktober sind die Ergebnisse von LS und LSM schlechter als die der anderen beiden Methoden, was sowohl in Abbildung 5.7 als auch 5.8 erkennbar wird. Wie aus Tabelle 5.2 ersichtlich, führen

diese beiden Methoden im schlechtesten Monat (Oktober) regional gemittelt zu prozentualen Verschlechterungen.

MCD Die Rohdaten des MCD lassen von Mai bis August flächendeckend außer in großen Höhen zu geringe Werte erkennen. Für die übrigen Monate ist dies z.T. schwächer ausgeprägt und die Überschätzungen erstrecken sich je nach Monat auch in niedrigere Mittelgebirgslagen. Auch hier ergeben alle BK-Methoden Verbesserungen, die jedoch für LSM und LS geringer sind.

Im regionalen Mittel verändern sich die Abweichungen von $-31,3-0,0\%$ ($8,6-32,1\%$ absolut) auf $-6,9-2,4\%$ ($2,6-7,4\%$ absolut, höchste Restfehler LSM). Die Spannweiten der Veränderungen sind Tabelle 5.1 zu entnehmen. Es treten ausschließlich im November, mit geringen Ausgangsfehlern, leichte Verschlechterungen durch die Korrekturen auf. Bei der Betrachtung der Mittelwerte der Fehlerbeträge – also ohne Ausgleich gegensätzlicher Fehler – ist der ursprüngliche November-Bias höher, die Korrektur resultiert in einer Verbesserung der Daten. Die Verbesserungen durch LSM sind in Februar, März, September und Dezember, durch LS in Januar, Juni, Juli, August und Oktober erkennbar am geringsten. Unterschiede bzgl. der pV (Wertebereich der Einzelmonate siehe Tabelle 5.2) sind v.a. im Februar (LSM über weite Teile der Verteilung unterhalb der anderen), März (wie Februar, sowie LS schlechteste ca. 20 % schlechter als die übrigen), Juli (LS niedriger als Rest), September (QM11 besser), November und Dezember (beide LSM v.a. schlechtere Werte schlechter) deutlich sichtbar. Für alle Methoden sind im November und Dezember die geringsten Korrekturerfolge zu verzeichnen.

R95n Die in den Rohdaten deutlich erkennbaren Kontraste zwischen zu hohen Simulationen in niedrigeren und zu niedrigen Simulationen in höheren Lagen lassen sich zwar nach der Korrektur v.a. für LSM noch erahnen, jedoch erheblich abgeschwächt.

Der pBias-Durchschnitt über das Untersuchungsgebiet wird von $-0,3-82,3\%$ (absolut $38,7-110,5\%$) auf $-10,5-4,4\%$ (absolut $9,7-20,2\%$, höchste absolute Restfehler LSM) modifiziert. Ausschließlich im Oktober, in dem geringen Ausgangsfehlern vorliegen, bleibt die Korrektur im regionalen Mittel ohne Erfolg, ansonsten führt sie immer zu einer Verbesserung (siehe Tabelle 5.1). Ohne VZ-Beachtung sind die regionalen Durchschnittsfehler höher und auch im Oktober ergibt sich eine Datenverbesserung. Bei Betrachtung der sortierten pV-Werte fällt für R95n eine Häufung von Gitterzellen ohne erkennbare Veränderung auf (Stufe auf Nulllinie in Abbildung

5.8). Diese ist im Juni am stärksten ausgeprägt (ca. 40–50 von 373 möglichen Gitterzellen), jedoch in jedem Monat (außer PMPE Feb. und Mär.) vorhanden. Von April bis Juni sind die QM11-, von Oktober bis Dezember die LSM-Verbesserungen am geringsten. Nur für LS sind die regionalen Mittelwerte der prozentualen Veränderungen in allen Monaten positiv (siehe Tabelle 5.2).

Frosttage Bei den Rohdaten der Frosttageanzahl halten sich im Januar zu geringe (Großteile des UG-Südens, NO- und NW-Rand, nördliche Rhön) und zu hohe (Thüringisch-Fränkischer Wald, Rheingraben und nördliche Ausläufer, Teile der Frankenalb, zentrales und östliches Unterfranken) Werte in etwa die Waage. Im Rest des Jahres überwiegen zu niedrig simulierte Häufigkeiten (in höheren Lagen schwächer ausgeprägt bis zu leichten Überschätzungen). Im Dezember sind v.a. im Rhein-Main-Gebiet zu hohe Werte erkennbar, ansonsten herrschen schwache Unterschätzungen vor. Die Fehler(beträge) sind Richtung in den Übergangsmonaten deutlich höher als am Ende und Beginn des Jahres. Die Korrektur führt im Mittel über alle Monate flächendeckend zu einer deutlichen Fehlerminderung (für LSM am schwächsten).

Die Fehler betragen im regionalen Durchschnitt der Ausgangsdaten $-91,7$ – $0,6$ % (absolut $3,9$ – $91,7$ %) sowie nach der Korrekturanwendung $-75,8$ – $9,3$ % (absolut $1,3$ – $75,8$ %, LSM höchste Restfehler). Außer im Januar mit niedrigen Ursprungsfehlern (dann nahezu unverändert, z.T. leichte Verschlechterung), ist im regionalen Mittel für jeden Monat und jede Methode eine Verbesserung klar erkennbar (Wertespanne der Monate in Tabelle 5.1). Die insgesamt am wenigsten erfolgreiche Methode LSM schneidet gerade in den Übergangsmonaten April, Mai, September und Oktober, die sich durch große Fehler in den Rohdaten auszeichnen, jedoch deutlich schlechter ab als die übrigen BK-Verfahren. Die besten Korrekturen ergibt QM11. Bei der pV-Einzelbetrachtung (Übersicht in Tabelle 5.2) fallen schlechtere Ergebnisse für LSM auf (Jan., Apr., Mai, Okt.–Dez.). Im September entsprechen die Differenzen wie auch die prozentualen Veränderungen von PMPE exakt LS (je fünf gültige Werte, dabei zwei ohne Veränderung durch Korrektur) sowie von LSM mit einer Ausnahme QM11 (je vier gültige Werte, dabei einer ohne Veränderung durch Korrektur). Die Rohdaten der korrigierten Werte betragen hierbei maximal $0,0\bar{6}$, was 2 Frosttagen in den 30 Jahren der Validierungsperiode entspricht.

Eistage Die Anzahl der Eistage wird von REMO überschätzt, v.a. in niedrigeren Höhenlagen und dabei am stärksten im März im Oberrheingrabengebiet inkl. Untermain. Durch die Korrek-

tur wird dieser Bias über das gesamte Gebiet deutlich verringert, sodass je nach Methode und Monat z.T. gar leichte Unterschätzungen auftreten.

Im regionalen Mittel bedeutet dies ursprünglich Fehler zwischen 3,1 und 188,6 % (absolut ebenso), nach der Korrektur belaufen sie sich auf -26,6–60,7 % (absolut 3,4–75,4 %). Es ergibt sich im Oktober (nur 4 Gitterzellen mit Daten) durch PMPE eine Verschlechterung, ansonsten immer eine deutliche Verbesserung der Daten (Tabelle 5.1). Hinsichtlich des Ursprungsfehlers entspricht dies Veränderungen in Höhe des in Tabelle 5.2 angegebenen Wertebereichs. Im Zeitraum Januar–März sowie November–Dezember zeigen sich nur sehr wenige Verschlechterungen, wobei die Korrekturgüte mit steigendem Abstand vom Jahreswechsel abnimmt. Geringere Verbesserungen als die übrigen Methoden zeigen sich im März für LSM und v.a. LS, im November und Dezember für LS. Im April und Oktober liegen nur wenig Werte vor und die Korrektur ist von mäßigerem Erfolg.

Wie in Fußnote 38 (Seite 99) beschrieben, wird bei einem Ursprungsbias von 0,0 % zur Ermöglichung der Berechnung selbiger auf 1,0 % gesetzt. Wenn nun, wie beispielsweise für LS an zwei Gitterzellen im Oktober der Fall, der Wert von 0,033 Eistagen einem pBias von 0,0 % entspricht (Beobachtungswert ebenfalls 0,033 Tage) und die Korrektur für die selbe Gitterzelle in einem Wert von 0,073 Eistagen resultiert, sind das 220,0 % des Beobachtungswertes und somit ein pBias von 120,0 %. Dies bedeutet wiederum eine prozentuale Verschlechterung um -11900 %⁴¹. Die Verschlechterung um 0,04 Tage entspricht somit 11900 %. Daher kommt es im Oktober und zum Teil im April aufgrund der sehr geringen Anzahl an beobachteten wie simulierten Häufigkeiten bei der Bildung prozentualer Fehler sowie prozentualer Verbesserungen der prozentualen Fehlern zu sehr hohen Beträgen. Für PMPE liegt im Mittelwert eine Verschlechterung um fast 9000 % vor. Die Simulationen an den für die Korrektur in gültigen Modellen resultierenden Gitterzellen (LSM und QM11 3, PMPE 4, LS 5 Gitterzellen im Oktober) liegen zwischen 0,03 und 0,4 Ereignistagen, dies entspricht pBias-Werten von 0–500 %. Nichtsdestotrotz sind die prozentualen Fehler sowie die prozentualen Veränderungen selbiger anschaulicher als eine absolute Angabe ohne Kenntnis der Bezugsgröße.

Hitzetage Im unkorrigierten Zustand wird die Anzahl der Hitzetage im Juni und August weitgehend unterschätzt. Im Juli ergibt sich eine Zweiteilung des Gebiets (NW+, SO-), im Septem-

⁴¹ $100 \% \cdot \left(1 - \frac{120 \%}{0 \%}\right)$ gesetzt auf $100 \% \cdot \left(1 - \frac{120 \%}{1 \%}\right) = 100 \% \cdot (-119) = -11900 \%$

ber überwiegen zu hohe Werte (Monat mit größten Fehlern). Im Mai beeinflusst der betrachtete Zeitraum den Bias, wobei im Westen stets zu hohe Werte erkennbar werden. Die optisch größten Korrekturerfolge ergeben sich für Juli und August, wobei LSM nur geringe Biasabschwächungen zeigt. Im Mittel über alle Monate (Abbildung 5.6) verbleiben im NO des Untersuchungsgebietes die größten Restfehler, am stärksten und weitesten ausgebreitet für LSM.

Die zu hohen Werte im NW im Mai werden außer durch PMPE deutlich korrigiert, zudem treten im SO für LS und PMPE anstatt der ursprünglich zu geringen z.T. deutlich zu hohe Werte auf. Im Juni bleiben die zu geringen Häufigkeiten in abgeschwächter Form bestehen, für LS und PMPE kommen im Thüringer Wald zu hohe Wahrscheinlichkeiten hinzu. Die optisch größten Korrekturerfolge ergeben sich für Juli und August (letzterer weniger im NW), wobei LSM nur geringe Biasabschwächungen zeigt. Im September schließlich wird die ursprüngliche Überschätzung der Hitzetage mit Ausnahme des Nordwestens deutlich verringert und geht z.T. in eine leichte Unterschätzung über.

Im Gebietsmittel wird der Bias von ursprünglich -62,9–71,6 % (absolut 20,5–83,3 %) auf -17,4–23,6 % (absolut 7,5–55,8 %) reduziert. Die Indexwerte werden im Mai durch QM11 und PMPE, im Juli (zu hohe Werte NW in zu niedrige gekehrt) durch LSM verschlechtert, ansonsten verbessert. Bei Verwendung der absoluten Fehler verbleibt ausschließlich durch PMPE im Mai ein Qualitätsverlust der Daten (vgl. Tabelle 5.1). Hinsichtlich der prozentualen Verbesserung ist, ähnlich der Frosttage, eine Häufung von unveränderten Werten erkennbar, am stärksten im Mai. Insbesondere im Juli, aber auch im August, liegen die pV durch LSM deutlich unter den übrigen, PMPE hingegen ist hier am erfolgreichsten. Wie bei der Anzahl der Eistage ist auch für die Hitzetagehäufigkeit die Betrachtung der Übergangsmonate mit sehr geringen Auftretenszahlen schwierig, da diese bei der relativen Betrachtung zu sehr starken und so verzerrenden Werten führen. In Tabelle 5.2 sind die Wertebereiche der Monate aufgetragen.

DMI Ähnlich der Starkregentage sind auch die DMI-Ursprungsdaten durch zu feuchte Bedingungen (höherer DMI) in niedrigen und zu trockene Bedingungen in höheren Lagen gekennzeichnet, wobei insgesamt (außer von Oktober bis Dezember) zu viel Feuchtigkeit simuliert wird. Durch die Korrekturen werden die Fehler beider Vorzeichen deutlich abgeschwächt. Für LS resultieren v.a. im Winterhalbjahr einige Unterschätzungen in niedrigeren Höhenlagen, für QM11 bleibt von Dezember bis Februar/März die Überschätzung z.T. abgemildert erhalten.

Im regionalen Mittel zeigt die Korrektur klare Erfolge mit einer Verringerung des Ursprungsbiases von 0,9–26,7 % (absolut 21,2–35,9 %) auf -2,8–6,6 % (absolut 2,5–8,2 %). Der Restfehler ist von Dezember bis Februar für QM11 am größten. Bei VZ-Beachtung ist im Oktober und November mit geringen Ausgangsfehlern nur wenig Veränderung erkennbar, die Linearskalierung führt im Oktober zu einer leichten Verschlechterung (siehe Tabelle 5.1). Hinsichtlich der Fehlerbeträge sind hier sowohl die Ursprungsfehler als auch die Korrekturerfolge deutlich höher. Im Monatsdurchschnitt bleiben v.a. in Regnitz- und Obermainsenke die ursprünglichen Überschätzungen bei QM11 vorhanden, jedoch in abgeschwächter Form. Bei der Linearskalierung werden sie, ebenso wie diejenigen in Oberrheingraben und Wetterau, zu leicht unterschätzten Werten modifiziert (vgl. Abbildung 5.6).

Die sortierten Werte der prozentualen Veränderungen liegen für die vier Methoden meist nah beieinander. Im Januar und Februar hebt sich PMPE positiv, QM11 negativ ab. Im Juni und Juli liegt LSM z.T. deutlich unter den anderen, im Oktober und Dezember ist wieder PMPE am besten. Nur für LS ist der regionale Mittelwert der prozentualen Veränderungen für alle Monate positiv

Durch die zusätzliche Betrachtung der Regionsmittel der Fehlerbeträge wird sichtbar, dass gegensätzliche Fehler bei normaler Mittelung das Bild sowohl der Ursprungsqualität als auch des Verbesserungserfolgs deutlich verzerren können. Dies ist besonders für DMI in Oktober und November, R95n in September und Oktober, MCD im November sowie R1mmn im Dezember der Fall. Die Abschwächung der absoluten Fehler wird im regionalen Mittel z.T. nicht sichtbar bzw. es treten z.T. sogar Verschlechterungen auf. Abbildung 5.9 verdeutlicht dies (mit QM11 als Beispiel, andere Methoden ähnlich):

Optisch ist von den Rohfehlern (obere Reihe) zu den Restfehlern nach Korrektur (mittlere Reihe) eine deutliche Verbesserung erkennbar. Im regionalen Mittel jedoch liegen die rohen Fehler bei 8,7 % (R95n), 1,6 % (DMI), 0,0 % (MCD) bzw. 1,7 % (R1mmn), die Restfehler bei -4,7 % (DMI), -0,5 % (R95n), -0,9 % (MCD) bzw. -0,1 % (R1mmn), was im Falle von MCD eine leichte Verschlechterung impliziert. Werden nun die absoluten Fehler gemittelt, so zeigt sich eine deutliche Verbesserung (R95n 39,7 auf 12,6 %, DMI 24,2 auf 3,5 %, MCD 8,6 auf 3,4 %, R1mmn 8,4 auf 1,8 %). Ein weiterer Punkt kommt hinzu, der im Falle der prozentualen Veränderungen (untere Reihe) zu Tage tritt: In der Abbildung ist das räumliche Überwiegen positiver Werte (also Verbesserungen) durch eine dunkelblaue Färbung der meisten Gitterpunkte sichtbar. Bei der arithmetischen Mittelung aller Werte beträgt sie 11,5 % (R95n), 42,2 % (DMI),

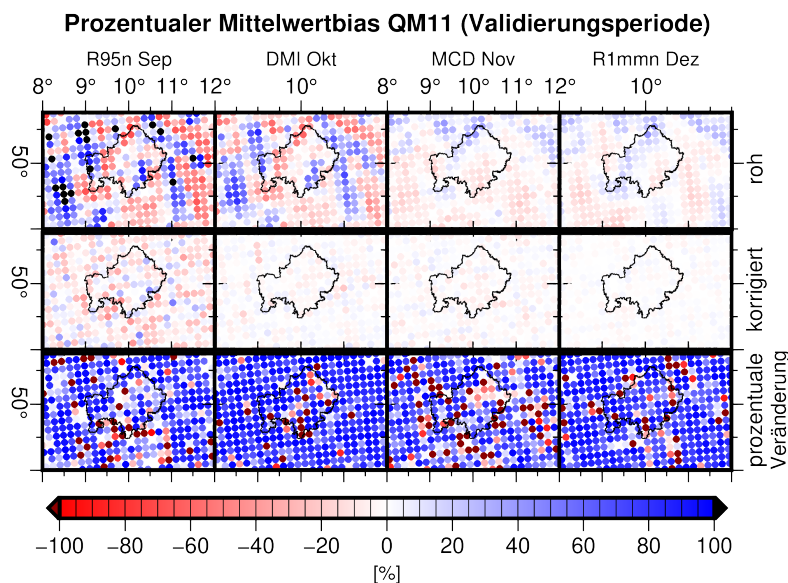


Abbildung 5.9: Prozentualer Mittelwert-Bias DMI Oktober: Vor und nach der Korrektur (QM11) sowie prozentuale Verbesserung (von oben nach unten). Beispielsituationen: R95n September, DMI Oktober, MCD November und R1mmn Dezember (von links nach rechts).

-2,3 % (MCD) bzw. 37,9 % (R1mmn), die Mediane jedoch liegen bei 63,2 % (R95n), 85,6 % (DMI), 54,5 % bzw. 79,7 % , was das starke Ins-Gewicht-Fallen stark negativer prozentualer Veränderungen, vor allem an Gitterpunkten mit geringem Ausgangsbias, verdeutlicht.

Spätfrost Hinsichtlich des Spätfrostes zeigt REMO eine deutlich zu geringe Auftretshäufigkeit. Diese ist in Höhenlagen und z.T. im SW des Untersuchungsgebietes schwächer ausgeprägt. Die Korrektur durch LSM zeigt wenig Erfolg, insbesondere im Westen des Gebietes. Außerdem resultieren hinsichtlich der monatsbezogen definierten Spätfrostes für LSM viele Gitterzellen ohne gültige Werte. Die übrigen Methoden lassen für beide Indexvarianten klare Verbesserungen erkennen, die teilweise zu leichten Überschätzungen führen. Für den LS-VPT-Spätfrost bleiben von NW nach SO noch deutlich zu wenig Ereignistage, ansonsten ist kein räumliches Muster erkennbar. In Abbildung 5.10 sind die regionalen Mittelwerte (roh, korrigiert, Veränderung) dargestellt, in Abbildung 5.11 die sortierten Gitterzellenwerte der prozentualen Verbesserungen.

Im Bezug auf die regionalen Mittelwerte kann der Bias des Spätfrostes mit thermisch definierter Vegetationsperiode von -75,9 bis -69,6 % (absolut 69,6–75,9 %) auf -40,5 bis -0,4 % (absolut 5,1–40,5 %) reduziert werden. Dessen mit monatlich definiertem Zeitraum von -77,8 bis -75,5 % (absolut 75,5–77,8 %) auf -54,6 bis -0,3 % (absolut 5,4–54,6 %). Für beide Varianten

verbleibt der deutlich größte Restbias bei LSM. Details zu Veränderungen und prozentualen Verbesserungen sind Tabelle 5.3 zu entnehmen. Wie Abbildung 5.11 zeigt, sind unabhängig von der angewandten Korrektur an keiner Gitterzelle Verschlechterungen feststellbar. Allerdings wird auch hier deutlich, dass LSM am wenigsten zur Qualitätserhöhung beiträgt. Für VPT ist zudem die additive Linearskalierung etwas schlechter als die übrigen Methoden, ansonsten ähneln sich die Ergebnisse.




Abbildung 5.10: Biaskorrekturergebnisse prozentualer Mittelwert-Bias Spätfrost: Regionale Mittelwerte (Validierungsperiode) mit Vorzeichenbeachtung sowie auf Basis der Fehlerbeträge.

Bias der Rohdaten als grauer Balken, Bias nach Korrektur als farbiger Balken je Korrekturmethode, Verbesserung als farbiger Kreis. Jeweils links mit und rechts ohne Vorzeichenbeachtung.

Tabelle 5.3: Spätfrost: Veränderung des regionalen Mittelwerts Δ [PP] und regionaler Mittelwert der prozentualen Verbesserung [%] von pBias MW durch die Biaskorrektur (in Klammern Δ bzgl. der absoluten pBias-Werte, pV Median). Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| | LS | LSM | QM11 | PMPE |
|--------------|-------------|-------------|-------------|-------------|
| VPT Δ | 64,4 (61,8) | 35,4 (35,4) | 69,2 (64,5) | 67,3 (63,6) |
| VPT pV | 86,8 (89,5) | 47,5 (45,7) | 92,5 (93,8) | 91,0 (92,3) |
| VPM Δ | 74,4 (69,7) | 23,2 (23,2) | 73,8 (70,5) | 72,5 (70,1) |
| VPT pV | 92,1 (93,3) | 32,3 (30,6) | 91,8 (93,2) | 92,9 (94,4) |

Zusammenfassend lässt sich sagen, dass alle Biaskorrekturmethode in den meisten Monat-Index-Kombinationen zu einer Verringerung des Mittelwertfehlers führen. Der regionale Me-




Abbildung 5.11: Biaskorrekturergebnisse prozentualer Mittelwert-Bias Spätfrost: Verteilung der prozentualen Verbesserung (Validierungsperiode) dargestellt durch die sortierten Werte aller Gitterzellen je Berechnungsbasis (Farbe) und Korrekturmethode (Linienart). Die x-Achse ist auf die Anzahl der jeweils vorhandenen Werte begrenzt. Das Minimum der y-Achse entspricht nicht dem Minimum der Wert.

dian der prozentualen Verbesserungen liegt für DMI, R1mmn und MCD für alle Monate und Methoden bei über 50 %, an mindestens der Hälfte aller Gitterzellen wird der Fehler also um mehr als 50 % verringert. Die deutlichsten Unterschiede zwischen den Methoden finden sich für einige Situationen in den Übergangsmonaten der Temperaturkenntage. Hierbei sind die Ergebnisse von LSM für die Frosttagehäufigkeit im April, Mai, September und Oktober sowie von PMPE für die Eistagehäufigkeit im Oktober deutlich schlechter als die der übrigen Verfahren. Die Übergangsmonate der Temperaturkenntage sind jedoch von sehr niedrigen Referenzwerten und wenigen gültigen Gitterzellen geprägt. Für den Spätfrost ist die Korrektur aller Methoden an allen Gitterzellen beider Indizes erfolgreich, wobei die Verbesserungen durch LSM deutlich am geringsten ausfallen, während sich die übrigen Ergebnisse ähneln.

5.2.2 Streuung: Prozentualer Bias der Standardabweichungen

Abbildung 5.12 zeigt die über alle Monate gemittelten Werte der nach der Biaskorrektur verbleibenden prozentualen Standardabweichungsfehler im Validierungszeitraum. Hinsichtlich der zugrundeliegenden Fehler der Rohdaten im Vergleich zu denen des Gesamtzeitraums (Abbildung 5.2) sind insbesondere folgende Unterschiede zu nennen: Ein leichter positiver Bias bzgl. der

Frosttage im SO für LSM (und weniger LS), ein für LS und QM11 abgeschwächter, für PMPE und LSM verstärkter positiver Eistagebias im Südwesten, ein stärkerer positiver Hitzetagebias in Ostunterfranken für LS (für die restlichen Methoden etwas schwächer) sowie stärkere negative Abweichungen der DMI-Schwankungen in höheren Lagen für LS. Im Allgemeinen sind die Ursprungsfehler jedoch mit denen in Abbildung 5.2 im Einklang, weshalb ein optischer Vergleich gerechtfertigt ist⁴². Da alle Werte um denselben Wert erhöht werden, führt LS definitionsgemäß zu keinen oder nur durch Wertebereichsanpassungen bedingten Veränderungen der Daten (s.u.). QM11 und PMPE zeigen deutliche Korrekturerfolge über das gesamte Untersuchungsgebiet, die für Frost- und Hitzetage am geringsten ausfallen. Für DMI resultieren auf Basis von PMPE anstatt der ursprünglich zu hohen Streuungen in niedrigen Höhenlagen nach der Korrektur zu geringe Variabilitäten (schwächer ausgeprägt auch für QM11). Letzteres gilt in verstärkter Form auch für die multiplikative Linearskalierung, welche allgemein die geringsten Qualitätserhöhungen mit sich bringt, besonders für R1mmn und die Anzahl der Frosttage mit einer schlechteren Repräsentation der Standardabweichungen als vor der Korrektur.

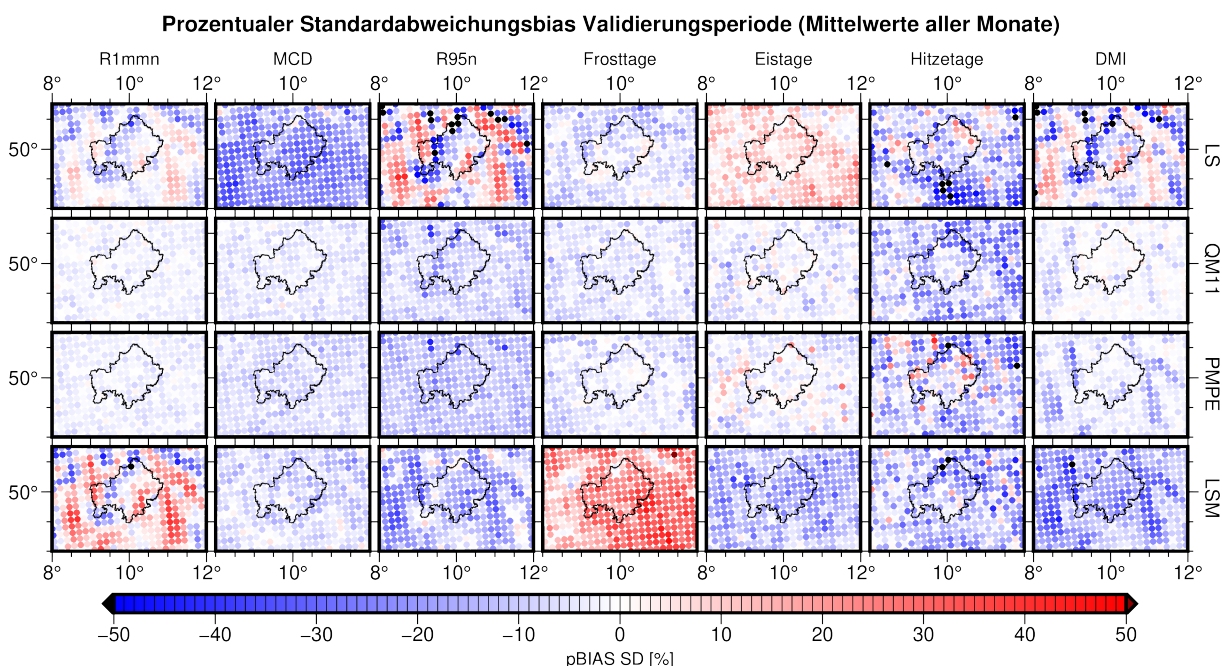


Abbildung 5.12: Modellgüte bzgl. der klimatischen Kennwerte im Validierungszeitraum nach der Biaskorrektur: Prozentualer Standardabweichungsbias. Karten der Mittelwerte über alle Monate je Index. Werte vor der Korrektur; jedoch für den Gesamtzeitraum, siehe Abbildung 5.2.

⁴²Auch hier ist wie bei den Mittelwertfehler die angepasste Farbskala zu beachten.

Regional gemittelt sind die monatlichen Ergebnisse in Abbildung 5.13 dargestellt. Wie schon für die Mittelwerte (Abbildung 5.7), sind auch hier die Durchschnittswerte der Fehlerbeträge mit aufgetragen. Trotz des oben genannten additiven Ansatzes von LS sind in Abbildung 5.13 für R95n, Frost-, Hitzetage und DMI z.T. deutliche Korrekturinflüsse erkennbar. Dies ist darin begründet, dass im Korrekturverfahren eine Beachtung der Indexgrenzen integriert ist. Keiner der betrachteten Kennwerte kann negativ werden, der DMI besitzt ein Maximum von 100 und alle anderen Indizes außer MCD sind auf die Anzahl der Tage im jeweiligen Monat begrenzt. Resultiert also aus der linearen Korrektur ein Wert außerhalb des Definitionsbereichs, so wird er auf die jeweilige obere bzw. untere Grenze gesetzt. Somit können Modifikationen der Streuung resultieren. Die Korrekturen zeigen hinsichtlich der Standardabweichung allgemein weniger Erfolg als bezüglich des Mittelwertes. Am schlechtesten sind die Ergebnisse für die multiplikative Linearskalierung, die in vielen Fällen eine Verschlechterung der Variabilitätsdarstellung zur Folge hat (v.a. R1mmn, Frosttage, DMI). Die Mittelung der Fehler mit Vorzeichenbeachtung führt häufiger zu verschlechterten Regionswerten als die der absoluten Fehler (v.a. R95n). QM11 und PMPE führen in den meisten Situationen zu einer verbesserten Darstellung der Schwankungen. Für QM11 ist die Veränderung des regionalen Mittelwerts ohne VZ-Beachtung in allen Monaten für alle Kennwerte positiv (siehe auch zusammenfassende Tabelle 5.4). Die Verteilung der prozentualen Veränderungen der einzelnen Gitterzellenwerte ist in Abbildung 5.14, ein Überblick über die entsprechenden Mittelwerte und Mediane in Tabelle 5.5 zu sehen. Die Mittelwerte liegen hierbei häufig im sechs- bis neunstellig negativen Bereich. Wie sehr wenige sehr stark negative Werte⁴³ dies bedingen wird bei Betrachtung der Grafik sowie dem Vergleich mit den Medianen erkennbar. Wiederum liegen nur bei der QM11-Korrektur für alle Indizes und Monate mindestens an der Hälfte der Gitterzellen prozentuale Verbesserungen vor. Details werden nachfolgend beschrieben, ohne die jeweiligen Abbildungen in jedem Fall dezidiert zu nennen.

R1mmn Die R1mmn-Standardabweichung wird von REMO in Mai–Juli sowie Oktober und Dezember meist unterschätzt, im April ist das Bild ausgeglichener, ansonsten überwiegen zu hohe Schwankungen. Dabei treten tendenziell in vielen Monaten Kontraste zwischen höheren (Unter-) und niedrigeren (Überschätzung) Höhenlagen auf. Während sich optisch für LS keine

⁴³Bedingt durch niedrige Ausgangsfehler als Referenz.

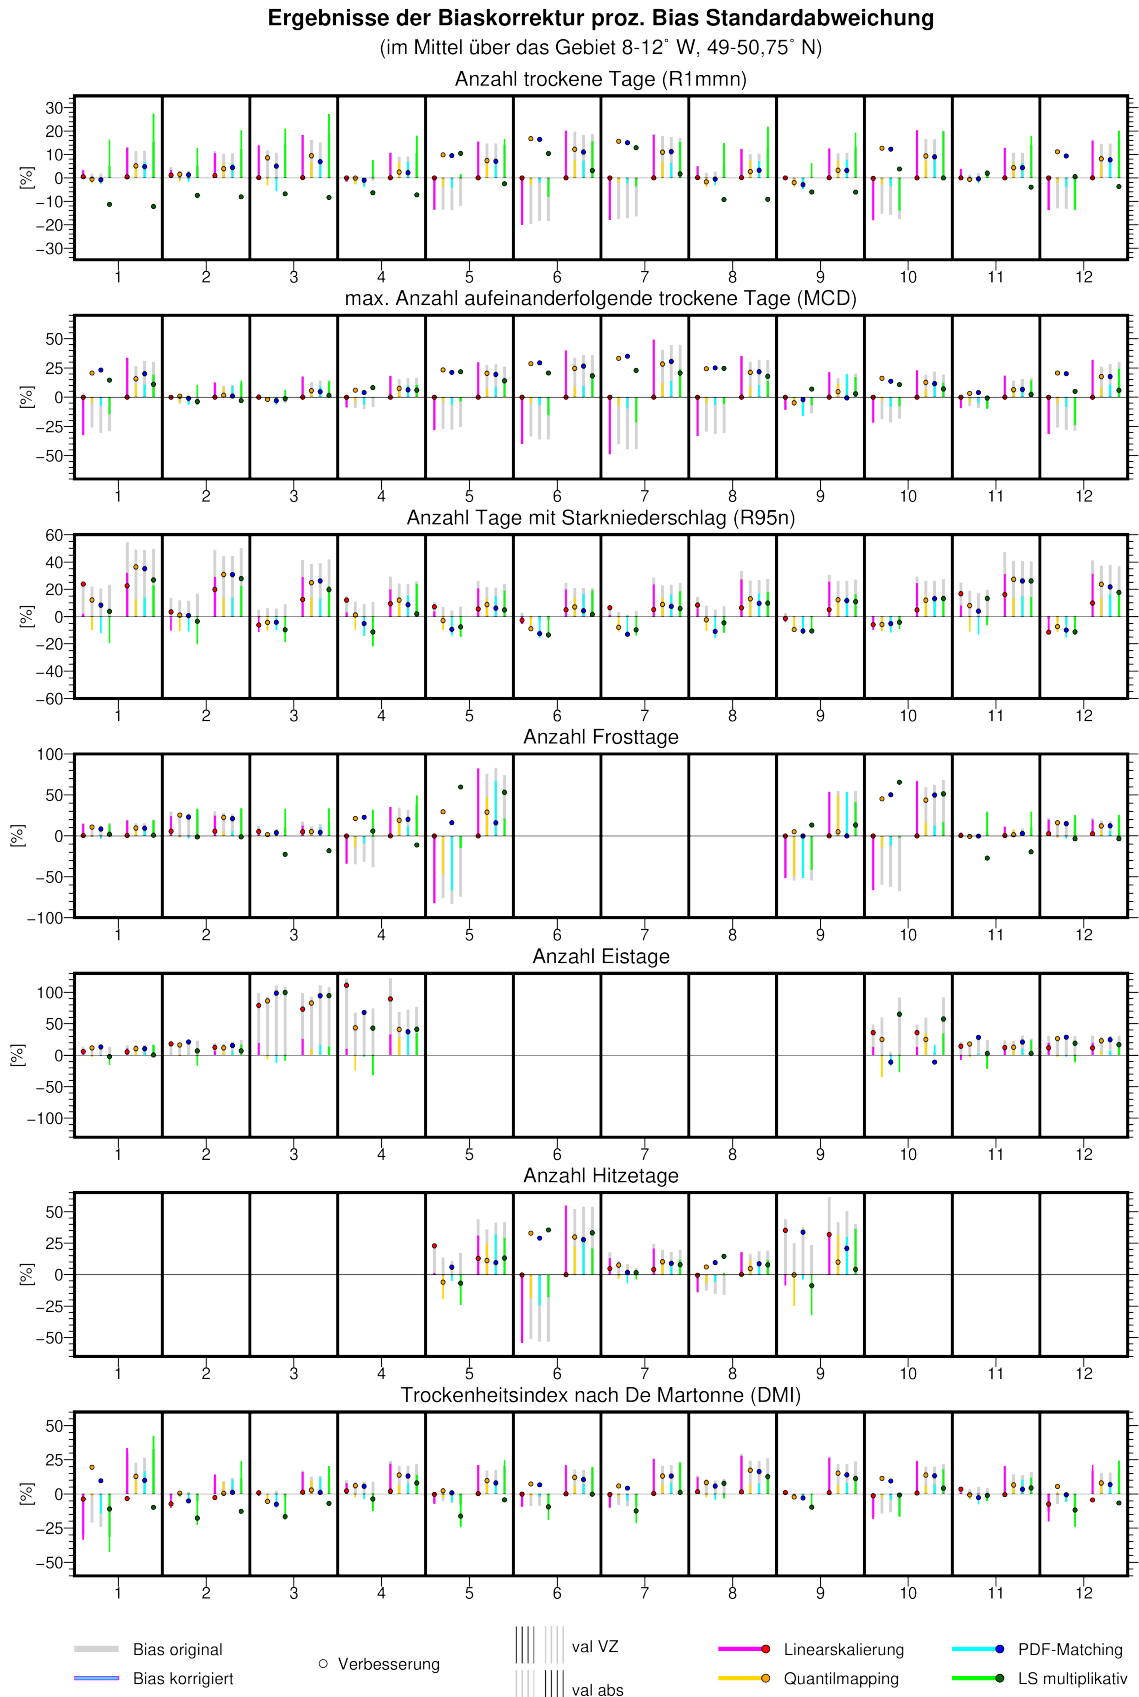


Abbildung 5.13: Biaskorrekturergebnisse prozentualer Standardabweichungsbias: Regionale Mittelwerte (Validierungsperiode) mit Vorzeichenbeachtung sowie auf Basis der Fehlerbeträge. Bias der Rohdaten als grauer Balken, Bias nach Korrektur als farbiger Balken je Korrekturmethode, Verbesserung als farbiger Kreis. Jeweils links mit und rechts ohne Vorzeichenbeachtung.

Tabelle 5.4: Veränderung des regionalen Mittelwerts von pBias SD durch die Biaskorrektur in Prozentpunkten (in Klammern bzgl. der absoluten pBias-Werte). Jeweils Wertespanne der Einzelmonate. Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| | LS | LSM | QM11 | PMPE |
|-------|-----------------------|-------------------------|-----------------------|-------------------------|
| R1mmn | -0,2–1,2 (0,0–1,0) | -11,2–12,9 (-12,3–3,1) | -2,0–16,8 (2,5–12,2) | -2,9–16,4 (2,2–11,2) |
| MCD | 0,0–0,0 (0,0–0,0) | -3,8–24,6 (-2,9–20,6) | -4,8–33,2 (1,6–28,3) | -3,0–35,0 (-0,6–30,6) |
| R95n | -11,5–23,8 (4,9–22,5) | -13,5–13,3 (1,6–27,8) | -9,6–12,1 (7,1–36,4) | -12,0–8,3 (4,3–35,0) |
| Frost | -0,0–5,8 (0,0–5,7) | -27,1–65,5 (-19,4–53,1) | -0,6–45,3 (1,3–43,7) | -0,3–50,3 (0,0–49,8) |
| Eis | 5,7–111,2 (5,2–89,3) | -2,3–99,5 (0,2–94,6) | 11,8–86,2 (10,6–82,8) | -11,0–98,6 (-11,0–94,4) |
| Hitze | -0,5–35,1 (-0,0–31,8) | -8,8–35,5 (4,0–33,2) | -6,1–32,9 (4,7–29,0) | 1,7–33,6 (8,6–27,8) |
| DMI | -7,4–3,5 (-4,4–2,1) | -17,7–7,8 (-12,7–12,6) | -5,5–19,5 (0,5–17,4) | -7,6–9,7 (1,1–16,4) |

Tabelle 5.5: Regionaler Mittelwert (Median) der prozentualen Verbesserung von pBias SD durch die Biaskorrektur. Jeweils Wertespanne der Einzelmonate. Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| [%] | LS | LSM | QM11 | PMPE |
|-------|----------------------------|---------------------------------|------------------------------|----------------------------|
| R1mmn | -32,1–2,5 (0,0–0,0) | *-79,1 (-89,8–26,7) | *-34,8 (23,1–64,4) | *-10,1 (24,8–64,6) |
| MCD | 0,0–0,0 (0,0–0,0) | -1089,9–39,7 (-22,0–62,6) | *-68,3 (11,0–78,3) | -849,0–72,9 (-4,2–79,7) |
| R95n | *-15,8 (0,0–28,9) | *-54,7 (-6,0–56,1) | *-17,7 (10,9–72,5) | *-12,8 (0,0–70,5) |
| Frost | -32,6–17,9 (0,0–31,1) | -909,5–72,4 (-242,1–79,1) | *-76,8 (9,3–83,2) | -83,2–79,4 (0,0–83,0) |
| Eis | *-42,9 (0,0–71,3) | *-10,2 (-45,5–89,6) | *-30,5 (0,0–89,7) | *-61,2 (0,0–82,7) |
| Hitze | *-5,2 (0,00–0,00) | *-55,8 (0,0–66,6) | *-233,7 (0,0–60,8) | *-47,7 (0,0–63,2) |
| DMI | -190,6–0,7 (-13,2–0,00) | -1131,1– -80,3 (-111,3–46,2) | -992,3– -46,4 (25,2–74,1) | -717,1–22,9 (16,9–71,9) |

* < -1,0·10⁵

Prozentuale Verbesserung des prozentualen Standardabweichungsbias
sortierte Gitterzellenwerte Validierungszeitraum

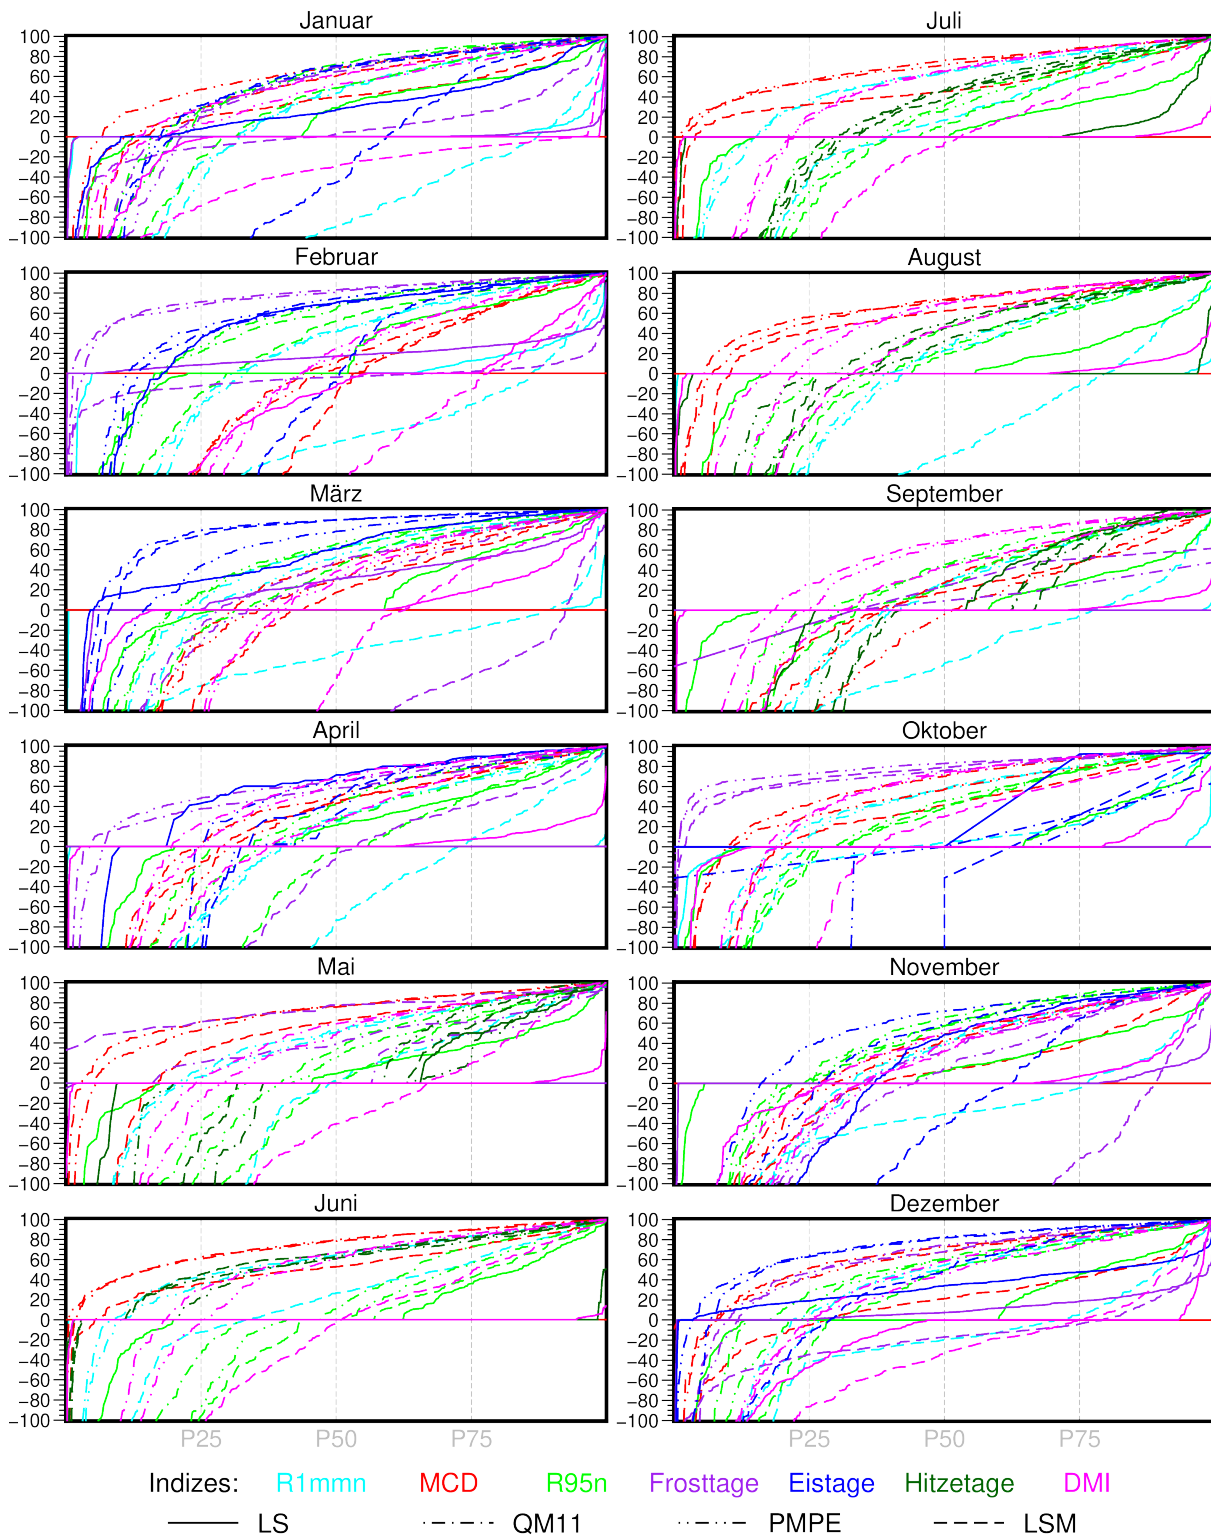


Abbildung 5.14: Biaskorrekturergebnisse prozentualer Standardabweichungsbias: Verteilung der prozentualen Verbesserung (Validierungsperiode) dargestellt durch die sortierten Werte aller Gitterzellen je Monat, Index (Farbe) und Korrekturmethode (Linienart). Die x-Achse ist auf die Anzahl der jeweils vorhandenen Werte begrenzt.

Veränderung ergibt, sind vor allem zu hohe Schwankungen nach der LSM-Korrektur in niedrigen Höhenlagen stärker ausgeprägt als davor. QM11 und PMPE hingegen führen zu deutlich verringerten Fehlern, jedoch ohne klare räumliche Muster.

Dies wird hinsichtlich der regionalen Mittelwerte auch in Abbildung 5.13 deutlich. QM11 zeigt dabei meist etwas höhere Erfolge als PMPE. Der ursprüngliche pBias SD verändert sich von -19,4–12,1 % (absolut 9,0–20,2 %) auf -20,00–21,00 % (absolut 6,0–27,4 %). Wie aus Tabelle 5.4 und Abbildung 5.13 ersichtlich wird, existieren für alle Methoden Monate mit Verschlechterungen des regionalen Mittelwertes. Werden die VZ außer Acht gelassen, ist dies jedoch nur für LSM der Fall. Gleiches gilt hinsichtlich der Mittelwerte der prozentualen Verbesserungen (negative Mediane nur für LSM; Tabelle 5.5, Abbildung 5.14). Generell werden bei Betrachtung der Verteilung der prozentualen Verbesserungen in Abbildung 5.14 die deutlich negativ von QM11 und PMPE abweichenden LSM-Ergebnisse sichtbar: Im Januar–März liegen über 80 %, im April etwa 70 %, im Mai etwa 50 % von Januar–März, August–September sowie November–Dezember liegt das 75. Perzentil nahe oder unter Null. An mindestens 75 % (Apr. und Dez. ca. 70 %) der Gitterzellen führt LSM also zu einer verringerten Variabilitätsgröße. In den übrigen Monaten führt LSM zu etwas besseren Korrekturen, jedoch weiterhin schlechter als QM11 und PMPE. Letztere resultieren für (je nach Monat) 10 % und 40 % der Gitterzellen in pBias-SD-Erhöhungen. Die linearskalierten Werte sind per definitionem für den Großteil der Gitterzellen unverändert.

MCD Die Rohdaten der maximalen Trockenperiodenlänge weisen meist zu niedrige Schwankungen auf. Ausnahmen hierzu sind v.a. im Februar–April, September und November zu finden. Die optisch größte Verbesserung resultiert aus der QM11-Biaskorrektur, etwas schlechtere Ergebnisse auf Basis von PMPE. Regionale Muster werden hierbei nicht deutlich. Vor allem im Februar (ganzes Gebiet außer NO) und März werden durch LSM häufig zu starke Variabilitäten erzeugt. Durch die Korrekturen wird der regionale Durchschnitt des Bias (Abbildung 5.13) von ursprünglich -48,8–2,3 % (absolut 9,6–49,2 %) auf -48,7–10,3 % (6,5–49,2 %) verändert. Hierbei (vgl. auch Tabelle 5.4) sowie hinsichtlich der prozentualen Verbesserung (Abbildung 5.14, Tabelle 5.5) zeigt sich die geringere Güte von LSM, wobei die Unterschiede deutlich geringer ausgeprägt sind als etwa bzgl. R1mmn. Durch LS erfolgt gemäß Definition im Mittel keine Veränderung.

R95n Im Rohzustand ist die Streuung des aus REMO-Daten berechneten Starkniederschlags im Allgemeinen von topographischen Gegensätzen geprägt: Höhere Lage weisen zu geringe, niedrigere Lagen zu hohe Streuungen auf. Die größten Fehler treten hierbei von Januar bis März auf. Im November sind die zu hohen Variabilitäten in geringeren Höhen stärker ausgeprägt. Durch die Biaskorrektur werden hohe positive Abweichungen auch durch LS abgeschwächt. Die anderen Methoden führen größtenteils zu einer Entfernung der topographischen Kontraste, so dass zu geringe Schwankungen (jedoch mit niedrigeren Beträgen als vor der Korrektur) das Bild beherrschen. Für LSM sind die Restfehler größer als für QM11 und PMPE.

Auch für die regionalen Mittelwerte (Abbildung 5.13) ist nach der Korrektur das Vorherrschen zu geringer Schwankungen sichtbar. Dabei zeigt sich, dass die besten Ergebnisse bei Mittelung der Beträge für QM11 erreicht werden (vgl. Tabelle 5.4). Für alle Indizes und Monate ändert sich der ursprüngliche pBias SD im Regionsdurchschnitt von -6,2–25,6 % (absolut 20,5–54,2 %) auf -21,7–7,9 % (12,0–31,8 %). Hinsichtlich der Verteilung der prozentualen Veränderungen (Abbildung 5.14, Tabelle 5.5) liegen QM11 und PMPE meist recht nah beieinander mit etwas besseren Ergebnissen für QM11. Von September bis November sind auch die LSM-Resultate ähnlich, ansonsten deutlich schlechter. LS führt definitionsgemäß für viele Gitterzellen zu keiner Veränderung, die Häufigkeit der negativen Werte beträgt ca. 5–30 %, die der positiven ca. 35–65 %.

Frosttage Vor der Korrektur ist die Streuung der Standardabweichung von Dezember bis Februar zu hoch (außer z.T. Höhenlagen), im März und November v.a. im SW zu niedrig und in den übrigen Monaten (wo vorhanden) meist zu gering simuliert. Während LS wie erwartet kaum Veränderungen mit sich bringt, zeigt LSM für Dezember–Februar ebenfalls keine sichtbaren Einflüsse. Im März, April (außer zu niedrige Werte SW) und November hingegen liegen nach der LSM-Korrektur zu hohe Schwankungen vor, im Mai und Oktober zeigen sich die für diese Methode geringsten Restfehler. QM11 und PMPE resultieren in einer Verringerung vorhandener regionaler Biasgegensätze und führen in allen Monaten zu Verbesserungen, jedoch fallen diese in den Übergangsmontaten geringer aus. Dies wird auch in Abbildung 5.13 für die regionalen Mittelwerte erkennbar. In Mai, September und Oktober zeigt LSM die größten Korrekturerfolge, ansonsten ist dies für QM11 oder PMPE mit ähnlich hohen Werten der Fall.

Der ursprüngliche Wertebereich des pBias SD von -82,8–31,8 % (absolut 7,5–82,0 %) ändert sich durch die Korrektur kaum (-81,9–33,0 %, ohne VZ 5,2–82,0 %), was v.a. durch die un-

verändert hohen LS-Fehler begründet ist. Die monatlich stärksten positiven wie auch negativen Veränderungen finden sich für LSM (mit und ohne VZ, vgl. Tabelle 5.4). Die sortierten prozentualen Verbesserungen (Abbildung 5.14) verdeutlichen die schlechten LSM-Ergebnisse im März und November mit verringerter Variabilitätsgüte an ca. 85–90 % der Gitterzellen (vgl. negativer Median in Tabelle 5.5). Auch im Januar, Februar, April und Dezember liegen die Linien deutlich unter denen von PMPE und QM11, während im Mai und September mit geringer Werteanzahl sichtbar bessere Ergebnisse erzielt werden. Vor allem im Februar und März beeinflusst LS durch die Wertebereichsbegrenzung auch die Standardabweichungen.

Eistage Ausschließlich in hohen Lagen (Thüringisch-Fränkischer Wald, v.a. Januar) treten unterschätzte Eistagevariabilitäten auf, ansonsten herrschen zu hohe Schwankungen vor, am stärksten im SW im März. Nur nach LS in Dezember und Januar bleiben diese Werte optisch fast unverändert, ansonsten sind deutliche Reduktionen erkennbar, wobei diese bei LSM im Allgemeinen zu einer Umkehr hin zu unterschätzten Standardabweichungen führt. Für QM11 und PMPE treten die größten Restfehler, dann meist negativer Art, im März auf.

Während das regionale Mittel des pBias-SD vor der Korrektur bei 5,1–120,9 % (absolut 5,1–121,8 %) lag, ist es danach mit –34,4–19,1 % (absolut 5,4–34,9 %) deutlich geringer. Durch PMPE werden die regionalen Mittelwerte mit und ohne VZ-Beachtung, durch LSM nur mit VZ-Beachtung in einem Monat verschlechtert (Abbildung 5.13, Tabelle 5.4). Außer LSM (vier Monate negativer Median) führen alle Methoden in allen Monaten an mindestens 50 % der Gitterzellen zu einer Verbesserung (oder gleichbleibenden Werten) der Standardabweichung (Abbildung 5.14, Tabelle 5.4).

Hitzetage Während im Juni zu geringe Schwankungen der Hitzetageanzahl deutlich überwiegen, liegt in den übrigen Monaten kein eindeutiges Bild vor. Vor allem im Juni werden die Fehler nach der Korrektur durch alle Methoden außer LS über fast das gesamte Untersuchungsgebiet deutlich abgeschwächt, insbesondere im Mai und September kommt es z.T. auch zu erhöhten Fehlern und/oder umgekehrten Vorzeichen.

Im regionalen Mittel (mit Vorzeichenbeachtung) treten ausschließlich im Mai und September für QM11 und LSM sowie im Juni und August für LS leicht erhöhte pBias-SD-Werte auf. Während die regionalen pV-Mediane für keinen Monat negativ sind und im Maximum über 60 % liegen, werden auch die Monatsminima der regionalen Mittel von stark negativen Werten

geprägt (Tabelle 5.5). Selbst der monatlich höchste regionale Mittelwert ist für QM11 noch deutlich negativ (-233,7 % Juli). LS stellt durch seine Definition wiederum eine Ausnahme dar.

DMI Im Januar überwiegen zu geringe DMI-Schwankungen im Untersuchungsgebiet. In den übrigen Monaten sind topographische Kontraste prägend (vgl. R1mmn und R95n), mit zu niedrigen Werten in höheren und zu hohen Werten in niedrigen Lagen. Diese sind je nach Monat stärker oder schwächer ausgeprägt. Nach der Korrekturanwendung sind diese Gegensätze (außer für LS mit per definitionem kaum Veränderungen) deutlich verringert, für LSM herrschen dann in den meisten Monaten zu geringe Standardabweichungen vor.

LSM führt ausschließlich im August im regionalen Mittel (mit VZ, ohne VZ Jul.–Nov.) zu einer Verbesserung der Standardabweichung. Auch für die anderen Methoden kommt es in einigen Monaten zu Verschlechterungen (QM11 und PMPE nur mit VZ; vgl. Tabelle 5.4). Insgesamt wird der regionale pBias-SD-Durchschnitt durch die Korrektur von -31,2–13,4 % (absolut 9,1–32,5 %) auf -42,2–11,8 % (absolut -31,2–13,4 %) in seiner Spannweite eher erhöht als verringert. Im Januar–März, Mai–Juli sowie Dezember treten an über 50 % der Gitterzellen nach LSM-Korrektur weniger den Beobachtungsdaten entsprechende Standardabweichungen auf als bei den Rohdaten, für LS beträgt der Median im Februar -13,2 %, in den übrigen Monaten 0,0 %. Im November liegen die sortierten pV-Werte durch LSM nahe an QM11 und PMPE, ansonsten meist deutlich darunter, wobei QM11 und PMPE meist ähnliche Werte aufweisen (QM11 meist etwas besser). Die monatlichen pV-Mittelwerte sind für LSM und QM11 immer negativ, die Median für QM11 und PMPE immer positiv (vgl. Tabelle 5.5).

Tabelle 5.6: Spätfrost: Veränderung des regionalen Mittelwerts Δ [PP] und regionaler Mittelwert der prozentualen Verbesserung [%] von pBias SD durch die Biaskorrektur (in Klammern Δ bzgl. der absoluten pBias-Werte, pV Median). Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| | LS | LSM | QM11 | PMPE |
|--------------|-----------|-------------|--------------|-------------|
| VPT Δ | 0,0 (0,0) | 55,2 (40,0) | 43,9 (39,8) | 41,5 (38,1) |
| VPT pV | 0,0 (0,0) | 64,4 (72,8) | 74,11 (85,5) | 77,4 (81,2) |
| VPM Δ | 0,0 (0,0) | 25,7 (16,8) | 27,0 (24,1) | 28,8 (25,9) |
| VPM pV | 0,0 (0,0) | 11,9 (47,0) | 50,3 (63,2) | -7,4 (71,0) |

Spätfrost Die Standardabweichung beider Spätfrostvarianten wird von REMO ausschließlich zu gering simuliert. Diese Fehler werden durch QM11 und PMPE deutlich verringert, durch

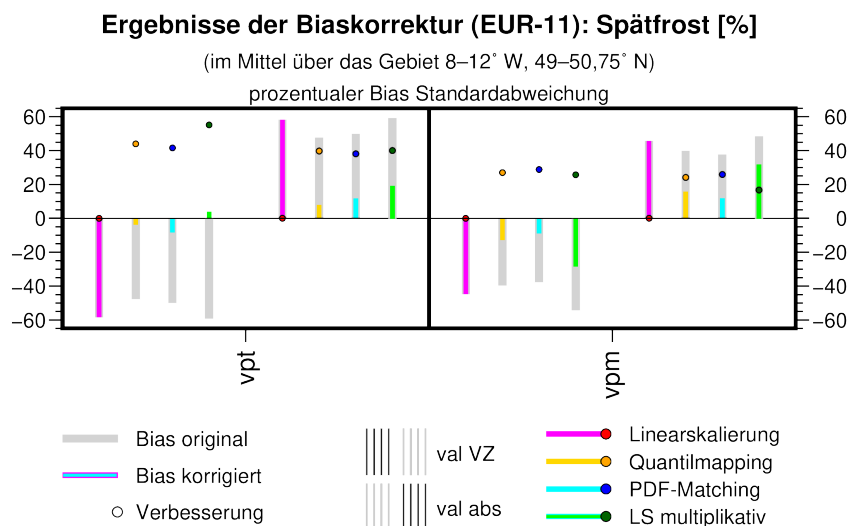


Abbildung 5.15: Biaskorrekturergebnisse prozentualer Standardabweichungsbias Spätfrost: Regionale Mittelwerte (Validierungsperiode) mit Vorzeichenbeachtung sowie auf Basis der Fehlerbeträge. Bias der Rohdaten als grauer Balken, Bias nach Korrektur als farbiger Balken je Korrekturmethode, Verbesserung als farbiger Kreis. Jeweils links mit und rechts ohne Vorzeichenbeachtung.

LSM treten vermehrt zu hohe Variabilitäten auf (v.a. im SW sowie O des UGs). Für QM11 und PMPE bleiben hinsichtlich des VPM-Spätfrost im SW die größten Fehler erhalten, ansonsten zeichnet sich kein klares räumliches Muster ab. Die regionalen Mittelwerte bleiben durch LS unverändert und werden durch die anderen Methoden verbessert.

Der regionale Mittelwert des pBias SD – dargestellt in Abbildung 5.15 – ändert sich für die Spätfrosthäufigkeit bzgl. der thermischen Vegetationsperiode von -58,1 bis -47,4 % (absolut 47,4–58,1 %) auf -58,1–3,8 % (7,6–58,1 %). Die Veränderungen mit und ohne VZ-Beachtung sind für LSM am höchsten, für PMPE am geringsten, die prozentuale Verbesserung ist für PMPE (Mittelwert der Gitterzellen) bzw. QM11 (Median) am stärksten (vgl. Tabelle 5.6).

Definiert in Bezug auf die monatliche Vegetationsperiode wird der ursprüngliche Bias im Regionaldurchschnitt (Abbildung 5.15) von -48,2 bis -37,5 % (absolut 37,5–48,2 %) auf -44,7–10,3 % (11,6–45,4 %) v.a. im unteren Bereich der Spannweite verringert. Die verbleibenden hohen Werte sind durch unveränderte Werte bei LS bedingt. Ansonsten zeigt sich eine Verringerung der Fehler. In Relation zum Ursprungsbias ergeben sich geringere prozentuale Verbesserungen als für VPT. Hierbei ist für PMPE der regionale Mittelwert zwar negativ, der Median jedoch der höchste unter allen angewandten Verfahren. Abgesehen vom genannten PMPE-pV-




Abbildung 5.16: Biaskorrekturergebnisse prozentualer Standardabweichungsbias Spätfrost: Verteilung der prozentualen Verbesserung (Validierungsperiode) dargestellt durch die sortierten Werte aller Gitterzellen je Berechnungsbasis (Farbe) und Korrekturmethode (Linienart). Die x-Achse ist auf die Anzahl der jeweils vorhandenen Werte begrenzt.

Mittelwert bringt LSM die geringsten, PMPE die höchsten VPM-Korrekturerfolge (vgl. Tabelle 5.6).

Insgesamt ist die Korrektur der Standardabweichungsfehlers für QM11 und PMPE am erfolgreichsten. LS führt gemäß seiner additiven Definition nur dann zu Veränderungen, wenn eine Wertebereichsanpassung der Daten erfolgt. Auffallend ist die deutlich geringere Verbesserung, oft auch Verschlechterung (v.a. R1mmn und DMI), der Variabilität durch LSM. Werden die Vorzeichen bei der regionalen Mittelung miteinbezogen, so ergeben sich ungeachtet der Korrekturmethode Verschlechterungen für die Großzahl der Monate des R95n-Indizes. Für den Spätfrost zeigen alle Methoden außer LS deutliche Korrekturerfolge, wobei diese bezüglich VPM für LSM am geringsten sind.

5.2.3 Verteilung: Prozentualer Quantil-RMSE

Ein Blick auf die Karten der pQRMSE-Mittelwerte aller Monate vor und nach der Korrektur (Abbildung 5.17) zeigt für alle Kennwerte und Methoden eine Verbesserung der Verteilungsrepräsentation. Am höchsten ist sie für QM11 und PMPE. Für R95n und DMI sind weiterhin wie in den Rohdaten topographische Muster erkennbar. Die stärksten Abweichungen verbleiben für die Hitzetagehäufigkeit. Eine Erhöhung der regionalen Mittelwerte der prozentualen Quantil-

RMSEs durch die Anwendung der Korrektur ist ausschließlich für die im Oktober simulierten Eistage durch PMPE zu registrieren. Ansonsten treten Verbesserungen auf. Abbildung 5.18 gibt einen Überblick, der in Tabelle 5.7 hinsichtlich der Wertespanssen der Einzelmonate zusammengefasst wird. In Abbildung 5.19 für die sortierten prozentualen Veränderungen liegt der Median für keine Index-Monat-Methoden-Kombination im negativen Bereich. Auch das 25. Perzentil ist meist positiv (Ausnahmen: Extremtemperaturindizes in Übergangsmonaten). Wie auch Tabelle 5.8 verdeutlicht, treten jedoch für Eis- und Hitzetage im regionalen Mittel der prozentualen Veränderungen stark negative Werte auf, für die PMPE-Eistage auch im regionalen Median⁴⁴. Der Inhalt der Abbildungen wird anschließend näher besprochen, ohne durchgängig auf sie zu verweisen.

Tabelle 5.7: Veränderung des regionalen pQRMSE-Mittelwerts durch die Biaskorrektur in Prozentpunkten. Jeweils Wertespanne der Einzelmonate. Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| | LS | LSM | QM11 | PMPE |
|-------|------------|------------|------------|--------------|
| R1mmn | 2,4–9,6 | 2,4–9,5 | 4,7–10,8 | 4,8–10,7 |
| MCD | 2,4–13,6 | 3,2–21,1 | 6,4–25,6 | 5,2–24,8 |
| R95n | 17,1–69,4 | 23,7–86,7 | 20,9–85,8 | 22,1–86,4 |
| Frost | 1,15–42,4 | 1,0–37,6 | 3,6–58,6 | 3,3–61,8 |
| Eis | 21,1–413,0 | 24,3–345,4 | 29,2–251,9 | -132,5–353,6 |
| Hitze | 8,5–159,2 | 9,4–55,7 | 11,8–77,2 | 15,6–104,5 |
| DMI | 11,7–22,2 | 13,1–27,0 | 14,6–30,3 | 16,7–29,3 |

R1mmn Die Rohdaten von REMO weisen im November und Dezember tendenziell in höheren Lagen höhere, ansonsten eher in niedrigeren Lagen höhere pQRMSE-Werte auf. Nach der Korrektur sind diese deutlich abgeschwächt, die höchsten Restfehler bleiben für LSM.

Wie in Abbildung 5.18 zu sehen, verringert die Korrektur den über das Untersuchungsgebiet gemittelten pQRMSE von 9,5–16,2 % auf 4,2–10,2 %. Die beiden Linearskalierungen führen in allen Monaten zu geringeren Korrekturerfolgen als die anderen beiden Methoden (vgl. Tabelle 5.7). Auch relativ zum Ausgangswert zeigen sich die besseren Ergebnisse für QM11 und PMPE (Tabelle 5.8), wobei jeweils die Linearskalierungen und die Verteilungskorrekturen ähnliche Wertespanssen aufweisen.

⁴⁴Oktober, vier gültige Werte, davon ein positiver und drei stark negative.

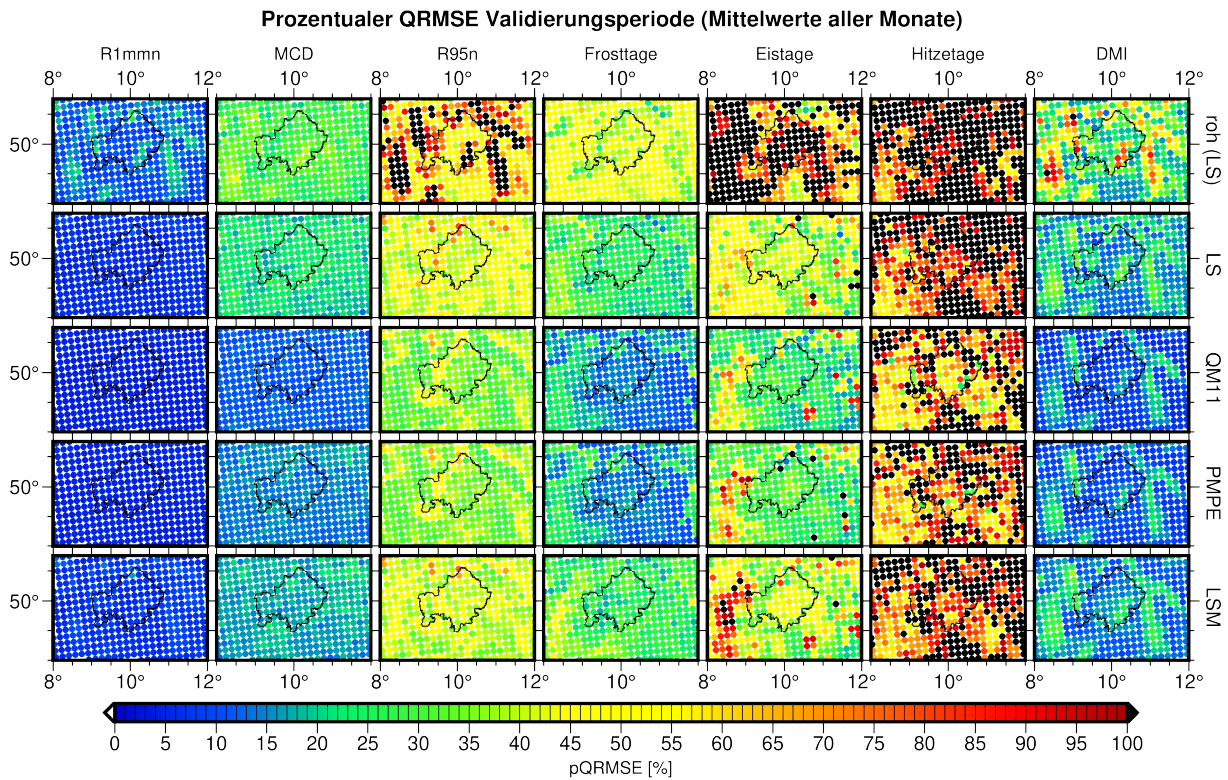


Abbildung 5.17: Modellgüte bzgl. der klimatischen Kennwerte im Validierungszeitraum nach der Biaskorrektur: Prozentualer QRMSE. Karten der Mittelwerte über alle Monate je Index. Werte vor der Korrektur sind hier in der obersten Zeile dargestellt. Letztere unterscheiden sich für Frost-, Eis- und Hitzetage z.T. deutlich von den für den Gesamtzeitraum dargestellten Rohdaten in Abbildung 5.3, da in den Übergangsmonaten nach der Biaskorrektur viele Fehlpixel vorliegen. Hierdurch fallen viele Gitterzellen mit ursprünglich hohen Fehlern aus der Betrachtung, die Rohdaten ohne deren Betrachtung sind im Mittel über alle Monate daher deutlich weniger fehlerbehaftet (v.a. bzgl. der Frosttage)..

MCD Vor der Korrektur treten die höchsten Verteilungsabweichungen der maximalen Trockenperiodenlänge im Januar und Juli auf. Die Simulationen folgen in vielen Monaten für höhere Lagen besser den Beobachtungen als für niedrigere Höhen. Die optisch größten Korrekturerfolge (monatliche Karten nicht gezeigt) ergeben sich durch QM11, gefolgt von PMPE und LSM, während LS die deutlich höchsten Restfehler aufweist.

Dies spiegelt sich auch in den regionalen Durchschnittswerten (Abbildung 5.18, Tabelle 5.7) wider. Für die monatlichen Minima und Maxima sowohl der regionalen Mittelwerte der Veränderungen als auch der pV-Mittelwerte und -Mediane gilt: QM11 > PMPE > LSM > LS (vgl. Tabelle 5.7, 5.8). Die Korrekturen führen insgesamt zu einer pQRMSE-Modifikation von 18,7–48,7 % auf 9,9–36,7 %. Hinsichtlich der Verteilung der Verbesserungen je Gitterzelle führt LS

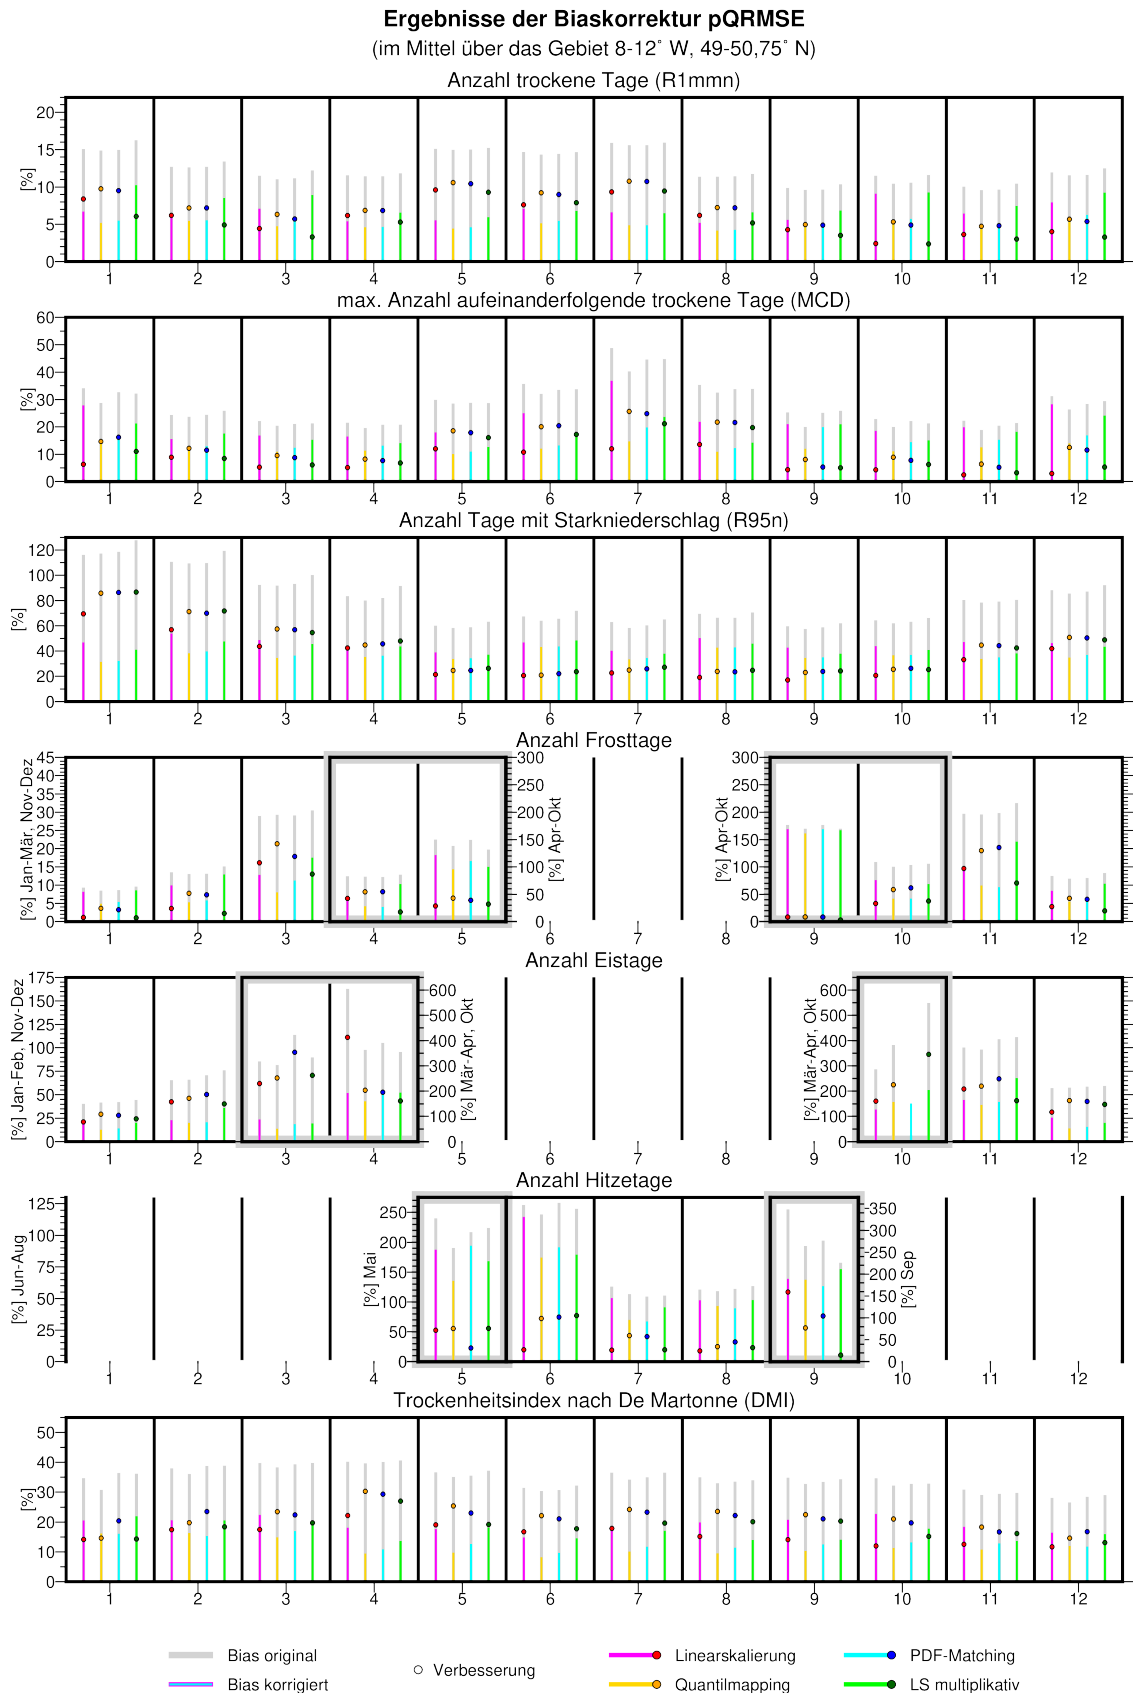


Abbildung 5.18: Biaskorrekturergebnisse prozentualer QRMSE: Regionale Mittelwerte (Validierungsperiode) mit Vorzeichenbeachtung sowie auf Basis der Fehlerbeträge. Bias der Rohdaten als grauer Balken, Bias nach Korrektur als farbiger Balken je Korrekturmethode, Verbesserung als farbiger Kreis. Jeweils links mit und rechts ohne Vorzeichenbeachtung.

Prozentuale Verbesserung des prozentualen QRMSE
sortierte Gitterzellenwerte Validierungszeitraum

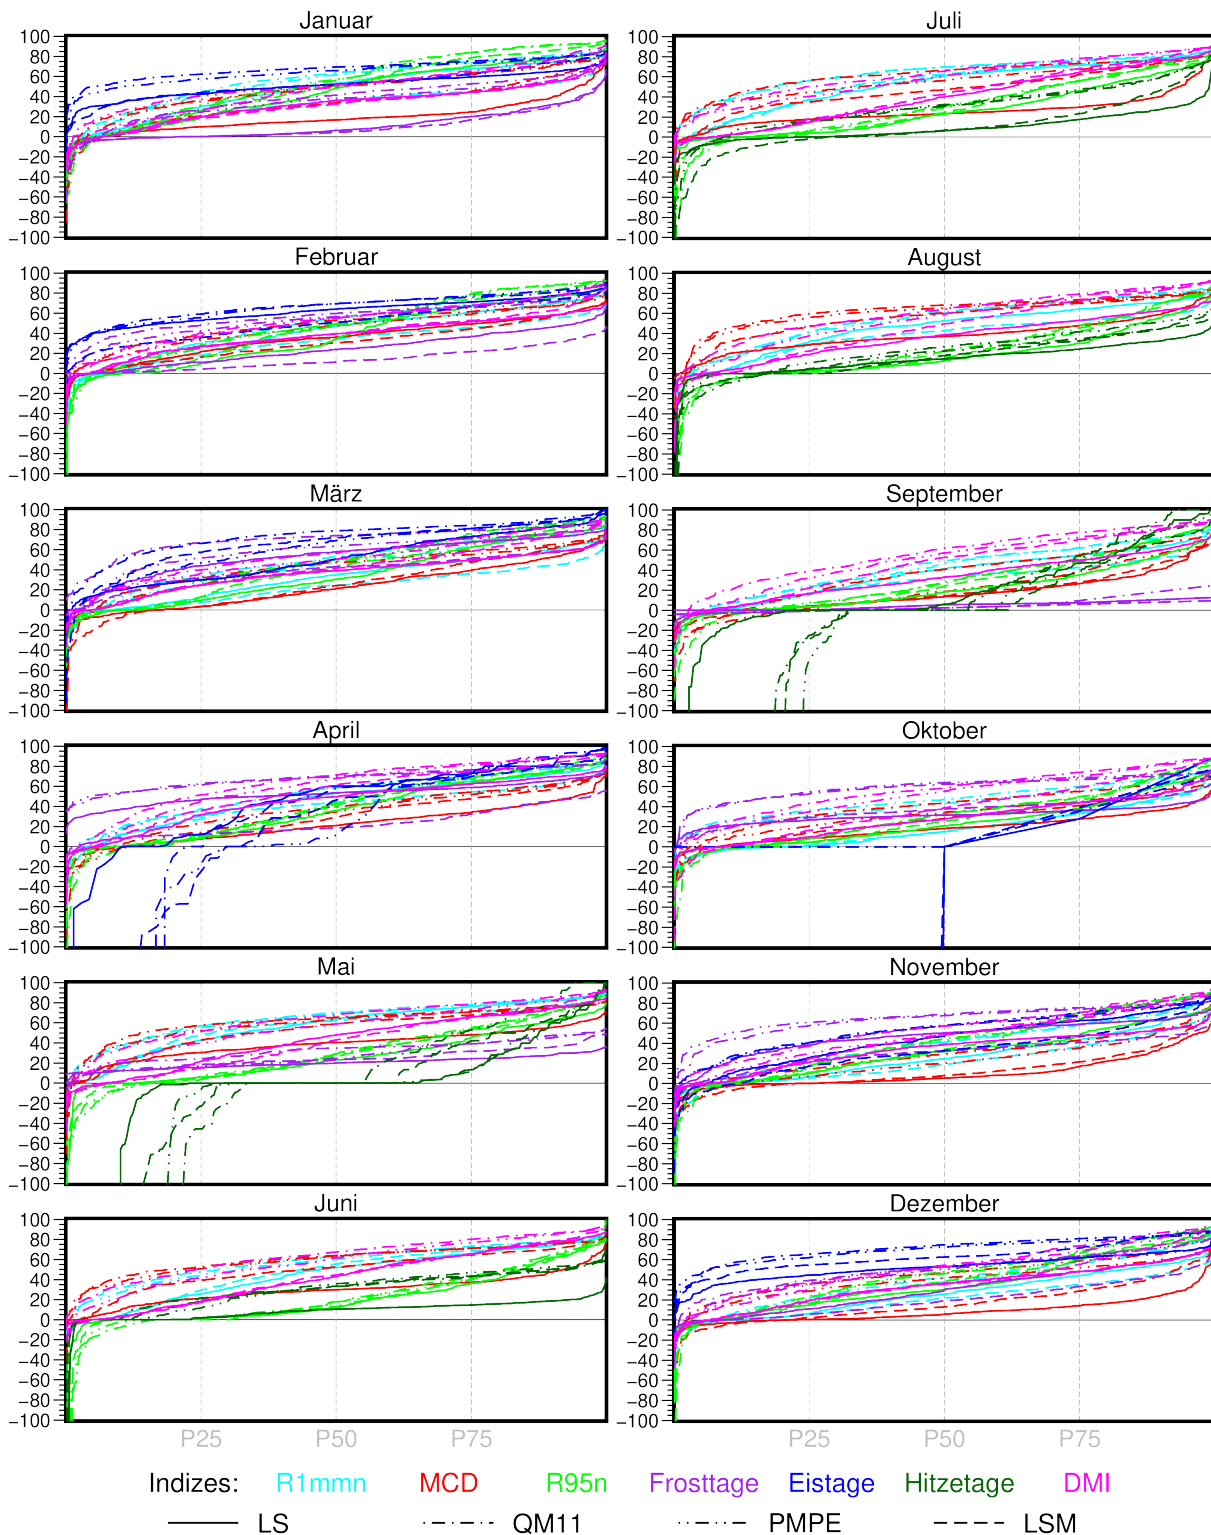


Abbildung 5.19: Biaskorrekturergebnisse prozentualer QRMSE: Verteilung der prozentualen Verbesserung (Validierungsperiode) dargestellt durch die sortierten Werte aller Gitterzellen je Monat, Index (Farbe) und Korrekturmethode (Linienart). Die x-Achse ist auf die Anzahl der jeweils vorhandenen Werte begrenzt.

Tabelle 5.8: Regionaler Mittelwert (Median) der prozentualen pQRMSE-Verbesserung durch die Biaskorrektur. Jeweils Wertespanne der Einzelmonate. Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| [%] | LS | LSM | QM11 | PMPE |
|-------|-----------------------------|-----------------------------|-----------------------------|-----------------------------------|
| R1mmn | 18,6–56,7 (15,1–63,6) | 18,5–55,6 (15,1–62,5) | 38,2–64,8 (41,0–70,5) | 36,6–63,9 (37,9–69,7) |
| MCD | 8,7–38,6 (5,2–40,5) | 12,1–55,7 (7,9–60,4) | 28,8–63,3 (29,3–68,2) | 20,1–61,1 (18,8–65,3) |
| R95n | 12,4–43,7 (11,4–48,6) | 6,1–49,4 (13,1–50,8) | 20,4–52,8 (17,4–57,1) | 13,0–53,7 (18,0–55,9) |
| Frost | 5,1–52,8 (5,5–58,0) | 2,5–39,6 (2,3–43,0) | 6,3–69,9 (2,3–74,1) | 5,1–68,5 (5,5–70,3) |
| Eis | -4736,4–61,7 (0,00–63,9) | -4188,7–65,0 (0,00–71,8) | -4454,4–72,8 (0,00–78,8) | -14158,6–69,9 (-11900,00–72,6) |
| Hitze | -1631,5–9,2 (0,0–14,6) | -5819,5–30,2 (0,0–33,4) | -4423,0–29,6 (0,0–33,1) | -2097,1–30,6 (0,0–35,8) |
| DMI | 28,0–44,4 (27,2–49,8) | 31,2–53,4 (32,6–60,3) | 46,4–63,6 (49,6–71,3) | 47,5–59,3 (49,5–67,9) |

im Februar zu etwas besseren Ergebnissen als LSM, im September hebt sich QM11 positiv von den anderen Methoden ab.

R95n Wie für pBias-SD und pBias-MW zeigen auch die pQRMSEs der rohen REMO-Daten für die Anzahl der Starkregentage deutliche topographische Kontraste. Die höheren Verteilungsabweichungen treten tendenziell in niedriger gelegenen Gitterzellen auf. Von November bis April sind die Fehler im Allgemeinen stärker als von Mai bis Oktober. Die Korrektur verringert sowohl die Gegensätze als auch die Werte an sich, wobei QM11 und PMPE ähnliche und die der anderen Methoden übertreffende Resultate bewirken. Die größten Restfehler zeigen sich nach der additiven Linearskalierung.

Der regionale Mittelwert des pQRMSE – ursprünglich 57,2–127,4 % – beträgt nach der Korrektur 31,1–53,5 %. Der beschriebene optische Eindruck (Karten nicht dargestellt) wird im räumlichen Durchschnitt nur hinsichtlich der geringeren Erfolge von LS deutlich, während die übrigen Methoden ähnliche Ergebnisse erzielen (vgl. auch Tabelle 5.7). Die prozentualen Veränderungen jedoch spiegeln die oben genannten Abweichungen der multiplikativen Linearskalierung von QM11 und PMPE wider (Tabelle 5.8). In allen Monaten liegen die LS-Verbesserungen über fast die gesamte Verteilung unter denen der anderen Verfahren.

Frosttage Die Verteilung der Frosttagehäufigkeiten stimmt in den Wintermonaten Dezember–Februar besser mit den Beobachtungsdaten überein und weicht mit zunehmender Sommernähe

stärker davon ab. Dabei sind die Simulationen für größere Höhenlagen meist besser. Auch der Korrekturerfolg ist in den Übergangsmontaten geringer, die Höhe der Restfehler nimmt von LSM über LS und PMPE zu QM11 ab. Die größten Abweichungen verbleiben weiter in tieferen Lagen, v.a. im SW des Untersuchungsgebietes.

Im regionalen Durchschnitt wird der pQRMSE-Wertbereich nur wenig verändert (Originalbias 8,4–176,1 %, korrigiert 4,7–167,8 %). Abbildung 5.18 lässt erkennen, dass dies durch fast gleichbleibend hohe Fehler im Oktober für alle Methoden begründet ist. In den übrigen Monaten sind die Korrektoreinflüsse meist größer. Die Minima und Maxima der monatlichen Wertespannen der Verteilungskorrekturen liegen über denen der Linearskalierungen (Tabelle 5.7). Wie auch in 5.19 für die prozentuale Veränderung erkennbar wird, liegen die LS-Werte für Mai und Oktober etwas unter LSM, ansonsten sind die LSM-Ergebnisse am schlechtesten. Die Ergebnisse von QM11 und PMPE ähneln sich (regionales Mittel und pV), wobei erstere im Allgemeinen etwas besser sind (vgl. Tabelle 5.8).

Eistage Die Simulationsgüte der Eistagehäufigkeit hinsichtlich der Übereinstimmung der Verteilung nimmt mit Entfernung vom Januar ab. Sie ist dort am geringsten, wo weniger Eistage auftreten: In niedrigeren Höhenlagen. Die Biaskorrektur führt zu deutlichen Verbesserungen, wobei insbesondere im März und weniger stark im November hohe Restfehler im Bereich des Oberrheingrabens verbleiben. Für LS im März (fast ganzes Gebiet außer um Thüringisch-Fränkischen Wald) sowie LSM im November (UG-Westen und -Zentrum) sind diese noch stärker ausgebreitet. Im April und vor allem im Oktober treten – in Beobachtungs- und Modelldaten – nur an wenigen Gitterzellen Eistage auf, deren zeitliche Verteilung durch alle Methoden außer PMPE (Okt.) deutlich verbessert wird, jedoch weiterhin stark von den Beobachtungen abweicht. Der regional gemittelte pQRMSE wird von 17,1–603,6 % auf 12,1–202,2 % verringert. Für PMPE im Oktober wird der pQRMSE erhöht (verschlechtert), ansonsten für alle Monate und Methoden um bis zu über 250 bis über 400 Prozentpunkte verringert. Die regionalen pV-Mittelwerte sind im Mai und Oktober (letzterer nicht QM11) vier- bis fünfstellig (letzteres nur PMPE Oktober) negativ, ebenso wie der PMPE-Median im Oktober. Die höchsten Mittel- und Medianwerte werden von QM11 erreicht.

Hitzetage Ähnlich der Eistagehäufigkeit ist auch die Simulationsgüte der Hitzetage dort besser, wo (und wann) selbige häufiger auftreten: In diesem Fall in den niedrigeren Höhenlagen

im Juli und etwas geringer im August. Im Juni, Mai und September sind die Simulationsgüten deutlich geringer und es treten nicht mehr flächendeckend Ereignisse auf. Die Korrektur führt zu einer Verbesserung der Verteilungsrepräsentation, es verbleiben jedoch für alle Methoden deutliche Restfehler. Gerade im Mai und September kommt es gehäuft zu Verschlechterungen durch die Korrekturanwendung an Gitterzellen, an denen vorher sehr geringe pQRMSE-Werte und Auftretswahrscheinlichkeiten vorherrschten.

Auf das regionale Mittel bezogen verringert sich der pQRMSE von durchschnittlich 41,5–347,1 % auf 31,4–210,5 %. Die Güte der Korrektur je Methode im Vergleich zu den jeweils anderen Methoden ist abhängig vom betrachteten Monat. LS zeigt im September, PMPE im August, QM11 im Juli und LSM im Mai und Juni jeweils die größten absoluten pQRMSE-Verbesserungen. Die monatlichen Wertespanssen sind in Tabelle 5.7 aufgeführt. Die sortierten pV-Werte (Abbildung 5.19) fallen insbesondere im Mai und September häufig unter Null (ca. 20–35 %), sodass die regionalen Mittelwerte für diese Monate drei- bis vierstellig negativ sind. Im Juni oder Juli sind die regionalen Mittelwerte am höchsten. Die Wertebereiche der regionalen pV-Mediane sind für alle Methoden außer LS ähnlich (vgl. Tabelle 5.8).

DMI Wie für die Anzahl der Starkregentage, treten auch beim De Martonne-Trockenheitsindex stärkere Verteilungsabweichungen in topographisch niedriger gelegenen Situationen auf. Von (Dezember) Januar bis April sind die Fehler stärker ausgeprägt als in den übrigen Monaten. Die Korrektur resultiert in einer deutlichen pQRMSE-Abschwächung, wobei die Restfehler von November bis März am größten sind und weiterhin eine topographische Prägung erkennen lassen. Der Korrekturerfolg nimmt von QM11 über PMPE zu LSM und LS ab.

Diese Gütereihenfolge zeigt sich im regionalen Mittel in den Monaten März bis November. Von Dezember bis Februar weist PMPE die besten Ergebnisse auf, gefolgt von QM11, LSM und LS. Der Gebietsdurchschnitt wird von 26,4–40,5 % auf 8,1–22,5 % gesenkt. Hierbei werden durch LS generell die schwächsten, durch QM11 und PMPE die stärksten Veränderungen erreicht (vgl. Tabelle 5.7). Dies wird auch in den prozentualen Verbesserungen sichtbar (Abbildung 5.19, Tabelle 5.8).

Spätfrost Bei thermisch definierter Vegetationsperiode wird die Verteilung der Spätfrostergebnisse am besten im Südwesten des Untersuchungsgebietes simuliert. Auch in höheren Lagen (sowie für die QM11- und PMPE-Perioden im mittleren Südunterfranken) sind die Abweichun-




Abbildung 5.20: Biaskorrekturergebnisse prozentualer QRMSE Spätfrost: Regionale Mittelwerte (Validierungsperiode) mit Vorzeichenbeachtung sowie auf Basis der Fehlerbeträge. Bias der Rohdaten als grauer Balken, Bias nach Korrektur als farbiger Balken je Korrekturmethode, Verbesserung als farbiger Kreis. Jeweils links mit und rechts ohne Vorzeichenbeachtung.

Tabelle 5.9: Spätfrost: Veränderung des regionalen pQRMSE-Mittelwerts Δ [PP] und regionaler Mittelwert der prozentualen pQRMSE-Verbesserung [%] durch die Biaskorrektur (in Klammern pV Median). Positive Werte zeigen eine Verbesserung, negative eine Verschlechterung an.

| | LS | LSM | QM11 | PMPE |
|--------------|-------------|-------------|-------------|-------------|
| VPT Δ | 34,5 | 40,5 | 64,3 | 59,4 |
| VPT pV | 39,4 (38,8) | 45,1 (44,5) | 77,3 (77,9) | 70,4 (71,4) |
| VPM Δ | 45,0 | 18,9 | 57,4 | 57,7 |
| VPM pV | 52,8 (53,4) | 24,4 (19,9) | 69,2 (71,4) | 70,0 (72,3) |

gen geringer als im restlichen Gebiet. Auch nach der Korrektur ist der Fehler im SW am geringsten. Für die Restfehlerhöhe gilt $QM11 < PMPE < LSM < LS$. Dieser optische Eindruck (Karte nicht dargestellt) wird auch im regionalen Mittelwert bestätigt (Abbildung 5.20). Insgesamt wird der pQRMSE hier von 82,9–90,4 % auf 18,6–55,9 % verringert. Die Differenz folgt der umgekehrten Reihenfolge wie die Restfehlerhöhe, gleiches gilt für regionale Mittelwerte und Mediane der Verbesserungen relativ zum Ausgangsfehler (Tabelle 5.9). Nur nach der LSM-Korrektur treten an einigen Gitterzellen verminderte Verteilungsqualitäten auf. Dies wird auch in Abbildung 5.21 sichtbar.




Abbildung 5.21: Biaskorrekturergebnisse prozentualer QRMSE Spätfrost: Verteilung der prozentualen Verbesserung (Validierungsperiode) dargestellt durch die sortierten Werte aller Gitterzellen je Berechnungsbasis (Farbe) und Korrekturmethode (Linienart). Die x-Achse ist auf die Anzahl der jeweils vorhandenen Werte begrenzt.

Die Verteilung des VPM-Spätfrost wird in höheren Höhenlagen tendenziell besser modelliert. Für LSM ergeben sich für den Großteil der Gitterzellen keine gültigen Werte. Nach der Korrektur verbleiben im SW die größten Restfehler. QM11 und PMPE zeigen ähnliche Ergebnisse, LS und v.a. LSM führen zu geringeren Verbesserungen. Im regionalen Durchschnitt beträgt der pQRMSE vor der Korrektur 83,3–87,2 %, danach 25,6–68,3 %. Die Veränderungen der regionalen Mittelwerte sind in Abbildung 5.20 angezeichnet sowie in Tabelle 5.9 aufgeführt. Diese, ebenso wie die die prozentualen Verbesserungen, dargestellt in Abbildung 5.21 und Tabelle 5.9, lassen die besten Ergebnisse für PMPE erkennen. Vor allem im unteren Bereich der Verteilung etwas geringere pV-Werte zeigt QM11, während LS und noch stärker LSM deutlich davon abweichen. LSM führt zu Verschlechterungen an etwa ca. 7 % der Gitterzellen.

Hinsichtlich der Korrekturen im Bezug auf den pQRMSE lässt sich somit Folgendes zusammenfassen: Die beiden Verfahren der Linearskalierung führen generell zu deutlich schlechteren Ergebnissen als die beiden Methoden, die gemäß ihrer Definition eine Verteilungsanpassung beinhalten. Dabei schneidet QM11 meist besser ab als PMPE, LSM besser als LS. Mit einer Ausnahme (Eistagehäufigkeit Oktober PMPE) führen alle vier Methoden in allen Monat-Index-Situationen zu einer Verbesserung der regionalen Mittelwerte. Für den VPT-Spätfrost gilt die gleiche Rangordnung, für VPM hingegen ist PMPE erfolgreicher als QM11 und LS als LSM.

5.2.4 Verteilung: Q-Q-Plots

In Abbildung 5.22 sind die sortierten Werte aller Monate je Index (Farbe) und Korrekturmethode angetragen. Eine solche Darstellung wird Q-Q-Plot (Quantil-Quantil-Plot) genannt und stellt ein rein optisches Evaluierungswerkzeug dar. Die Werte vor der Biaskorrektur sind als gepunktete, diejenigen nach der Biaskorrektur als durchgezogene Linien dargestellt. Sowohl für die einzelnen Monate (nicht gezeigt) als auch beim Verteilungsvergleich aller Monate wie in Abbildung 5.22 führt QM11 im Allgemeinen zur stärksten Annäherung an die Winkelhalbierende, während LSM und LS die schlechtesten Ergebnisse mit sich bringen. Für hohe Werte von R95n und Hitzetagen liegen die QM11-Ergebnisse z.T. weiter entfernt als die der anderen Methoden. Die starken Unterschätzungen von MCD im oberen Verteilungsbereich werden von QM11 am deutlichsten verbessert, jedoch nicht ganz entfernt, sondern in Richtung Maximum verschoben. Gleiches gilt auch für die beiden Spätfrostkennwerte, wie in Abbildung 5.23 erkennbar ist. Hier zeigt sich vor allem für LSM die starke Abweichung mit bis zu 182 (51,4) Spätfrosttagen im Vergleich zu beobachteten 76 (28) Tagen für VPT (VPM).

5.3 Model Output Statistics

Die Validierung der MOS-Ergebnisse erfolgt aufgrund der Methodik zweigeteilt. Zunächst werden die Ergebnisse des Kalibrierungszeitraums für MOS REMO-Eval (Antrieb durch Reanalyse-daten als perfekte Randbedingungen) vorgestellt, also vor der Übertragung auf die Daten des GCM-angetriebenen Regionalmodells. Die Resultate nach diesem Transfer folgen dann.

5.3.1 MOS REMO-Eval

5.3.1.1 Optionen

Wie in Abschnitt 4.4.4.2 beschrieben, erfolgt die Auswahl der Regressionsoptionen durch die Aufstellung unterschiedlicher MLR-Modelle (Multiple Lineare Regression) mit anschließen-




Abbildung 5.22: Biaskorrekturergebnisse Verteilung Indizes: Q-Q-Plots über alle Monate (Validierungsperiode).

dem Gütevergleich. Die gewählte Konstellation wird dann ebenfalls für die GLM-Regression (Generalized Linear Model) verwendet⁴⁵.

Für die monatsaufgelösten Klimakennwerte wird hierbei insgesamt die Kombination pre-co-ztrans2-manlim (im weiteren Verlauf auch pz2 genannt) gewählt:

- pre-co: Begrenzung der Korrelation zwischen den einzelnen Prädiktoren auf $|r| < 0,5$
- ztrans2: Verwendung standardisierter Prädiktorenzeitreihen
- manlim: Manuelle Begrenzung des Wertebereichs der Ergebnisse

⁴⁵Falls die manuelle Wertebereichsbegrenzung Teil der gewählten Optionskombination ist, entfällt diese bei den GLMs, da die (meisten) EDM-Familien bestimmte Definitionsbereiche implizieren

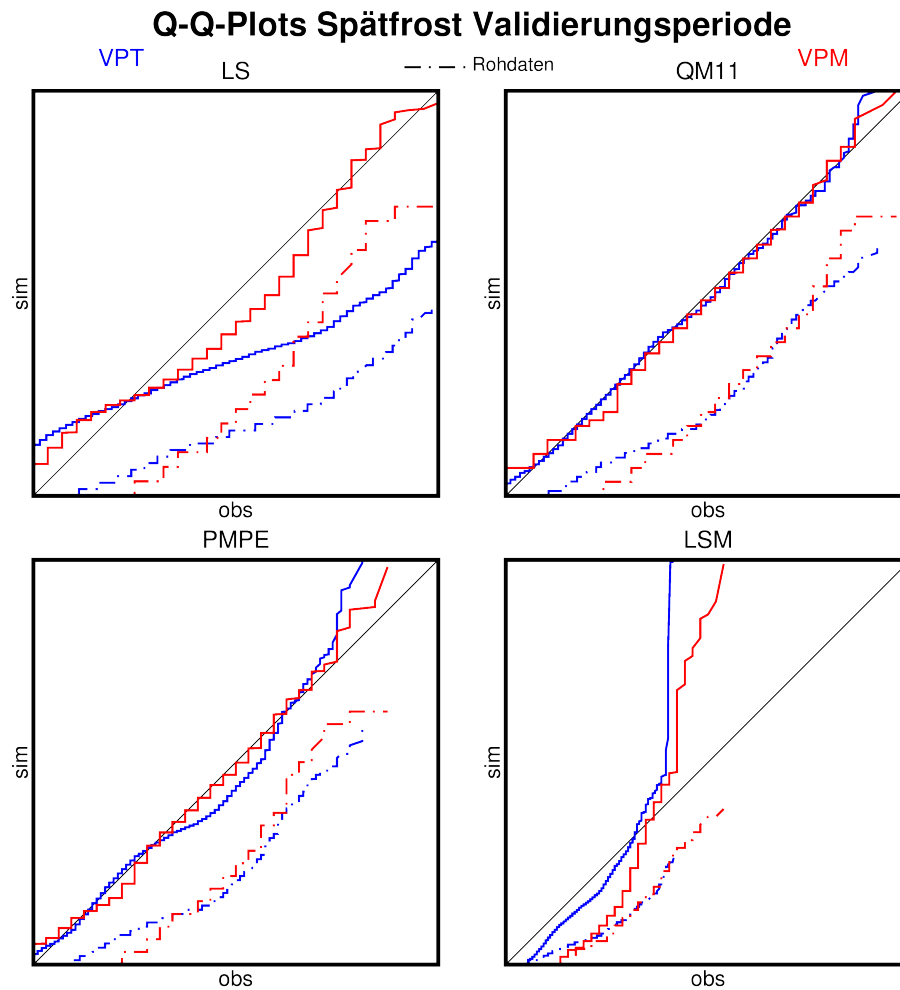


Abbildung 5.23: Biaskorrekturergebnisse Verteilung Spätfrost: Q-Q-Plots (Validierungsperiode).

Für die Spätfrostindizes erhalten `preco-ztrans2-manlim` und `preco-manlim` die maximalen Summensummen. Die Summenprodukte sind wegen negativer MSSS-Werte für alle Methoden null. Die Wahl der EDM-Familie für die GLMs erfolgt vor der Modellaufstellung je Situation (Index, Monat, Raum) für den Gesamtzeitraum, also ohne Bootstrapping. Es wird nur die beste Familie weiterverwendet (siehe 4.4.2, 4.4.4.1). Für den DMI wird in allen Fällen (alle Monate, alle Gitterzellen) ein Gauß-EDM mit log-Link selektiert. Die Ergebnisse der übrigen Indizes inkl. Spätfrost sind in Abbildung 5.24 zu sehen.

Für die maximale Trockenperiodenlänge mit gegebener Poisson-EDM-Familie wird in allen Monaten überwiegend der log-Link gewählt, der Monat mit der höchsten Anzahl an Quadratwurzellinks ist Februar mit 44,9 %. Alle anderen Indizes einschließlich Spätfrost werden mithilfe von Binomial-GLMs simuliert. Für `R1mmn` wird von November bis März sowie im Juli am häufigsten der cloglog-Link, in den anderen Monaten vorwiegend der log-Link selektiert.

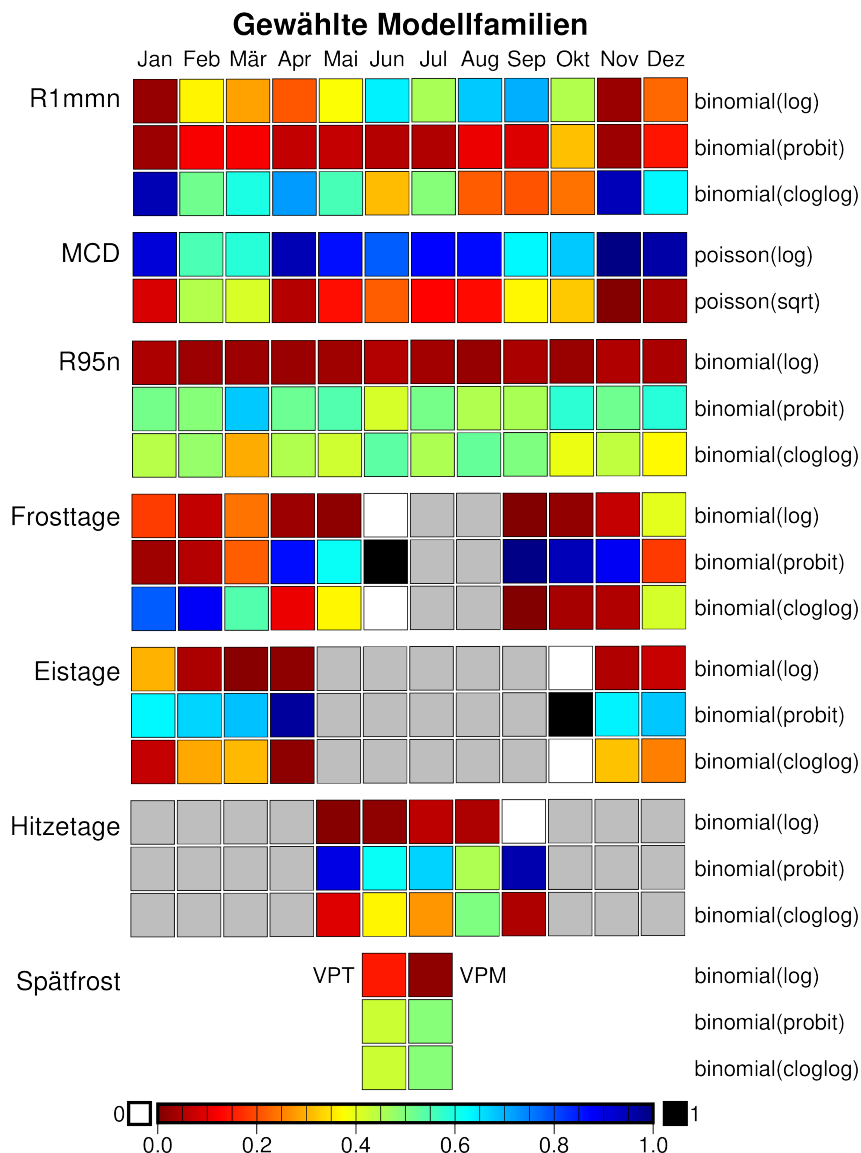


Abbildung 5.24: Gewählte Modellfamilien.

Die Modellierung der Starkregenereignisse ist in den meisten Fällen mit probit-Link am erfolgreichsten, nur im Juni wird der cloglog-Link häufiger gewählt. Bei den Frosttagen ist von Dezember bis März cloglog, von April bis November probit der Link mit den besten Simulationen, im Juni wird ausschließlich probit verwendet. Letzteres gilt für die Eistage im Oktober, bei denen auch sonst der probit-Link überwiegt. Außer im August mit 50,1 % cloglog ist auch für die Hitzetage probit die häufigste Linkfunktion. Für beide Spätfrostindizes halten sich probit- und cloglog-Link die Waage, der log-Link wird selten verwendet.

5.3.1.2 Prädiktoren

Die gewählten Prädiktorvariablen für alle Gitterzellen, Monate und Indizes sowie MLR und GLM sind in Abbildung 5.25 dargestellt. Dabei werden zunächst zwei Umstände deutlich: Zum Einen werden alle Prädiktorvariablen, die für die Simulation zur Verfügung stehen, auch selektiert. Zum Anderen kommen die großräumigen Prädiktoren (PCs) deutlich häufiger zur Anwendung als die lokalen (3×3 -Fenster). Am häufigsten wird hierbei noch der lokale Niederschlag (v.a. durch R1mmn, R95n, DMI) gewählt. Für MLR ist die Temperatur in 500 und 850 hPa die wichtigste erklärende Variable, für GLM der Luftdruck auf Meereshöhe sowie die Bewölkung. Für die einzelnen Indizes und Monate sind die Ergebnisse zum Teil unterschiedlich. Alle folgenden Aussagen beziehen sich, soweit nicht anders genannt, auf die PC-Prädiktoren. Die Einzelmonate werden ohne separate Abbildung besprochen.




Abbildung 5.25: Gewählte Prädiktorvariablen aller Indizes, Monate und Gitterzellen. Je Index links PCs, rechts 3×3 -Fenster. MLR-Ergebnisse in schwarz, GLM-Ergebnisse in grau.

Variablenkürzel siehe Tabelle 4.4.

Für R1mmn wird im Allgemeinen ta500 und ta850 am häufigsten selektiert, im Januar–März ist der lokale Niederschlag jedoch auch sehr wichtig und in vielen Monaten sind u- und v-Wind sowie spezifische Feuchte in unterschiedlichen Höhenlagen von hoher Relevanz für die Simulation. Dies gilt für MLR, für GLM hingegen wird zwar ebenfalls im Januar–März der lokale Niederschlag oft verwendet, ansonsten zeigt sich jedoch eine ausgeglichenerere Verteilung der Prädiktoren. Insgesamt besitzen clt, psl, sfcWind und uas die größten Häufigkeiten.

Auch für MCD (MLR) sind die Temperatur, die Windkomponenten und die spezifische Feuchte in verschiedenen Höhenlagen wichtige Erklärvariablen. Hinzu kommt die geopotenzielle Höhe in 500 hPa. Am seltensten kommen evspsbl, hfls, psl und tas zum Einsatz. Für GLM ist das Bild wiederum ausgewogener, die am meisten zur Anwendung kommenden Prädiktoren sind dieselben wie für R1mmn mit sfcWindmax statt uas.

Die Temperatur in 500 und 850 hPa ist auch für R95n (MLR) am stärksten vertreten, gefolgt von u- und v-Windkomponenten in den gleichen Atmosphärenniveaus. Die Evaporation wird am seltensten verwendet. Die GLM-R95n-Simulation verwendet die Prädiktorvariablen clt, hfss, ps und psl am meisten.

Während ta500, ta850 und hus850 über alle Monate die häufigsten MLR-Frosttageprädiktoren sind, wird im September der bodennahe u-Wind am häufigsten genutzt. Im Dezember, Januar und März übertrifft die Anzahl der lokalen spezifische Luftfeuchteprädiktoren die der PCs. Letzteres gilt hinsichtlich Januar und März auch für GLM. In Bezug auf alle Monate überwiegen die Bewölkung, die spezifische Luftfeuchte in beiden verwendeten Höhen sowie der Niederschlag hinsichtlich ihrer Prädiktorenanzahl. Im September sind v.a. die lokale Windgeschwindigkeit sowie der großräumige v-Wind modellbeeinflussend.

Die atmosphärische Temperatur sowie der v-Wind in allen einbezogenen Niveaus sind die häufigsten Eistageprädiktoren für MLR. Im Oktober übertrifft die Anzahl der lokalen Prädiktoren der sensiblen Wärmeflüsse die der großräumigen und bildet mit hus850, pr und ta850 die Gruppe der zahlenmäßig relevantesten Prädiktoren. Im Februar ist die lokale spezifische Feuchte die meistgewählte Erklärvariable. Insgesamt werden für die Eistage im Vergleich zu den anderen Indizes am häufigsten lokale anstatt großräumige Prädiktoren bevorzugt: Tas und vas im Januar, huss im Februar, tasmin im März und November, hfss im Oktober, tas im Dezember. Auch für GLM ist dies für tasmin im Januar und März sowie huss im Februar (mit Abstand häufigster Prädiktor in diesem Monat) erkennbar. Im Oktober prägen hus850 und tasmin deutlich die Prädiktorauswahl. Ansonsten ist das Bild ausgewogener, tas wird insgesamt am häufigsten selektiert.

Spezifische Feuchte (beide Niveaus), Temperatur (nicht bodennah) und v-Wind (bodennah und 500 hPa) sind die am meisten verwendeten Prädiktoren der MLR-Hitzetagesimulation, wobei wie bei den anderen Indizes auch die übrigen Erklärvariablen Verwendung finden. Für die GLMs wird psl am häufigsten genutzt, gefolgt von sfcWind(max), huss und pr.

Der lokale Niederschlag wird in vielen Monaten und auch in der Gesamtbetrachtung häufiger für die DMI-MLR-Simulation verwendet als die entsprechenden PCs. Werden beide zusammen betrachtet, ist der Niederschlag die am meisten selektierte Variable. Bei allen anderen überwiegen die PCs deutlich, ta850 und ta500 sind hinsichtlich ihrer Anzahl am stärksten vertreten. Auch für die GLMs ist der Niederschlag bei gemeinsamer Betrachtung von lokalen und großräumigen Prädiktoren die häufigste Variable (die lokalen Prädiktoren überwiegen aber seltener

und nicht bei Gesamtbetrachtung), ansonsten werden die PCs von Bewölkung und sensiblen Wärmeflüssen am meisten verwendet.

Insgesamt fällt auf, dass bei der GLM-Simulation häufiger bodennahe Variablen als Prädiktoren zum Einsatz kommen, während bei den MLR atmosphärische Einflüsse stärker vertreten sind. Die Verteilung der Prädiktorenanzahl ist für die GLMs oft weniger differenziert.

Die gewählten Prädiktorvariablen der Spätfrostmodellierung über alle Gitterzellen und beide Indexvarianten sind in Abbildung 5.26 für *preco-ztrans2* zu sehen. Die Ergebnisse unterscheiden sich optisch nur für MLR-VPT und sind auch hier sehr ähnlich. Für GLM führen *preco* und *pz2* zu den gleichen Resultaten. Wie bei den übrigen Indizes überwiegen die PC-Prädiktoren deutlich gegenüber den lokalen Einflussgrößen. Für MLR werden *ua500* und *va500*, für GLM *clt* und *hfss* am häufigsten verwendet.




Abbildung 5.26: Gewählte Prädiktorvariablen aller Spätfrostindizes und Gitterzellen *preco-ztrans2*.

5.3.1.3 Anzahl Gitterzellen mit gültigem Modell

Einen Überblick über gültige MLR-Gitterpunkte gibt Abbildung 5.27. Die GLM-Ergebnisse sind im Groben ähnlich, aber etwas schlechter. Unterschiede und Details werden im Folgenden beschrieben:

Sowohl bei MLR als auch bei GLM kann für R1mmn im April an drei, für MCD im Dezember an zwei Gitterzellen kein gültiges MOS-Modell gefunden werden. Auch hinsichtlich der Starkregentage stimmt die Anzahl der gültigen Gitterpunkte überein, mit Ausnahme von Februar und März, für die jeweils eine Gitterzelle mehr durch GLM modelliert werden kann. Im März, Juni, Juli und September finden sich 670–696, ansonsten über 700 von möglichen 720 Modellen. Frost-, Eis- und Hitzetage besitzen in Juni–August bzw. Mai–Oktober bzw. Oktober–April




Abbildung 5.27: Anzahl der Gitterzellen mit gültigen MLR-Modellen je Index und Monat.

keine gültigen Werte. Bezüglich Ersterer bleibt zudem im Mai (582 zu 607), September (8 zu 10) und Oktober (713 zu 714) Modellkonstruktion für GLM an mehr Zellen als für MLR ohne Erfolg, ansonsten sind mindestens 717 Punkte abgedeckt. Auch hinsichtlich Zweiterer finden sich in März (522 zu 544), Oktober (5 zu 7) und November (700 zu 712) weniger GLM- als MLR-Modelle, ansonsten wird von beiden das gesamte Gebiet abgedeckt. In jedem Monat mit gültigen Modellen der Hitzetage sind dies für GLM 2–71 Gitterzellen weniger als für MLR, nur im Juli wird von MLR die maximale Gitterzellenzahl erreicht. Bei der MLR-Modellerstellung resultieren für DMI von Februar bis November keine Fehlpixel, bei der GLM-Konstruktion im April 82 sowie im September einer. Im Januar werden 661 (GLM) bzw. 666 (MLR) Gitterzellen simuliert, im Dezember 312 bzw. 325.

Hinsichtlich der Spätfrosthäufigkeit auf Basis der monatlichen Vegetationsperiode resultiert bei beiden MLR- und GLM-Varianten ein Fehlpixel, auf Basis der thermischen Vegetationsperiode finden sich für alle Gitterpunkte Modelle.

5.3.1.4 Modellgüte

Während für die Biaskorrektur und MOS REMO-ESM keine zeitliche Korrespondenz der korrigierten bzw. simulierten Werte zur Realität vorliegt, können die MOS REMO-Eval-Ergebnisse direkt mit Beobachtungsdaten verglichen werden. Daher ist eine Betrachtung von MSSS und R^2 möglich⁴⁶:

Die über alle Gitterzellen und Monate gemittelten MSSSs der klimatischen Kennwerte (Abbildung 5.28) bei den MLR-Simulationen fallen außer für die Anzahl der Eistage negativ aus, die R^2 -Durchschnittswerte liegen zwischen 0,56 (DMI) und 0,72 (Eistage). Über das ganze Jahr betrachtet gilt also: Der Großteil der Schwankungen wird hinsichtlich ihrer Position erfasst, der Fehler innerhalb der Simulation übersteigt jedoch fast immer die interne Variabilität (Schwankungsbreite). Wird die Modellaufstellung anhand von GLMs mit vorher gewählten EDM-Familien durchgeführt, sind die Ergebnisse im Mittel aller Monate für alle Indizes schlechter. Die MSSS-Werte sind immer negativ, die Determinationskoeffizienten reichen von 0,44 (R95n) bis 0,61 (Eistage). Für vier Index-Monat-Situationen ergibt sich bei den GLM- ein etwas höheres R^2 (maximale Differenz 0,06) als bei den MLR-Modellen.




Abbildung 5.28: Qualität MOS REMO-Eval: MSSS und R^2 Klimaindizes (über alle Gitterzellen und Monate gemittelt). Werte < -1 werden nicht gezeigt.

Die besten Übereinstimmungen mit den Beobachtungsdaten finden sich für die Anzahl der Eistage im Januar (MLR), dargestellt in Abbildung 5.29. Hier beträgt der MSSS 0,78, das Bestimmtheitsmaß 0,89.

Für den Spätfrost (Abbildung 5.30) sind die MLR-Ergebnisse für pre-co-ztrans2-manlim und pre-co-manlim sehr ähnlich. Die regionalen MSSS-Durchschnittswerte sind für VPT deutlich

⁴⁶Hierbei ist jedoch zu beachten, dass der Kontrollzeitraum sich nur über 4 Jahre (2009–2012) erstreckt.




Abbildung 5.29: Anzahl der Eistage: Vergleich MOS REMO-Eval und Beobachtungsdaten Januar (MLR). Regionale Minima, Mittelwerte und Maxima.

(-4,55 bzw. -4,97), für VPM leicht negativ (-0,08 bzw. -0,09). Das Bestimmtheitsmaß liegt für VPT unter 0,5 (0,41 bzw. 0,42), für VPM leicht darüber (0,53, beide Methoden). Anders ausgedrückt: Der Simulationsfehler ist (regional gemittelt) größer als die internen Schwankungen, deren Lage wird jedoch für VPM in den meisten Fällen beschrieben. Auch hier ergeben sich durch die GLM-Simulationen geringere Werte. Die Ergebnisse für preco und preco-ztrans2 sind identisch. Der MSSS beträgt -11,44 (VPT) bzw. -3,05 (VPM), R^2 0,40 (VPT) bzw. 0,45 (VPM).




Abbildung 5.30: Qualität MOS REMO-Eval: MSSS und R^2 Spätfrost preco-ztrans2. Farben siehe Abbildung 5.28. Werte < -1 werden nicht gezeigt.

Da MOS REMO-Eval nur einen Zwischenschritt zu MOS REMO-ESM und damit möglichen Zukunftsprojektionen darstellt, wird an dieser Stelle von einer detaillierteren Ergebnisuntersuchung abgesehen.

5.3.2 MOS REMO-ESM

Für die Evaluierung der Indexsimulationen auf Basis von REMO-ESM wird der Zeitraum 1951–1980 verwendet, wobei es sich um einen (quasi-)unabhängigen Zeitraum handelt, da mit dem Jahr 1980 ein Jahr Überschneidung zum Zeitraum der REMO-Eval-Daten besteht. Anders als

bei der Biaskorrektur können die MOS-Ergebnisse nicht im Vergleich zu Ausgangsfehlern vor der Simulation betrachtet werden. Im Synthesekapitel 5.4.1 erfolgt eine Gesamtgegenüberstellung mithilfe der berechneten Indizes.

5.3.2.1 Durchschnittswerte: Prozentualer Bias der arithmetischen Mittel

Abbildung 5.31 zeigt die Resultate der REMO-ESM-Model Output Statistics bezüglich des prozentualen Mittelwertbias im Mittel aller Monate, Abbildung 5.32 im regionalen Durchschnitt. Wie bereits in Kapitel 5.2 sind in letzterer auch die arithmetischen Mittel der Fehlerbeträge angetragen, um sich aufhebende gegensätzliche Fehler sichtbar zu machen. In den Abschnitten zu den einzelnen Kennwerten werden die beiden Abbildungen nicht immer dezidiert genannt, die Beschreibungen beziehen sich jedoch darauf (räumliche Verteilung Durchschnittsfehler aller Monate in Abbildung 5.31, regionale Mittelwerte Fehler je Monat in Abbildung 5.32).

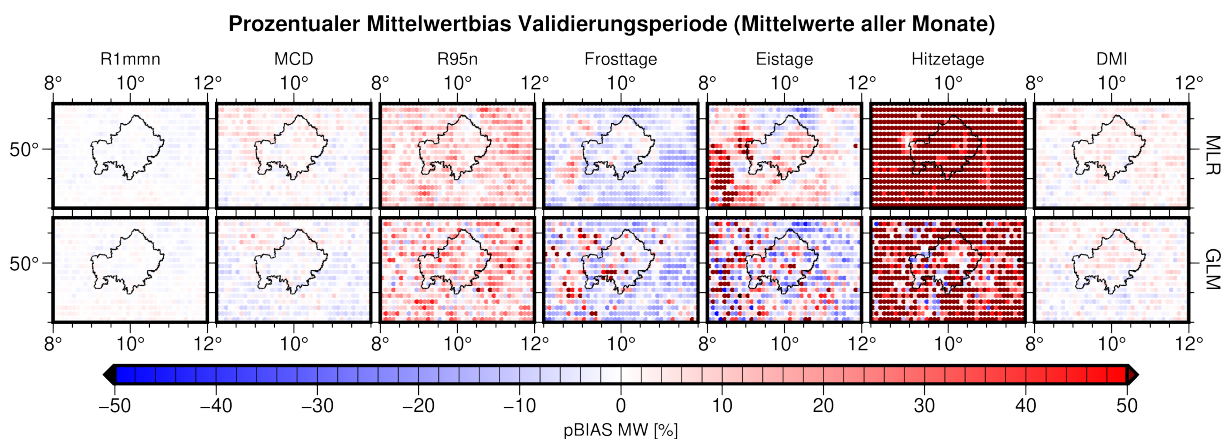


Abbildung 5.31: Modellgüte bzgl. der MOS-simulierten klimatischen Kennwerte 1951–1980:

Prozentualer Mittelwertbias. Karten der Mittelwerte über alle Monate je Index.

R1mmn Der regional gemittelte prozentuale Mittelwertbias der Trockentageanzahl liegt zwischen -6,0 und 8,2 % (bei Mittelung der Beträge 3,2–8,3 %). Die Fehler auf Basis von GLM sind etwas höher (-6,2–8,2 % (Mittelwert -0,0 %), ohne VZ 3,3–8,3 % (4,9 %)) als basierend auf MLR (-6,0–6,6 % (-0,5 %), absolut 3,2–6,9 % (4,5 %)). Im April–Juni und August wird die Trockentageanzahl im Regionsdurchschnitt über-, im März, Juli, Oktober und Dezember unterschätzt (gleiche Vorzeichen GLM und MLR). In den übrigen Monaten liegen die mittleren Fehler bei maximal -1,2 %. Die stärksten Abweichungen (mit und ohne VZ-Beachtung) werden im August erreicht. Bei der räumlichen Betrachtung (Mittelwert siehe Abbildung 5.31, Monate




Abbildung 5.32: Ergebnisse MOS REMO-ESM prozentualer Mittelwert-Bias 1951–1980: Regionale Mittelwerte mit Vorzeichenbeachtung (ausgefüllte Balken) sowie auf Basis der Fehlerbeträge (ungefüllte Balken). Jeweils MLR in schwarzer, GLM in grauer Farbe.

nicht gezeigt) sind die Ergebnisse beider Methoden ähnlich. Es zeigen sich negative Fehler im März, Juli (außer SW, z.T. SO), Oktober und Dezember über den Großteil des Untersuchungsgebietes, während in April, Juni (letzter v.a. im Zentrum und verstreut im Norden auch negative VZ) sowie August positive Abweichungen vorherrschen. Zu niedrige Trockentagehäufigkeiten treten im Januar v.a. im Osten und Nordosten (MLR stärker ausgeprägt), im Februar von SW bis NO, im Mai im SW und teilweise SO, im September in NW, Mitte und NW sowie im November im gesamten Osten für beide Methoden auf.

MCD Auch die maximale Trockenperiodenlänge wird im regionalen Mittel im März, Juli, Oktober und Dezember zu niedrig simuliert sowie zusätzlich im April und September (MLR und GLM). Im Februar, Mai, Juni und August hingegen ist sie zu hoch. Insgesamt reichen die Fehler von -21,1 bis 21,3 % (absolut 7,5–22,7 %). Die Fehlerspanne mit VZ-Beachtung liegt für MLR bei -18,0–19,5 % sowie für GLM bei -21,1–21,3 % (jeweils Min. Mär., Max. Mai). Auch die absoluten Abweichungen sind im Mai am höchsten (20,2 % MLR, 22,7 % GLM). Für die meisten Monate ähneln sich die räumlichen Verteilungen der Fehler für MLR und GLM. Die größten Unterschiede werden im November (MLR im Westen mehr positive Vorzeichen) und Dezember (MLR im NW und SO mehr positive VZ) erkennbar. Im Februar, März, Mai und Oktober (sowie GLM Nov. und Dez.) sind die Vorzeichen des räumlichen Mittelwertes über das gesamte Gebiet vorherrschend, ansonsten zeigt sich mehr Heterogenität. Im Mittel über alle Monate sind auf MLR-Basis positive Fehler stärker verbreitet als auf GLM-Basis (siehe Abbildung 5.31).

R95n Außer im Juni (beide Methoden), August (MLR) und mit geringen Fehlern im Dezember (beide), wird die Anzahl der Starkregeneignisse im Regionsdurchschnitt immer zu hoch simuliert, am stärksten im Mai. Die Monatswerte liegen zwischen -10,7 und 34,9 % (MLR, MW 9,5 %) bzw. -8,3 und 30,3 (GLM, 10,9 %). Vor allem im August, Oktober und Dezember wird der Einfluss gegensätzlicher Vorzeichen auf den Mittelwert erkennbar. Ohne VZ-Beachtung sind die Durchschnittswerte auch im Jahresmittel höher mit 19,3 % für MLR (13,7–39,0 %) und 30,6 % für GLM (25,7–39,0 %). Auch wird bei Entfernen der Vorzeichen vor der Mittelung die schlechtere GLM-Simulationsgüte bezüglich aller Monate deutlich. Diese ist auf der Kartendarstellung der Mittelwerte über alle Monate (Abbildung 5.31) zu erahnen, jedoch bei der Betrachtung der Einzelmonate stärker ausgeprägt (Abbildung nicht gezeigt). Zudem wir-

ken die Fehler diffuser, weniger regelhaft im Raum verteilt, während für MLR mehr Cluster vorliegen.

Frosttage Die Häufigkeit der Frosttage (regionale Mittelwerte der Fehler) wird von den MLR-Simulationen im Mai sowie September–November, von den GLM-Simulationen im Oktober und November überschätzt, ansonsten unterschätzt. Im Mittel über alle Monate ergeben sich prozentuale Abweichungen von -9,5 % (MLR, -34,2–16,0 %) bzw. 1,5 % (GLM, -21,9–26,6 %). Die absoluten Fehler betragen im Durchschnitt 18,1 % (MLR 4,0–47,9 %) bzw. 30,5 % (GLM 4,0–100,0 %). Die größten Fehlerbeträge treten in den Übergangsmo­naten zum Sommer auf. Eine topographische Einordnung der Fehler ist im Durchschnitt aller Monate nicht klar erkennbar: Zu viele Frosttage treten z.B. im westlichen Odenwald, in der Wetterau und den Haßbergen auf (MLR, GLM z.T. übereinstimmend, oft diffus). Auch in den einzelnen Monaten ist das Bild nicht klarer, die Ergebnisse von MLR und GLM weisen jedoch häufig Ähnlichkeiten auf. Im Mai weisen die GLM-Simulationen räumlich verteilt starke Unter- sowie Überschätzungen auf, während für MLR außer im Bereich der Haßberge zu geringe Häufigkeiten deutlich überwiegen. In den niedrigen Höhenlagen im Westen und Südwesten existieren keine Modelle. Die Septemberwerte beruhen auf wenigen Gitterzellen im Bereich der nördlichen Fränkischen Alb sowie im Mittelfränkischen Becken, welche für MLR vorwiegend negativ, für GLM vorwiegend positiv sind.

Eistage Räumlich betrachtet (Durchschnittswerte aller Monate) zeigt sich in der Westhälfte des betrachteten Gebietes auf MLR-Basis eine deutliche Tendenz zu überschätzten Eistagehäufigkeiten in niedrigen Höhenlagen. Im Osten ist dies weniger ausgeprägt, die stärksten negativen Abweichungen finden sich zwischen östlicher Rhön und westlichem Thüringer Wald. Für GLM ist kein klares Muster erkennbar. Die einzelnen Monate ergeben sich unterschiedliche Muster: Für beide Methoden liegen im Januar v.a. im Oberrheingrabenbereich (GLM stärker und größere Ausbreitung) sowie in der nördlichen Mitte des Untersuchungsgebietes zu niedrige Anzahlen vor, im Februar hingegen im Bereich der Rhön und des Thüringisch-Fränkischen Waldes, im Rest der Region werden größtenteils zu viele Eistage simuliert. Im Dezember wiederum hebt sich der Oberrheingrabenbereich einschließlich Kraichgau (GLM auch Wetterau) sowie das zentrale Unterfranken (MLR hier schwächer) mit stärkeren negativen Fehlern vom übrigen Gebiet mit leichteren Unter- und Überschätzungen ab. Weniger Übereinstimmung zwischen MLR und GLM ist im März (MLR positive Kraichgau und Haßberge, sonst meist negativ,

GLM diffuser) und November (MLR überwiegend positiv, am stärksten im SW und allgemein niedrigeren Lagen, GLM diffus) erkennbar. Für Oktober existieren nur wenige Werte im Gebiet des Thüringer Waldes (+ MLR eine Gitterzelle Fichtelgebirge).

Im Durchschnitt wird das Auftreten von Eistagen von MLR um 21,4 % (Abweichungen Einzelmonate -17,2–79,5 %) überschätzt, von GLM um 10,0 % unterschätzt (Abweichungen Einzelmonate -96,6–40,3 %). Das negative Vorzeichen der GLM-Fehler ist v.a. durch die starken Unterschätzungen im Oktober bedingt, auch im Dezember ist der Mittelwert negativ. Letzteres gilt auch für den MLR-pBias, wo zusätzlich im März zu geringe Häufigkeiten resultieren. Werden die Vorzeichen außer Acht gelassen, liegen die mittleren Fehler bei 41,3 % (MLR 10,4–119,6 %) bzw. 48,3 % (GLM 15,0–96,6 %).

Hitzetage Im regionalen Mittelwert ausschließlich überschätzt wird die Anzahl der modellierten Hitzetage. Am stärksten ist dies im Mai (MLR 175,6 %, GLM 306,6 %, absolut 176,3 bzw. 371,3 %), am schwächsten im Juli (GLM 42,3 %, ohne VZ 50,7 %) bzw. September (MLR 30,4 %, ohne VZ 50,1 %) der Fall. Durchschnittlich ergeben sich somit für MLR 109,8 % (ohne VZ 114,0 %) sowie für GLM 147,4 % (185,9 %) Abweichung. Sowohl in den Einzelmonaten als auch darüber gemittelt weist die MLR-Simulation räumlich gesehen über fast das gesamte Gebiet zu hohe Häufigkeiten auf. Auffällig ist das Gebiet um Hanau (um und außerhalb der NW-Spitze Unterfrankens) mit negativen Fehlern im Mai und September sowie geringen Fehlern im Juni und Juli, was im Jahresmittel zu sehr geringen Abweichungen führt. Zu geringe Häufigkeiten treten zudem im September an einer Linie von etwa Karlsruhe bis Bamberg, den modellierbaren Gitterzellen im Südosten sowie z.T. in der Südhälfte Unterfrankens auf (Großteile des Nordens, Ostens und Südostens ohne gültige Modelle). Wie schon bei den meisten anderen Indizes sind auch die GLM-Hitzetagefehler deutlich heterogener im Raum verteilt als die auf MLR-Basis. Zu hohe Häufigkeiten überwiegen von Juni–August deutlich, sind aber von negativen Abweichen durchbrochen.

DMI Die regional gemittelten DMI-Simulationsfehler für MLR und GLM besitzen in allen Monaten die gleichen Vorzeichen: Im Januar, April, Juni und August sind die Werte zu niedrig (zu trockene Bedingungen modelliert), ansonsten zu hoch (zu feucht). Der MLR- ist im Durchschnitt mit 1,9 % (-16,3–17,4 %) etwas höher als der GLM-pBias mit 0,6 % (-17,8–11,1 %). Bei Mittelung der Beträge nähern sich die Werte(-spannen) noch etwas an (MLR 11,7 % (7,6–

18,7 %), GLM 12,1 % (8,3–18,8 %)). In Abbildung 5.31 zeigen sich über alle Monate gemittelt geringe Abweichungen des DMI im gesamten Gebiet mit negativen Tendenzen etwa im SW des Untersuchungsgebietes sowie SO, während im Rest Unterfrankens sowie im UG-NW eher positive Vorzeichen erkennbar werden. Diese niedrigen Durchschnittsfehler setzen sich jedoch aus gegensätzlichen Richtungen der Abweichungen der Einzelmonate zusammen (Ergebnisse MLR und GLM soweit nicht anders genannt ähnlich): Im Januar, April, Juni, August überwiegen negative pBias-Werte, in der genannten Reihenfolge an Häufigkeit bzw. Stärke zunehmend, wie auch an den Durchschnittswerten in Abbildung 5.7. Im Februar überwiegen im Osten positive Vorzeichen. Im März und Mai liegen die optisch größten Unterschiede zwischen GLM und MLR vor: Die MLR-Ergebnisse sind fast überall zu hoch, während die GLMs im Mittelfränkischen Becken eher zu niedrige Werte simulieren. Im Juli sind im Zentrum und NO positive Fehler vorherrschend, im September fast überall außer im SW. Eine etwa meridionale Zweiteilung findet sich im Oktober (Westen (stärker) positiv, Osten (schwächer) negativ) und November (Westen negativ, Osten positiv).

Spätfrost Wie Abbildung 5.33 (linke Spalte) zeigt, wird die Anzahl der Spätfrosttage mit thermischer Vegetationsperiodendefinition im regionalen Durchschnitt von allen Methoden über, mit monatlicher von allen Methoden unterschätzt. Diese Vorzeichen herrschen jeweils über den Großteil des UGs vor⁴⁷, für den VPT-Spätfrost treten im NW (für GLM stärker und z.T. auch in anderen Regionen außer (S)W-Unterfranken und SW des Gebietes) im gitterzellenweisen Nebeneinander zu den negativen auch positive Abweichungen auf. Der VPM-Spätfrost wird nur an wenigen Gitterpunkten überschätzt. Die räumlichen Mittelwerte betragen für VPT 23,1–36,2 % (ohne VZ-Beachtung 29,4–38,3 %, Minimum GLM pz2, Maximum MLR preco), für VPM -27,6 bis -25,6 % (26,6–29,3 %, schlechtester GLM preco, bester GLM pz2 mit VZ, MLR pz2 ohne VZ). Anders als für die REMO-Eval unterscheiden sich die beiden GLM-Varianten⁴⁸ für die REMO-ESM-Ergebnisse.

Im Allgemeinen ergibt sich folgendes Bild: Die größten Mittelwertfehler treten für die Simulation der Temperaturkenntage und hierbei für die Hitzetage – mit im regionalen Durchschnitt ausschließlich Überschätzungen – auf. Ansonsten liegen die regional gemittelten pBias MW

⁴⁷Räumlich betrachtet zeigen preco und pz2 jeweils keine deutlichen Unterschiede.

⁴⁸Also mit und ohne Standardisierung der Prädiktorzeitreihen.

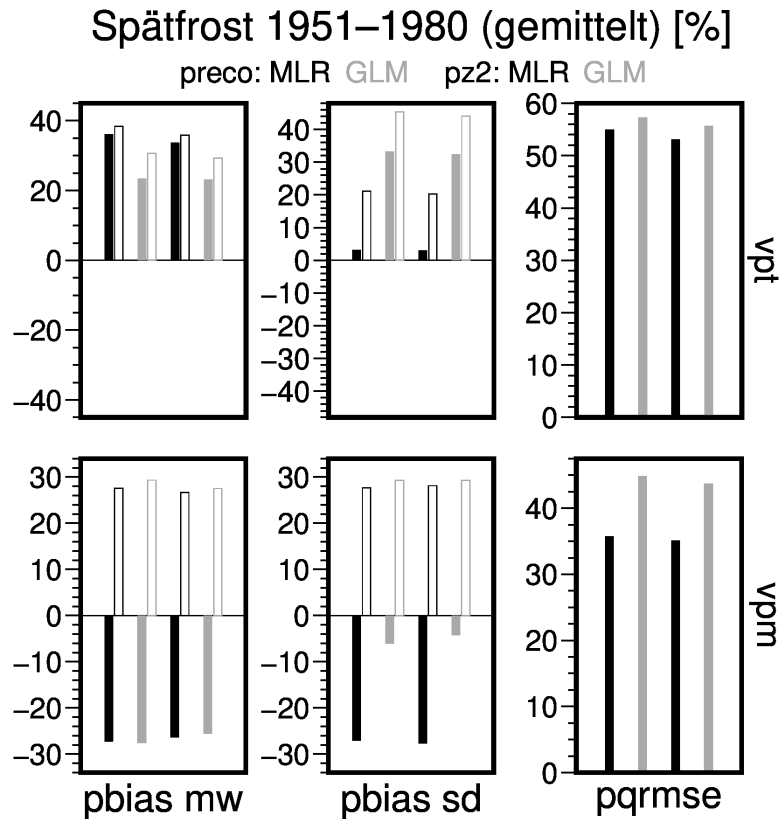


Abbildung 5.33: Ergebnisse MOS REMO-ESM Spätfrost 1951–1980: Regionale Mittelwerte prozentualer Bias Mittelwert und Standardabweichung sowie $pQRMSE$ mit Vorzeichenbeachtung (ausgefüllte Balken) sowie auf Basis der Fehlerbeträge (ungefüllte Balken, für $pQRMSE$ identisch). Jeweils MLR in schwarzer, GLM in grauer Farbe.

unter 50 %, für MCD und DMI unter 25 %, für R1mmn unter 10 %. Je nach Monat und Methode sind die Werte hierbei zu hoch oder zu niedrig. Ob MLR oder GLM bessere Ergebnisse erzielt, ist situationsabhängig. Beim Spätfrost wird die VPT-Version im regionalen Mittel ausschließlich über- (MLR stärker als GLM, < 40 %), VPM nur unterschätzt (< 30 %).

5.3.2.2 Streuung: Prozentualer Bias der Standardabweichungen

Wie für die Mittelwertfehler sind auch für die Standardabweichungsfehler die Karten der über alle Monate gemittelten Werte (Abbildung 5.34) sowie die regionalen Durchschnittswerte je Monat (Abbildung 5.35) dargestellt. Sie dienen als Anschauungsbasis für die folgenden Ausführungen und werden nicht für jeden Kennwert explizit genannt.




Abbildung 5.34: Modellgüte bzgl. der MOS-simulierten klimatischen Kennwerte 1951–1980: Prozentualer Standardabweichungsbias. Karten der Mittelwerte über alle Monate je Index.

R1mmn Außer im März ($\pm 1,6\%$) stimmen die Vorzeichen der regional gemittelten Standardabweichungsfehler der R1mmn-Simulationen auf Basis von MLR und GLM in allen Monaten überein. Im Januar und Mai sind sie positiv, ansonsten negativ, sie reichen von $-36,5$ – $6,9\%$ (MLR, ohne VZ-Beachtung $15,6$ – $36,5\%$) bzw. $-28,3$ – $18,1\%$ (GLM, $15,4$ – $29,0\%$) und betragen im Durchschnitt $-20,2\%$ (MLR, ohne VZ $25,7\%$) bzw. $-11,2\%$ (GLM, $21,6\%$). Räumlich betrachtet sind im Mittel über alle Monate zwar auch die geringeren GLM-Fehler erkennbar, es wird jedoch kein Muster der Verteilung deutlich. Die Einzelmonate zeigen, dass der Jahresdurchschnitt auf GLM-Basis teilweise durch geringer unter-, aber teilweise auch durch stärker überschätzte Variabilitäten bedingt wird (teilweiser Ausgleich gegensätzlicher Fehler). So sind die positiven pBias-SD-Werte im Januar und Mai höher und stärker verbreitet und auch in einigen anderen Monaten treten, dann vereinzelter, Überschätzungen auf. Im März (niedrigste prozentuale Fehler mit VZ-Beachtung) besitzen die Simulationen durch beide Methoden im Osten und zentralen Süden des Untersuchungsgebietes sowie in der Taunusregion zu hohe Schwankungen, ansonsten eher zu niedrige. Die übrigen Monate sind durch zu geringe Variabilitäten geprägt.

MCD Auch die MCD-Fehler zeigen im regionalen Mittel für beide Methoden stets in die gleiche Richtung, nur im Mai und August sind sie positiv, ansonsten negativ. Bei Betrachtung der monatlichen Karten (ohne Abbildung) verdeutlicht dies: Im Mai herrschen außer im Osten (mit gemischten Vorzeichen) zu hohe Werte deutlich vor (GLM höher als MLR), im August gilt dies mit Ausnahme des Baulandes (südwestlich der zentralen Südspitze Unterfrankens) und einigen kleineren weniger stark ausgeprägten Unterschätzungen. Außer in den Monaten

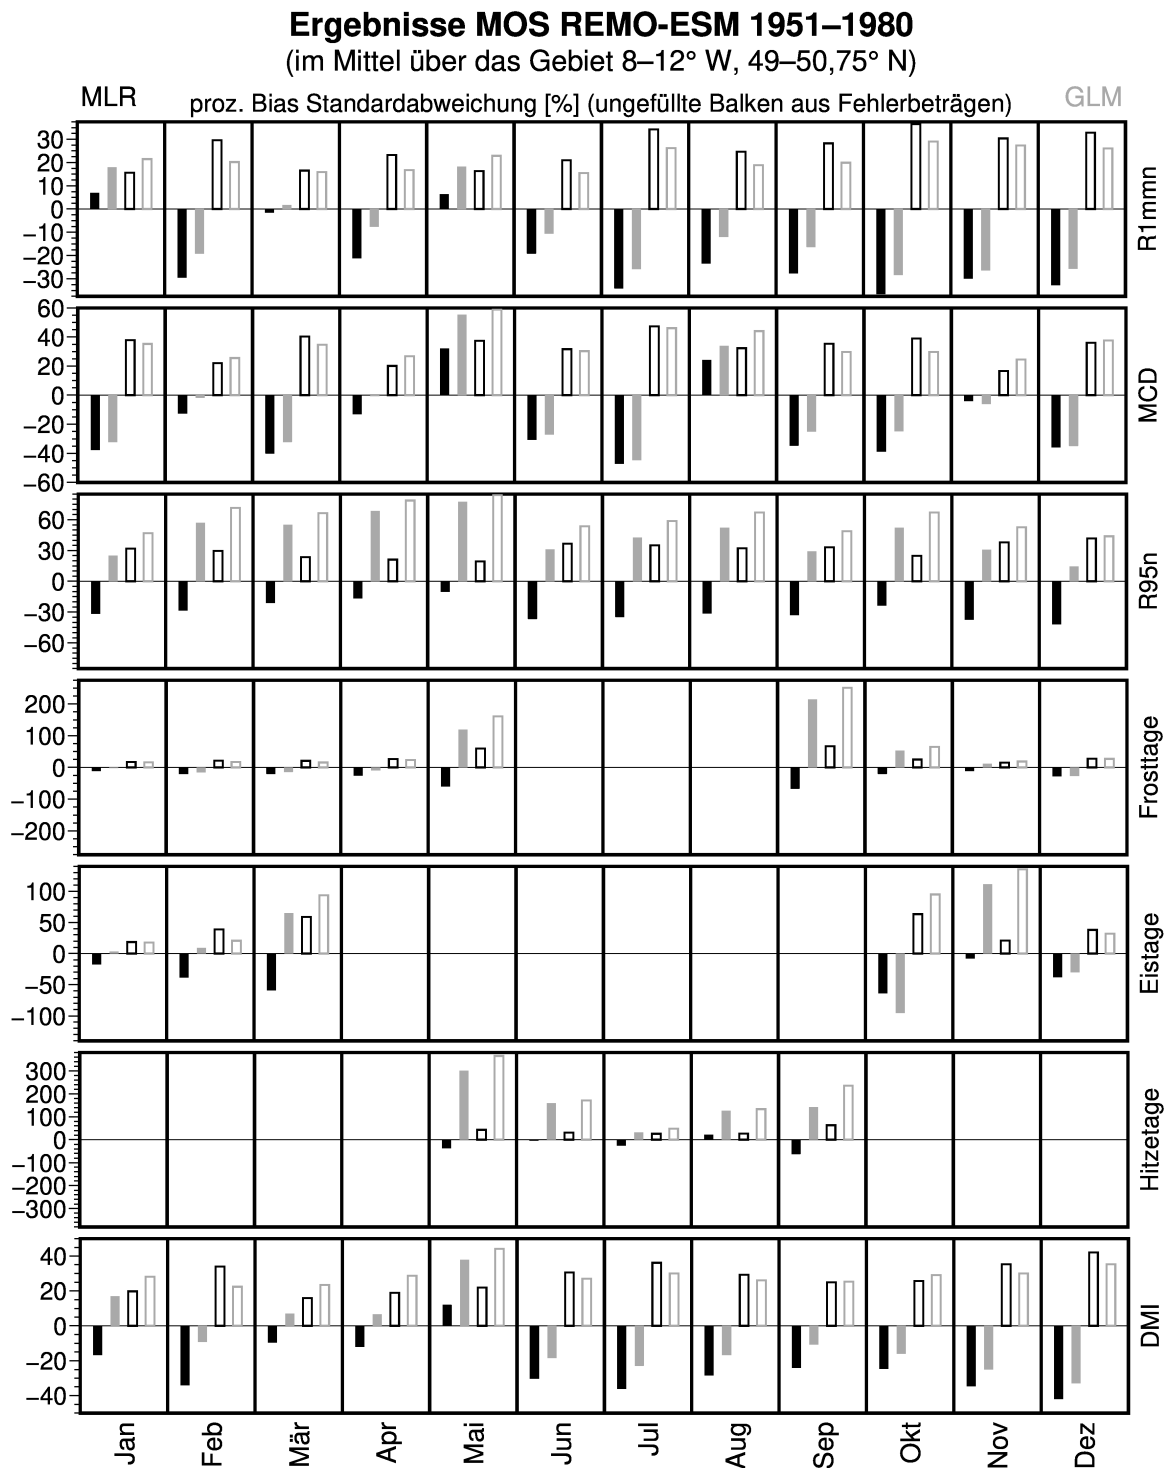


Abbildung 5.35: Ergebnisse MOS REMO-ESM prozentualer Standardabweichungsbias 1951–1980: Regionale Mittelwerte mit Vorzeichenbeachtung (ausgefüllte Balken) sowie auf Basis der Fehlerbeträge (ungefüllte Balken). Jeweils MLR in schwarzer, GLM in grauer Farbe.

mit Durchschnittswerten von über -15 % (Februar, April, November) überwiegen zu geringe Variabilitäten über das Gesamtgebiet deutlich, wobei die GLM-Ergebnisse häufiger vereinzelte Gitterzellen mit positiven Vorzeichen aufweisen. Im Februar sind die Schwankungen v.a. im NO sowie der Wetterau zu hoch, im April und November unklarer verteilt (Nov. MLR Westhälfte ohne äußersten Westen tendenziell positive VZ). Außer der genannten Unterschiede ähneln sich die MLR- und GLM-Fehler. Im Jahresmittel führen die stärkeren Mai- und Augustabweichungen sowie die diffus verteilten positiven Fehler zu etwas geringeren Werten für GLM. Dies zeigt sich auch bei Betrachtung der Mittelwerte von -19,9 % (-47,1–32,1 %) für MLR bzw. -11,6 % (-44,7–55,3 %) für GLM, jedoch ohne VZ-Beachtung 33,0 % (MLR, 16,5–47,2 %) bzw. 35,2 % (GLM, 24,6–58,8 %).

R95n Ganz im Gegensatz zu den in den vorherigen Abschnitten beschriebenen Trockenindizes, sind die Standardabweichungsfehler von GLM und MLR für die Starkregenereignisse gegensätzlich gerichtet: MLR immer negativ, GLM immer positiv. Das wird auch bei räumlicher Betrachtung deutlich, wobei die GLM-Karten – wie sehr häufig – oft sehr gesprenkelt wirken, also keine erkennbaren räumlichen Cluster aufweisen. Am stärksten und verbreitetsten sind die GLM-Überschätzungen im Februar–Mai (Mai Osthälfte fast ausschließlich positive Vorzeichen). Für MLR zeigen sich von März–Mai einige Bereiche mit positiven Fehlern (März Westtaunus und Kraichgau, April zentraler Süden, Mai Osten), wodurch das regionale Mittel abgeschwächt wird, ansonsten sind zu geringe Variabilitäten gebietsbestimmend. Die regionalen Durchschnittswerte reichen von -41,7 bis -10,3 % für MLR (Monatsmittel -28,6 %, Betragsmittel 19,4–41,8 % (30,6 %)) sowie 14,4–77,3 % für GLM (44,6 %, absolut 43,9–83,9 % (61,6 %))

Frosttage Im Zeitraum Dezember–März ähneln sich die Variabilitätsfehler von GLM und MLR sowohl hinsichtlich der räumlichen Mittelwerte als auch der Raumverteilung (negativ, nur im Jan. positive Werte in NO (stärker) und SO bestimmend). Während in den übrigen Monaten auch für MLR zu geringe Schwankungen deutlich überwiegen, mischen sich für GLM im April v.a. in der südlichen UG-Hälfte mehr Gitterzellen mit positiven Vorzeichen in das Fehlerbild, im Mai sowie September–November sind diese dann bestimmend (Okt. und Nov. am stärksten und weitesten verbreitet im Westen). Insgesamt ergeben sich somit räumlich gemittelt Fehler von -11,0 bis -66,5 % für MLR (MW -29,2 %, ohne VZ 15,3–66,5 % (31,1 %)) bzw. -26,7–214,4 % (36,7 %, absolut 15,8–250,6 % (66,1 %)).

Eistage Außer im September (wenige Gitterzellen im Thüringer Wald) und Dezember weisen die Variabilitätsfehler der Eistagehäufigkeiten auf MLR- und GLM-Basis in unterschiedliche Richtungen. Für MLR herrschen in allen Monaten zu geringe Standardabweichungen vor (Jan. UG-Westhälfte weniger stark, Nov. SW positiv). Für GLM ist das räumliche Bild diffuser, wobei außer in den genannten Monaten mit klar negativem Bild überschätzte Streuungen überwiegen (Jan. SW negativ, Feb. NO negativ). Dies bedeutet im regionalen und monatlichen Mittel zwar geringere Fehler für GLM als MLR (10,5 % vs. -37,3 %), aber die monatliche Spannweite (-94,9–111,1 % vs. -63,3 bis -7,7 %) wie auch die Durchschnittswerte auf Basis der absoluten Fehler (65,7 % (17,8–135,1 %) vs. 39,7 % (18,5–63,3 %)) zeigen die relativ bessere MLR-Performance.

Hitzetage Nur im August sind die mittleren Standardabweichungsfehler der Hitzetage sowohl für MLR als auch für GLM positiv (räumlich für beide vorherrschend, MLR-intern im zentralen Norden am höchsten), jedoch für GLM (wie auch in allen anderen abgedeckten Monaten) deutlich stärker. Das räumliche Muster der Fehler ist für GLM diffus (nur Juli NO Cluster hochpositiver Werte, August Oberrheingraben relativ schwächer positiv), für MLR zeigt sich im Mai an der Südostgrenze Unterfrankens ein Gebiet positiver Vorzeichen, im Juni ist der NW negativ, der Osten positiv und der Rest des UGs gemischt mit negativer Tendenz. Insgesamt weisen die GLM-Simulationen mit 31,3–300,3 % (Mittelwert 151,3 %, absolut 48,0–365,0 % (190,4 %)) stärkere prozentuale Abweichungen auf als diejenigen auf MLR-Basis mit -61,2–21,5 % (-21,1 %, absolut 25,7–62,7 % (37,9 %)).

DMI Die DMI-Variationen werden von GLM und MLR im Mai überschätzt (regionaler MW sowie überwiegend ganzes UG außer SW), im Februar sowie Juni–Dezember unterschätzt (regionale Mittelwerte sowie überwiegend ganzes UG, GLM von positiven Fehler durchsprunkt, daher geringere Mittelwerte). Im Januar, März und April hingegen sind die MLR-Fehler negativ (Cluster positiver VZ: Januar SO, März und April W), die GLM-Fehler positiv (v.a. durch starke Fehler positiven Vorzeichens Jan. SO, März NW; April N und O außer NO-Spitze negativ). Über alle Monate ergeben sich somit für MLR zu geringe Standardabweichungen, für GLM schwächere Fehler unterschiedlicher Vorzeichen. Die regionalen Mittelwerte belaufen sich auf -42,0–12,0 % für MLR (MW -23,3 %, absolut 15,9–42,0 % (27,9 %)) sowie -32,8–37,7 % (MW -7,0 %, absolut 22,4–44,2 % (29,1 %)) für GLM.

Spätfrost Die Streuung der Spätfrosttage wird im regionalen Mittel für VPT um 3,0–33,2 % (GLM > MLR, absolut 20,4–45,4 %) über-, für VPM um 4,2–27,6 % unterschätzt (MLR stärker als GLM, absolute Abweichung 27,7–29,3 %, dann GLM stärker als MLR). Räumlich betrachtet sind – wie auch für die Mittelwertabweichungen – kaum Unterschiede zwischen den preco- und pz2-Ergebnissen erkennbar (für MLR und GLM), die MLR- und GLM-Fehler unterscheiden sich jedoch deutlicher. Für MLR-VPT-Spätfrost wird die Variabilität im SO des Untersuchungsgebietes sowie in Großteilen Unterfrankens zu hoch, ansonsten meist zu niedrig simuliert. Für GLM sind die Überschätzungen in der genannten Region stärker ausgeprägt und zudem weiter verbreitet. Auch im Rest des Untersuchungsgebietes treten positive Fehler im Nebeneinander mit negativen auf. Für VPM sind auf MLR-Basis mit Ausnahme weniger schwacher negativer Fehler ausschließlich zu große Standardabweichungen zu verzeichnen. Auf GLM-Basis sind die Variabilitäten z.T. deutlich zu hoch (tendenziell in niedrigeren Höhenlagen, jedoch diffus wirkende Streuung), im äußersten Norden überwiegen negative Fehler jedoch deutlich.

Die MOS-Ergebnisse des pBias SD lassen sich somit wie folgt zusammenfassen: Räumlich über das Gesamtjahr betrachtet – mit Ausnahme der Hitzetage v.a. in höheren Lagen und der Eistage im SW – sowie im regionalen Mittel der meisten Einzelmonate fällt die Standardabweichung der MLR-Simulationen zu gering aus. Für GLM ist sie im Bezug auf R95n und die Hitze- sowie zum Teil die Frost- und Eistagehäufigkeit zu hoch. Wie hinsichtlich des pBias MW, sind auch hier die Abweichungen für die Temperaturkenntage am höchsten, für R1mmn am geringsten und die Überlegenheit einer der Methoden je nach Situation zu beurteilen. Das Vorzeichen der regionalen pBias SD-Mittelwerte für den Spätfrost entspricht dem des pBias MW: Positiv für VPT (MLR hier deutlich besser) und negativ für VPM (GLM hier deutlich besser).

5.3.2.3 Verteilung: Prozentualer Quantil-RMSE

Die über alle Monate gemittelten räumlichen pQRMSE-Werte sind in Abbildung 5.36 dargestellt. Während sich die Ergebnisse für R1mmn, MCD, Hitzetage und DMI – abgesehen von einigen Details – hinsichtlich der Größenordnung der Fehler und deren räumlicher Verteilung ähneln, übersteigen die Abweichungen der GLM-Simulationen von R95n, Frosttagen und Eistagen in großen Teilen des Untersuchungsgebietes diejenigen der MLR-Simulationen. Über die Gesamtregion gemittelt ergeben sich je Monat die in Abbildung 5.37 erkennbaren prozentualen QRMSEs. Folgend wird näher auf die Ergebnisse der einzelnen klimatischen Kennwerte

eingegangen, wobei auch die nicht abgebildeten Raumverteilungen der einzelnen Monate thematisiert werden.




Abbildung 5.36: Modellgüte bzgl. der MOS-simulierten klimatischen Kennwerte 1951–1980:

Prozentualer QRMSE. Karten der Mittelwerte über alle Monate je Index.

R1mmn Die prozentualen QRMSEs der R1mmn-MLR- und -GLM-Simulationen ähneln sich hinsichtlich ihrer Größenordnung mit durchschnittlich 9,8 % (MLR, 7,3–12,5 %) bzw. 9,5 % (GLM, 7,7–11,3 %) sowie räumlichen Verteilung, wobei für MLR höhere Abweichungen tendenziell häufiger zu finden sind. Im Mittel über alle Monate finden im zentralen Westen sowie in Ostunterfranken und im SO des Untersuchungsgebietes relativ geringere Fehler. Im Oktober (UG-Westhälfte, GLM ohne äußersten Westen) sowie Dezember sind die stärksten Verteilungsfehler zu finden.

MCD Auch hinsichtlich der Verteilung der maximalen Trockenperiodenlänge sind die MLR- und GLM-Ergebnisse vergleichbar. MLR zeigt v.a. in den Monaten mit den höchsten Fehlern Januar und Juli höhere Abweichungen. Die Raumverteilung ist für GLM etwas gesprenkelter als für MLR. Über alle Monate gemittelt ergeben sich die geringsten Fehler im SO, die höchsten im SW und Norden des UG. Im regionalen Durchschnitt betragen die prozentualen QRMSEs 24,5–42,7 % (MW 31,3 %) für die MLR- sowie 24,6–39,0 % (MW 30,2 %) für die GLM-Simulationen.

R95n Im Gegensatz zu den in den vorherigen Abschnitten thematisierten Trockenheitsindizes fallen die GLM-Ergebnisse für die Verteilung der Starkregenereignisse deutlich schlechter aus als die auf MLR-Basis, das GLM-Monatsminimum der regionalen Mittelwerte übersteigt das

entsprechende MLR-Maximum. Die MLR-pQRMSEs erstrecken sich von 37,7 bis 60,1 % (MW 49,9 %), die GLM-pQRMSEs von 71,4 bis 110,5 % (MW 87,7 %). Die räumliche Verteilung der GLM-Resultate wirkt heterogen und gesprenkelt. Für MLR hingegen lassen sich Muster erkennen, die jedoch von Monat zu Monat sehr unterschiedlich sind. Bei der Gesamtbetrachtung sind die höchsten MLR-Fehler um Heilbronn sowie im UG-NO zu finden.

Frosttage Die Verteilungsabweichungen der Frosttagehäufigkeiten sind in den Übergangsmontaten April, Mai, September und Oktober deutlich höher als von November bis März. Im Zeitraum Januar–März sind die regional gemittelten MLR-Fehler höher, ansonsten die GLM-Fehler. Insgesamt belaufen sie sich auf 10,3–137,2 % (MLR, MW 42,0 %) bzw. 9,3–487,6 % (GLM, MW 107,3 %). Wenn modellierbar, treten die größten pQRMSEs allgemein im UG-SW auf, räumliche Cluster niedriger Fehler sind nicht klar auszumachen (Ausnahmen MLR Mai Frankenwald, Fichtelgebirge; Oktober zentraler Süden).

Eistage Für die Eistage ist die Simulation von Dezember bis Februar deutlich erfolgreicher als in März und November. Die monatlichen Durchschnittsfehler betragen 23,1–319,7 % (MLR, MW 108,7 %) bzw. 27,1–206,6 % (GLM, MW 151,7 %). Das räumliche Bild der MLR-Ergebnisse ist deutlich klarer und konzentrierter, das der GLM-Resultate diffuser und pixeliger. Für erstere zeigen sich von November bis Februar die größten Fehler im SW sowie allgemein höhere Abweichungen in niedrigeren Höhenlagen (auch im März, für den keine Simulationen in den Bereichen Oberrheingraben, Wetterau, Mainfränkische Platten sowie Maindreieck möglich sind). Für GLM hebt sich im November und März vor allem der Thüringisch-Fränkische Wald samt Fichtelgebirge mit relativ geringeren Fehlern ab, im Zeitraum Dezember–Februar sind v.a. die großen Abweichungen im SO prägend. Die beschriebenen Raumverteilungen spiegeln sich auch im Mittel über alle Monate wider.

Hitzetage Hinsichtlich der Verteilung der Hitzetagehäufigkeiten im räumlichen Durchschnitt schneiden die GLM-Simulationen (118,3–1424,1 %, MW 629,0 %) durchweg schlechter ab als die auf MLR-Basis (93,3–357,2 %, MW 218,8 %). Die höchsten MLR-Fehler treten in der Regel in den höchstgelegenen simulierbaren Gebieten auf (Mai Steigerwald, Albrand, zwischen Taunus und Vogelsberg; Jun. Fränkische Alb; Juli und August Rhön bis Fichtelgebirge; Sep. SW Unterfrankens, zwischen Taunus und Vogelsberg), was auch im Durchschnitt aller Monate z.T.

erkennbar wird. Das genannte Muster lässt sich für GLM im Juni und Juli geringfügig erahnen, ansonsten ist aufgrund der hohen Heterogenität kein klares Raumbild erkennbar.

DMI Für den de Martonne-Trockenheitsindex fallen die Verteilungsfehler im Oktober am höchsten (29,6 % MLR, 39,8 % GLM), im Januar am geringsten aus (14,6 % MLR, 21,6 % GLM). Die Mittelwerte betragen 23,7 % (MLR) bzw. 26,5 % (GLM). Raummuster sind – insbesondere für die MLR-Ergebnisse – kaum auszumachen. Auf MLR-Basis ergeben sich im Februar im zentralen Westen, im Juli im Zentrum, im August im (Süd-)Westen, im September von NW über das Zentrum bis NO sowie im Oktober im SW und Osten des Untersuchungsgebietes relativ höhere Fehler als im jeweiligen UG-Rest.

Spätfrost Sowohl für den VPT- als auch den VPM-Spätfrost liegen die pQRMSEs der GLM-Simulationen im Regionsdurchschnitt immer über denen der MLR-Simulationen, wobei für die Methoden mit standardisierten Prädiktoren (pz2) bessere Werte resultieren. Die pQRMSEs betragen 53,1–57,3 % für VPT sowie 35,1–44,8 % für VPM. Die räumliche Struktur der VPT-Verteilungsabweichungen zeigt für GLM keine erkennbaren Muster (jedoch häufiger höhere Werte als für MLR), für MLR treten im NO des Gebietes sowie im Mittelfränkischen Becken tendenziell die geringsten Fehler auf. Im Gegensatz dazu ist für VPM der Oberrheingraben inkl. westlicher Randhöhen und Wetterau sowie Kraichgau klar als Gebiet mit höheren pQRMSE-Werten erkennbar (für GLM stärker ausgeprägt).

Die MOS-Kernresultate bezüglich des pQRMSE sind somit folgende: Die räumliche Betrachtung der Gesamtjahresergebnisse zeigt für R95n, Frost- und Eistage deutlich geringere Verteilungsqualitäten für MLR als für GLM. Generell sind sie für R1mmn am besten, für die Hitzetagehäufigkeit am schlechtesten. Die regionalen Mittelwerte der Einzelmonate bestätigen dies und zeigen auch für die Hitzetagehäufigkeit eine deutlich schlechtere Qualität der GLM-Resultate. Für die anderen Kennwerte liegen die beiden Methoden nahe beieinander. Sowohl bezüglich des VPT- als auch des VPM-Spätfrostes treten für GLM höhere regionale Mittelwerte des pQRMSE auf. Sie liegen für VPT bei etwa 55 %, bei VPM leicht unter 45 %).

5.3.2.4 Verteilung: Q-Q-Plots




Abbildung 5.38: MOS-Ergebnisse Verteilung Indizes 1951–1980: Q-Q-Plots über alle Monate.

Monatliche Kennwerte Abbildung 5.38 zeigt die Verteilungsübereinstimmungen zwischen beobachteten und simulierten Daten für alle Gitterzellen und Monate. Hierbei fällt die starke Überschätzung von MCD, R95n, Hitzetagen und DMI durch die GLM-Modellierungen auf. Während die unteren Verteilungsbereiche noch gute Übereinstimmungen zeigen, sind die höheren Werte viel zu hoch. Die simulierten Verteilungen von R1mmn, Frost- und Eistagen sind nahe an den Beobachtungen, wobei die Eistage in der zweiten Verteilungshälfte über-, die Frosttage hinsichtlich hoher Werte eher unterschätzt werden. Die auffälligsten Abweichungen der MLR-Verteilung liegen für MCD und R95n vor. Für erstere werden Minima etwas zu gering, für zweite etwas zu hoch modelliert, für beide dann niedrige Werte gut und der Rest der Verteilung zu niedrig simuliert. Die Verteilungen der übrigen Indizes liegen näher an den Beobachtungsdaten, wobei je nach Position innerhalb der Verteilung Über- und Unterschätzungen vorliegen (Hitzetage z.B. Über-, DMI Unterschätzung Maxima). In den Einzelmonaten (ohne Abbildung) sind die Abweichungen oftmals stärker ausgeprägt und gleichen sich bei der Gegenüberstellung aller Werte teilweise aus.

Für die GLM-Ergebnisse sind auch hier die starken Überschätzungen der genannten Kennwerte erkennbar, für MCD sind diese im Januar und Juli nicht vorhanden, die mittlere Teil der Verteilung hingegen wird unterschätzt. Zudem treten auch für die Frosttage im September sehr starke Überschätzungen im oberen Verteilungsbereich auf, die sich im Oktober und November deutlich abschwächen. Hohe Eistagehäufigkeiten im März und November werden ebenfalls

deutlich zu stark simuliert. Die besten Ergebnisse zeigen sich für R1mmn, wobei auch hier je nach Monat Abweichungen von der Winkelhalbierenden erkennbar sind.

Die einzelnen Monate der MLR-Simulationen zeigen die bei der Gesamtbetrachtung erkennbaren Unterschätzungen von MCD und R95n nicht in allen Monaten (MCD nicht Mai (hier hohe Werte zu hoch), November (nur Maxima zu hoch), R95n nicht April, Mai), im Februar nähert sich das MCD-Maximum der Winkelhalbierenden an. Ansonsten werden (sehr) hohe DMI-Werte in allen Monaten unterschätzt, die anderen Verteilungsabschnitte, aber je nach Monat zu hoch, zu niedrig oder gut simuliert. Die Eistagehäufigkeiten werden im Februar, März sowie Dezember über weite Teile der Verteilung (nicht Minimum und Maximum) zu gering simuliert, die Hitzetagehäufigkeiten im August ausschließlich zu hoch. R1mmn und Frosttage werden teils unter-, teils überschätzt, wobei die zu Überschätzung der niedrigen R1mmn-Häufigkeiten am deutlichsten ist.

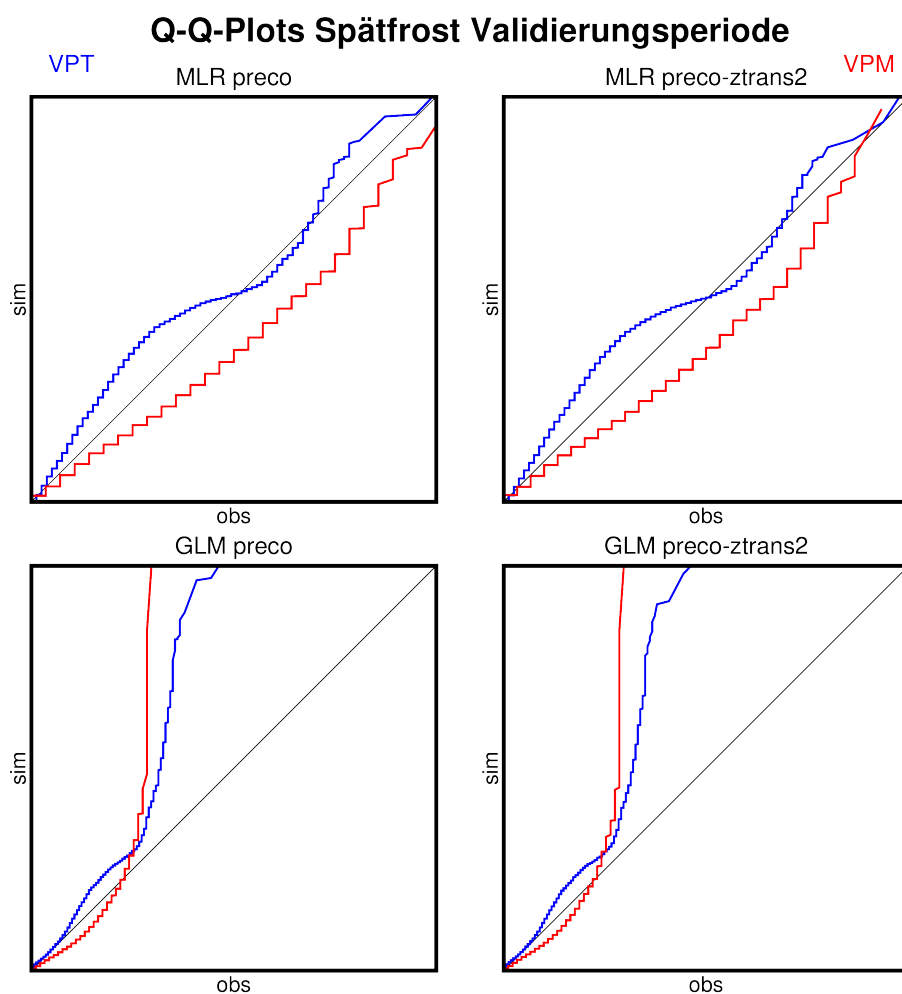


Abbildung 5.39: MOS-Ergebnisse Verteilung Spätfrost 1951–1980: Q-Q-Plots.

Spätfrost Auch hinsichtlich der Spätfrosthäufigkeiten (Abbildung 5.39) werden starke Überschätzungen im oberen Verteilungsbereich durch GLM (beide Varianten) erkennbar. Die niedrigen VPM-Häufigkeiten (nicht das Minimum 0) werden leicht unterschätzt. Die MLR-Methoden simulieren den VPM-Spätfrost über den Großteil der Verteilung als zu gering (nicht Minimum 0, Maximum preco zu gering, pz2 zu hoch), die VPT-Ergebnisse weisen komplexere Abweichungen auf: Minimum, Maximum und mittlere Werte liegen nahe den Beobachtungen, niedrige Werte werden zunächst zunehmend überschätzt und Richtung Mitte der Verteilung dann wieder besser simuliert. Gleiches gilt für das obere Drittel der Verteilung mit Annäherung in Richtung Maximum. Der Bereich zwischen etwa Mitte und zwei Dritteln der Wertespanne wird etwas zu gering modelliert. Für MLR-pz2-VPT ist das Maximum wieder etwas zu hoch.

5.4 Synthese

In den folgenden Kapiteln soll zunächst ein vergleichender Überblick über die Ergebnisse von Biaskorrektur und Model Output Statistics gegeben werden (Abschnitt 5.4.1). Daraufhin werden die sich daraus ergebenden besten Methoden genutzt, um Zukunftsprojektionen der landwirtschaftlich relevanten klimatischen Kenngrößen zu betrachten. Dies geschieht zunächst für REMO2015-MPI-ESM-LR (5.4.2) und anschließend für ein Ensemble weiterer Regionalmodelle (5.4.3). Eine Gesamtsynthese wertet die vorhergehenden Abschnitte gemeinsam aus (5.4.4).

5.4.1 Ergebnisüberblick REMO

Die gemeinsame Betrachtung von Biaskorrektur- und MOS-Ergebnissen wird durch die Unterschiede in der Methodik sowie der jeweils verfügbaren Datenzeiträume erschwert. Die Biaskorrektur basiert direkt auf REMO-ESM-Daten des historischen Zeitraums 1951–2005. Dieser wird beim Bootstrapping zufällig in einen 25-jährigen Kalibrierungs- und 30-jährigen Validierungszeitraum unterteilt. Für jede Situation (Index, Monat, Gitterzelle) können sich die abhängigen und unabhängigen Zeiträume daher unterscheiden. Für die explorativen Model Output Statistics wird zunächst ein Modell mit zeitlicher Korrespondenz benötigt, wofür die REMO-Eval-Daten (simulierte Jahre 1980–2012) zweifach unterteilt werden: Zunächst werden die vier letzten Jahre als Kontrollzeitraum entfernt. Anschließend erfolgt die zufällige Einteilung der

verbleibenden Jahre in zufällige Kalibrierungs- (25 Jahre) und Validierungszeiträume (4 Jahre) für das Modelltraining. Die Resultate werden danach auf REMO-ESM übertragen. Der Überschneidung zwischen REMO-Eval und REMO-ESM wird durch die Jahre 1980–2005 gebildet. Als 30-jähriger Validierungszeitraum wird daher 1951–1980 (ein Jahr Schnittmenge mit REMO-Eval-Zeitraum, daher quasi-unabhängig) verwendet.

Um einen direkten Vergleich von BK und MOS zu ermöglichen, wird der Gesamtzeitraum 1951–2005 verwendet. Zusätzlich kann ein 1:1-Vergleich nur für solche Werte vorgenommen werden, welche sich auf die Gesamtregion beziehen, da die MOS ein statistisches Downscaling enthalten und so die Gitterzellenanzahl deutlich höher ist als die der REMO-Daten. Einige gezeigte Karten dienen daher nur zur Gewinnung eines optischen Eindrucks. Aufgrund der Fülle der Monats-Index-Kombinationen werden nur vereinzelt Karten gezeigt, dann v.a. für den niedrigerdimensionierten Spätfrost.

5.4.1.1 pQRMSE zur Selektion der besten Methode

Monatlich aufgelöste Indizes Da der pQRMSE die gesamte Verteilung und nicht nur einzelne Aspekte der simulierten bzw. korrigierten Daten mit den Beobachtungsdaten vergleicht, wird diese Metrik zur Bestimmung der besten Methode verwendet. Hierbei fließen alle BK-Methoden, die beste MLR- sowie die beste GLM-Variante ein. Die pQRMSE-Werte werden pro Gitterzelle berechnet und anschließend über das Untersuchungsgebiet gemittelt. Dies ist in Abbildung 5.40 dargestellt. In einigen Monaten übertreffen die pQRMSE-Werte der MOS-simulierten Daten den pQRMSE der rohen REMO-Daten (jeweils erster Punkt von links) für MCD (alle Monate außer Februar, Juni–August, je mindestens GLM oder MLR), R95n (Mai–Okt. GLM), Frost- (Mai, Sep. GLM), Eis- (Nov. GLM) und Hitzetage (Mai–Sep. GLM, Jul. und Aug. MLR). Ansonsten liegen die Fehler aller korrigierten und simulierten Daten unterhalb des pQRMSE der Rohdaten⁴⁹

Es zeigt sich, dass die Biaskorrekturmethode und hierbei v.a. das nicht-parametrische Quantil-mapping für fast alle Index-Monat-Kombinationen die besten Ergebnisse mit sich bringen. Für die beiden Trockenheitsindizes R1mmn und MCD sowie DMI ist QM11 immer die bevorzugte

⁴⁹Die Rohdaten liegen nur hinsichtlich der Biaskorrektur vor, da die MOS ein statistisches Downscaling implizieren. Die regionalen Mittelwerte können dennoch verglichen werden.




Abbildung 5.40: Regionale Mittelwerte der pro Gitterzelle berechneten pQRMSEs der klimatischen Kennwerte 1951–2005 für alle Biaskorrektur- und MOS-Methoden. Indizes in Zeilen und Monate in Spalten. Je Monat und Index von links nach rechts Biaskorrekturergebnisse (Rohdaten, LS, QM11, PMPE, LSM) sowie MOS-Ergebnisse (MLR, GLM).

Methode. Gleiches gilt für die Eis- und Hitzetage in den jeweils abgedeckten Monaten (Eistage Okt.–Apr., Hitzetage Mai–Sep.). Für R95n wird nur im Juni und September das parametrische PDF-Matching gewählt, ansonsten ebenfalls QM11. Die besten Ergebnisse für die Frosttage (abgedeckt Sep.–Mai) ergeben sich im April und Oktober durch PMPE, im September durch MOS-MLR (pz2), ansonsten durch QM11. Zudem liegen für die Temperaturextremtage in vier Monat-Index-Kombinationen, in denen die beobachteten Häufigkeiten sehr niedrig sind (Frosttage Jun. 7 (BK-Basis) bzw. 8 (MOS-Basis) und Aug. 1, Eistage Mai 2 bzw. 4, Hitzetage Apr. 2 Tage, jeweils maximale Gesamtzahl an einer Gitterzelle in 55 Jahren), keine biaskorrigierten Werte vor ($skill = 0$ für alle BS-Iterationen). Die pQRMSEs der Rohdaten sind in Abbildung 5.40 zum Vergleich mit angetragen. Für diese Situationen existieren auch keine MOS-Modelle, ebenso wie für die Eistagehäufigkeit im April.

Prozentuale Quantil-RMSEs von über 100 %⁵⁰ für die beste Variante ergeben sich für die Anzahl der Frosttage im September (171,7 % MOS-MLR, zum Vergleich beste BK-Methode QM11 182,3 %; Mai QM11 als beste Methode 94,8 %), die Eistage im April und Oktober (134,9 bzw. 138,1 %) sowie Hitzetage im Mai und September (132,6 bzw. 166,0 %). Bei diesen Ergebnissen ist zu beachten, dass alle Gitterzellen ohne gültiges BK- oder MOS-Modell aus der Mittelwertbildung ausgenommen sind (anstatt beispielsweise bei BK unkorrigierte Daten einzusetzen). Insbesondere für die Frosttage im Mai ist das durch die BK erfasste Gebiet (nur Nord- und Nordostrand) dadurch deutlich kleiner als durch MOS (alles außer Südwesten). Die schwer erfassbaren Gebiete mit z.T. hohen MOS-Fehlern sind somit nicht Teil der BK-Evaluierung.

Es stellt sich die Frage, ob eine weitere Betrachtung (und nähergehende Untersuchung mittels MME) der Frosttage in September, der Eistage im April und Oktober sowie der Hitzetage im Mai und September zielführend ist. Genau diese Kenngrößen sind zwar landwirtschaftlich extrem relevant, allerdings aufgrund der geringen beobachteten Häufigkeiten sehr schwer zu korrigieren und simulieren. Die Anzahl der beobachteten Häufigkeiten liegt im regionalen Maximum bei (BK-Basis, MOS-Basis; zwei Nachkommastellen hier zur Verdeutlichung):

- Frosttage: September 0,76 bzw. 0,71 Tag
- Eistage: April 0,93 bzw. 1,40, Oktober 0,20 bzw. 0,29 Tage
- Hitzetage: Mai 0,58 bzw. 0,60, September 0,60 bzw. 0,71 Tage

⁵⁰Die Quadratwurzel der mittleren quadratischen Abweichungen zwischen sortierten Simulations- und Beobachtungsdaten ist also größer als der jeweilige beobachtete Mittelwert.

Diese geringe Anzahl der beobachteten Ereignishäufigkeiten erschweren die Simulation, was an den pQRMSEs von über 100 % ersichtlich wird. Aus diesem Grund werden die betroffenen Situationen für die Zukunftsanalysen verworfen.

Die regional gemittelten Werte aus Abbildung 5.40 beinhalten z.T. große räumliche Unterschiede. Hierauf wird im Folgenden – soweit nicht anders genannt nur auf Basis der jeweils besten Korrekturmethode – eingegangen.

Während der regional gemittelte pQRMSE der rohen REMO-Daten zwischen 9,4 (Nov.) und 15,4 % (Jul.) liegt, erstreckt er sich nach der Korrektur mit der besten Methode (QM11 für alle Monate) von 3,2 (Aug.) bis 4,5 % (Dez.). Die höchsten R1mmn-Fehler der Rohdaten treten meist in niedrigeren Regionen auf, im November und Dezember jedoch in den höheren Lagen v.a. im Norden des Untersuchungsgebietes. QM11 führt klar zu den besten Ergebnissen in jedem Monat und über das gesamte Gebiet.

Für MCD beträgt der pQRMSE vor der Korrektur je nach Monat 19,4–42,3 % (Nov., Jul.), danach für QM11 8,2–11,8 % (Mai, Jul.). Tendenziell sind auch hier die stärksten ursprünglichen Abweichungen in niedrigeren Regionen zu finden (Ausnahmen Sep.–Nov.), die größten QM11-Restfehler finden sich im Januar, Juli, September und November ohne klares räumliches Muster.

Die Starkregentage (Original-pQRMSE REMO 57,3 (Sep.)–118,4 % (Jan.), korrigiert mit bester Methode 27,2 (Jan.)–37,4 % (Jun.)) weisen nach der Korrektur oft dort die geringsten Abweichungen auf, wo die Rohdaten die höchsten Fehler aufweisen (niedrige Höhenlagen).

Der ursprüngliche pQRMSE von im Mittel 8,3–397,2 % (Jan., Sep.; ohne Jun. und Aug.) kann durch die Biaskorrektur auf 3,6–171,7 % (Jan., Sep.) verringert werden. Auch wenn die Korrektur über das gesamte Gebiet erfolgreich ist, bleiben v.a. im April und Oktober in niedrigen Lagen wie insbesondere dem Oberrheingraben die höchsten Abweichungen bestehen. Die Ergebnisse von Mai und vor allem September beruhen jeweils auf wenigen Gitterzellen. Im Mai (QM11) befinden sich diese in den höchsten Lagen des Untersuchungsgebietes (z.T. Ausläufer des Westerwaldes, Vogelsberg, Rhön, Thüringisch-Fränkischer Wald, Fichtelgebirge, z.T. Fränkische Alb) im September ohne erkennbaren topographischen Bezug nahe Nürnberg und östlich bis südöstlich von Bayreuth.

Auch die Verteilung der Eistage weicht vor und nach der Korrektur in niedrigen Lagen und insbesondere im Südwesten am stärksten von den Beobachtungen ab. Diese Abweichungen können

jedoch von ursprünglich 41,2–1259,3 % (Jan., Apr.; ohne Mai) deutlich auf 9,0–134,9 % (Jan., Apr.) verringert werden. Im April (Nordosten, Rhön, Vogelsberg, Teile Fränkische Alb) sowie insbesondere im September (höchste Höhen Thüringer Wald) werden nur wenige Gitterzellen abgedeckt.

Im Gegensatz zu Frost- und Eistagen liegt die Verteilung der Hitzetage in geringen Höhenlagen und im Speziellen im Südwesten des Gebietes am nächsten an der Referenzdaten. Diese Raumstruktur bleibt auch nach der Korrektur erhalten, die Abweichungen werden jedoch sichtbar verringert (regionales Mittel 55,6–535,7 % (Aug., Sep.; ohne Apr.), korrigiert 27,4–166,0 % (Jul., Sep.)). Im Mai und September treten viele Fehlwerte auf, im Juni einige im Norden und Nordosten des Gebietes.

Die topographischen Gegensätze (höhere pQRMSE in niedrigeren Lagen) der DMI-Verteilungsfehler bleibt auch nach der Korrektur von Oktober bis März, jedoch in deutlich abgeschwächter Form, erkennbar. Die mittleren Abweichungen werden von 27,5–40,1 (Dez., Mär.) auf 5,4–13,2 % (Jun., Feb.) verringert.

Für die meisten Index-Monat-Kombinationen zeigen QM11 und PMPE ähnliche, sich deutlich von den übrigen Methoden unterscheidende Ergebnisse, wobei QM11 überwiegend etwas bessere Korrekturen zur Folge hat. Nur die Frosttage im September mit sehr wenigen gültigen Gitterzellen werden etwas besser – aber immer noch stark abweichend – von MLR simuliert (pQRMSE 171,7 %) als von QM11 korrigiert (182,3 %).

Spätfrost Für die Anzahl der Spätfrosttage führen QM11 (VPT) und PMPE (VPM) zu den besten Resultaten. Abbildung 5.41 zeigt neben den regionalen Mittelwerten (rechts) auch den räumlichen Aspekt der Verteilungsabweichungen (rechts). Für die Biaskorrektur ist hierbei ein Vergleich mit den entsprechenden Rohdaten möglich (erste Karte bzw. erster Balken von links), für MOS existieren solche nicht. Hinsichtlich des Spätfrosts für die thermisch definierte Vegetationsperiode liegen die höchsten Fehler der Rohdaten im Gebiet Mittelfränkisches Becken, Fränkische Alb bis Grabfeld vor, die niedrigsten am südlichen Westrand der Untersuchungsregion. Die deutlich besten Ergebnisse sind für die QM11-Korrektur (mittlere Karte bzw. mittlerer Balken) zu erkennen. Im gesamten Untersuchungsgebiet wird der pQRMSE von ursprünglich 41,8–112,1 % (MW 82,3 %) sichtbar auf 6,9–27,1 % (15,3 %) gesenkt. Für PMPE ist die Korrekturgüte mit einem verbleibenden Fehler von durchschnittlich 21,6 % (8,1–45,6 %) etwas geringer, LS (45,2 % (16,4–77,1 %)) sowie LSM (48,4 % (16,2–104,1 %)) sind weniger erfolg-

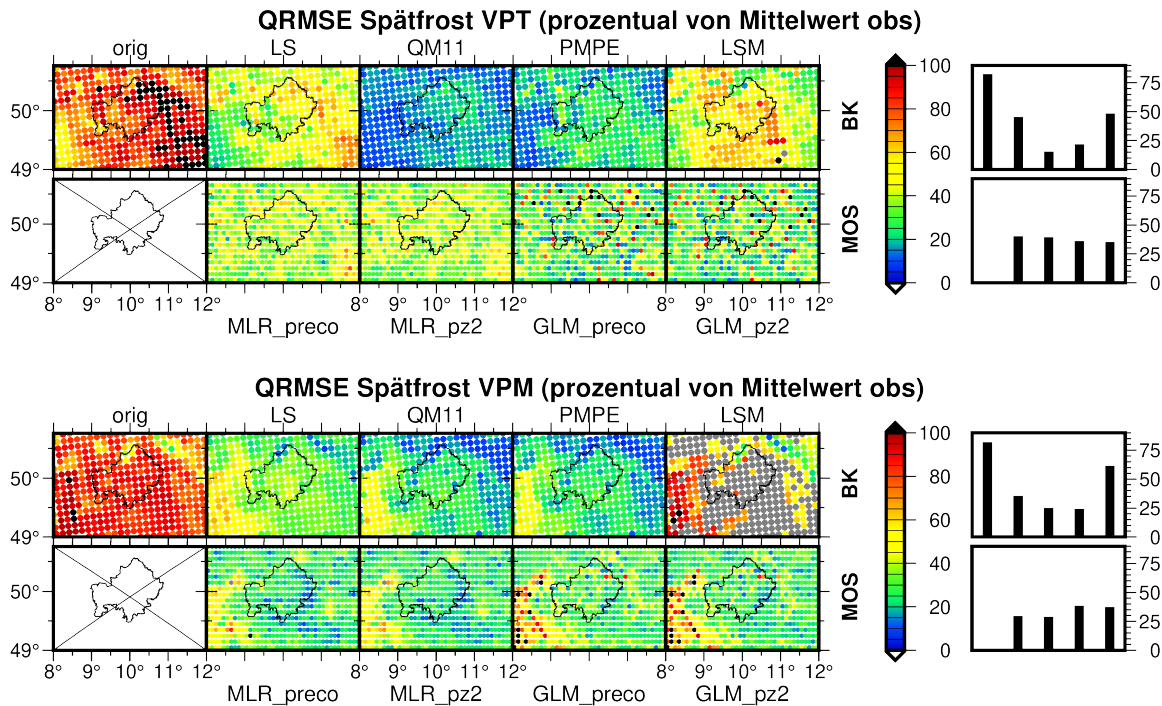


Abbildung 5.41: *pQRMSE Spätfrost als Kartendarstellung (links) sowie regionales Mittel der Gitterzellenwerte (Balkendarstellung rechts) aller Methoden. Oben VPT, unten VPM, dabei jeweils oben Biaskorrektur- und unten MOS-Ergebnisse.*

reich. Letztere zeigen deutliche räumliche Unterschiede mit besseren Werte im Südwesten (LS) bzw. Südwesten und (Nord-)Osten (LSM). Die verschiedenen MOS-Methoden weisen im Mittel ähnliche Verteilungsabweichungen auf, welche für die MLR-Simulationen etwas höher sind. Die Spannweite der *pQRMSE*-Werte ist jedoch für GLM deutlich höher als für MLR (MLR preco 40,0 % (14,9–79,6 %), MLR pz2 39,3 % (17,7–70,4 %), GLM preco 35,8 % (9,2–174,1 %), GLM pz2 35,2 % (9,4–148,4 %)), wobei kein klares räumliches Muster erkennbar ist.

Hinsichtlich der monatlich definierten Vegetationsperiode zeigen die Rohdaten eine klarere topographische Prägung der Verteilungsabweichungen (26,4–101,6 %, im Mittel 26,4 %): Die höchsten Fehler finden sich in niedrigen, die geringsten in hohen Lagen. Die Korrekturergebnisse von LS (35,4 % (8,6–66,4 %)), QM11 (25,0 % (6,6–64,8 %)) und PMPE (24,2 % (5,9–58,6 %), damit beste Resultate) ähneln sich, wobei speziell im Südwesten und allgemein in niedriger gelegenen Gebieten höhere Abweichungen verbleiben. LSM führt zu vielen Fehlerten und wenig Verbesserung, die höchsten Abweichungen übersteigen sogar die der Rohdaten (61,4 % (10,3–108,3 %)). Die Ergebnisse der multiplen linearen Regression (preco 29,5 % (9,6–117,8 %), pz2 28,9 % (7,3–71,1 %)) liegen im regionalen Durchschnitt zwischen denen

der Linearskalierung des Quantilmappings (QM11 und PMPE), die der generalisierten linearen Modelle (preco 38,4 % (11,5–1661,7 %), 37,2 (10,1–1616,1 %)) sind etwas schlechter. Hierbei fallen die hohen Maxima der GLM-Abweichungen auf (je eine Gitterzelle im Südwesten, ansonsten maximal 314,1 % bzw 358,7 %). Anders als bei VPT ist bei VPM auch für die MOS-Ergebnisse eine räumliche Differenzierung erkennbar, die sich v.a. durch höhere Abweichungen im Südwesten des Untersuchungsgebiets auszeichnet.

5.4.1.2 Indexmittelwerte

Auch wenn diese nicht als Kriterium für die Wahl der weiterverwendeten Methode hinzugezogen werden, kann die Betrachtung der Mittelwerte einen Eindruck von der jeweiligen Güte der Simulation bzw. Korrektur geben und verdeutlicht zudem die Größenordnung der Daten.

Monatlich aufgelöste Indizes In Abbildung 5.42 wird sichtbar, dass die biaskorrigierten Daten in fast allen Fällen deutlich näher an den beobachteten Werten liegen, als die REMO-ESM-Daten (je linker Bereich des Kastens je Index-Monat-Situation). Die Ausnahmen hierzu treten in Monaten mit nah an den Beobachtungswerten liegenden ursprünglichen Modelldaten auf (MCD Nov., R95n Okt., Frosttage Jan. und Mai, Hitzetage Mai, DMI Okt. und Nov.). Für die MOS-Simulationen ist dieser Vergleich nicht möglich (keine unkorrigierten Daten).

Spätfrost Alle biaskorrigierten sowie MOS-simulierten durchschnittlichen Spätfrosthäufigkeiten (VPT und VPM) sind realitätsnäher als die von REMO modellierten. Dies gilt sowohl im Regionsmittel als auch hinsichtlich der räumlichen Verteilung. Für beide Indexvarianten weicht LSM am stärksten von den Beobachtungsdaten ab, hinsichtlich der monatsdefinierten Vegetationsperiode entstehen viele Fehlwerte. Bei den Ergebnissen der Model Output Statistics treten für den VPT-Spätfrost außer im Nordosten des betrachteten Gebietes häufig zu hohe Werte auf (MLR stärker als GLM), für den VPM-Spätfrost sind die Werte v.a. im Thüringisch-Fränkischen Wald samt Frankenhöhe zu niedrig.




Abbildung 5.42: Regionale Mittelwerte der klimatischen Kennwerte 1951–2005 für alle Biaskorrektur- und MOS-Methoden sowie die jeweiligen Beobachtungsdaten. Indizes in Zeilen und Monate in Spalten. Je Monat und Index von links nach rechts Biaskorrekturergebnisse (entsprechende Beobachtungswerte, Rohdaten, LS, QM11, PMPE, LSM) sowie MOS-Ergebnisse (entsprechende Beobachtungswerte, MLR, GLM).

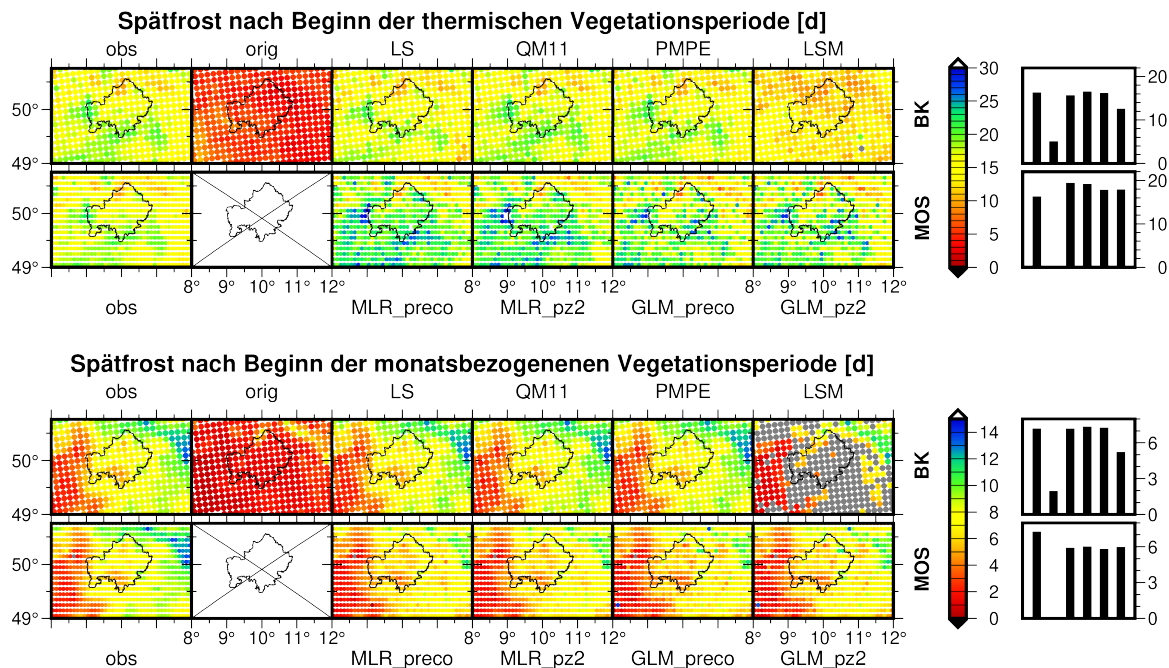


Abbildung 5.43: Mittlere beobachtete, RCM-modellierte und korrigierte sowie MOS-simulierte Anzahl der Spätfrosttage 1951–2005 als Kartendarstellung (links) sowie regionales Mittel der Gitterzellenwerte (Balkendarstellung rechts) aller Methoden. Oben VPT, unten VPM, dabei jeweils oben Biaskorrektur- und unten MOS-Ergebnisse.

5.4.2 Zukunftsprojektionen REMO

Die folgenden Aussagen beziehen sich stets auf die Ergebnisse der im vorangegangenen Kapitel herausgestellten besten Methode.

5.4.2.1 Monatlich aufgelöste Indizes

Die regionalen Mittelwerte der einzelnen Gitterzellentrends sind in Abbildung 5.44 aufgetragen. Wertgleich sind die Trends der regionalen Mittelwerte, allerdings kann nur für letztere eine Trendsignifikanz berechnet werden, weshalb beide in der Abbildung verzeichnet sind. Allgemein erkennbar sind trockenere, heißere Sommer sowie teilweise feuchtere, mildere Winter. Die zunehmende Sommer- und Herbsttrockenheit zeigt sich in positiven Trends von R1mmn (Mai–Okt. 0,7–3,4 d/100 a, alle signifikant), MCD (Jun.–Aug. und Okt.–Nov. 1,7–4,8 d/100 a, signifikant) sowie negativen DMI-Trends (Mai–Okt. -4,0 bis -14,9 mm/°C 100 a, signifikant). Auch die Anzahl der Starkregenereignisse nimmt ab (Jun.–Aug. -0,1–0,6 d/100 a, signifikant), die der Hitzetage deutlich zu (Jun.–Aug. 3,2–5,8 d/100 a, alle signifikant).




Abbildung 5.44: Trends der klimatischen Kennwerte im 21. Jahrhundert (30-jährige gleitende Mittel). Trends der regionalen Mittelwerte mit Signifikanzangabe (gefüllte) sowie Mittelwert, Minima und Maxima der regionalen Trends..

Bei der Betrachtung der räumlichen Verteilung der Trends von R1mmn, MCD, R95n und DMI im April und Dezember ergeben sich über das gesamte Untersuchungsgebiet feuchtere Bedingungen: Weniger Trockentage und kürzere Trockenperiodendauer, mehr Starkniederschlagsereignisse und ein höherer de Martonne-Index. Für R95n und DMI finden sich einige wenige Ausnahmen mit leichter Abnahme. Ganz allgemein sind hinsichtlich dieser vier Kennwerte mit Niederschlagsbezug die räumlichen Verteilungen der Trends für R1mmn am homogensten. Am auffälligsten vom Rest des Untersuchungsgebietes abweichend sind die sehr geringen Trends im SO sowie im Bereich des Thüringisch-Fränkischen Waldes samt Fichtelgebirge (TFE) im Januar, die leicht negativen Trends zwischen Vogelsberg und Rhön im Februar (sonst positiv), die sehr gering negativen bis leicht positiven Trends im Nordosten im März sowie die sehr schwachen Trends in Oberrheingebiet, Wetterau sowie im Oberpfälzisch-Obermainischen Hügelland. Die Tendenzen der maximalen Trockenperiodendauer zeigen größere räumliche Unterschiede, v.a. in den Monaten ohne signifikante Mittelwerttrends (Feb. S positiv, N eher negativ; Mär. SO und Teile NO positiv, sonst meist negativ, Apr. kein deutliches Bild, Sep. positiv NW sonst schwache Trends). Dem Mittelwert widersprechende Trends zeigen sich im Juni um das Fich-

telgebirge und westlich davon sowie teilweise im SW, im Juli v.a. im Südwesten und in Teilen des Spessarts sowie im November im Nordosten. Große räumliche Einigkeit bzgl. der Trendvorzeichen der Starkregenereignisse ist im Januar, April und Dezember vorhanden (Zunahme), im März und v.a. Februar finden sich häufiger auch gegensätzliche Vorzeichen. Im Juli und August sind zwar deutlich überwiegend negative Tendenzen erkennbar, die Anzahl der Starkregenereignisse steigt jedoch auch an einigen Raumpunkten (Juni v.a. im Süden). Im Oktober finden sich die stärksten Zunahmen im Nordwesten, im November im Süden des Untersuchungsgebietes. Die DMI-Trends zeigen ähnlich denen der Trockentage eine hohe räumliche Homogenität und weiche Übergänge. Jedoch treten innerhalb der Monate Januar, März, Mai, Oktober und November häufiger gegensätzliche Vorzeichen auf: Im Januar nimmt der DMI entgegen des Mittelwertes im Nordwesten und äußersten Westen (außer SW) zu, im Oktober ebenfalls im Nordwesten, im Mai östlich und westlich der Nordspitze Unterfrankens sowie im Norden der Fränkischen Alb. Im März heben sich Teile der Fränkischen Alb, des TFFs sowie des nordwestlichen Untersuchungsgebietes mit negativen Trendvorzeichen ab. Im November ergeben die Projektionen trockener werdende Bedingungen in der gesamten UG-Nordhälfte mit Ausnahme des TFF und nordöstlich davon (dort positiv) sowie fast der gesamten Westhälfte mit Ausnahme des äußersten Südens (dort positiv).

Die Temperaturkenntage zeigen weitgehend homogene räumliche Trendverteilungen. Eine Ausnahme hierzu bilden die Frosttagetrends im Oktober. Sie sind schwächer als in den anderen Monaten und im Nordosten (v.a. TFF) negativ, während in der Westhälfte des Untersuchungsgebietes positive Vorzeichen häufig vorzufinden sind. Die Verortung der schwächsten Eistagetrends im März koinzidiert räumlich mit derer der stärksten im November (Oberrheingebiet, Großteile Unterfrankens außer N- und W-Rand, ausstreifend in Fränkische Schweiz und Mittelfränkisches Becken).

5.4.2.2 Spätfrost

Während für alle Gitterzellen eine Abnahme der Spätfrosthäufigkeit gemäß monatlich definierter Vegetationsperiode projiziert wird (Ausnahme eine Gitterzelle mit 0,0 d/100 a westlich von Ludwigshafen), resultieren für den VPT-Spätfrost positive wie auch negative Trends. Die regionalen Mittelwerte liegen bei -3,7 d/100a (VPT, -22,2–29,4 d/100 a) bzw. -2,7 d/100a (VPM -9,4–0,0 d/100 a)




Abbildung 5.45: Trends der klimatischen Kennwerte im 21. Jahrhundert (30-jährige gleitende Mittel). Trends der regionalen Mittelwerte (alle signifikant) sowie Mittelwert, Minima und Maxima der regionalen Trends. Symbole siehe Abbildung 5.44.

Starke Zunahmen (über 100 % im Vergleich zum Mittelwert 1971–2000) der Spätfrosthäufigkeit hinsichtlich der thermischen Vegetationsperiode werden insbesondere in der Rhön sowie im Thüringisch-Fränkischen Wald samt Fichtelgebirge projiziert. Auch in Teilen des UG-Nordwestens sowie im zentralen Unterfranken zeigen sich deutliche positive Trends. Die stärksten Spätfrostreduktionen hingegen finden sich in Oberrheingebiet, Kraichgau sowie der Südostecke des Untersuchungsgebietes. Die für den Spätfrost mit monatlich definierter Vegetationsperiode resultierenden Abnahmen sind im Nordwesten des Untersuchungsgebietes am stärksten, im Südosten am schwächsten.

5.4.3 Anwendung auf Multimodellensemble

5.4.3.1 Monatlich aufgelöste Indizes

Bei Berechnung der betrachteten Kennwerte durch zwei weitere regionale Klimamodelle und anschließende Korrektur gemäß der besten Methode aus Abschnitt 5.4.1 ergeben sich die in Abbildung 5.46 gemeinsam mit den REMO-Ergebnissen gezeigten Trends. Während hinsichtlich der regionalen Mittelwerte der Trends der Temperaturextremtage (Frost-, Eis-, Hitze-) Vorzeicheneinigkeit zwischen den drei Modellen herrscht, existieren für die anderen Indizes z.T. Unterschiede in der Richtung der zukünftigen Projektionen. Übereinstimmend sind Projektionen hinsichtlich R1mmn-Abnahme im März (ALADIN nicht signifikant) sowie -zunahme im Mai und Juli–September. Auch eine Erhöhung der maximalen Anzahl konsekutiver Trockentage

wird im Mittel von allen drei Modellen für Juni–Oktober (REMO Mai und Sep., RACMO Jul. nicht signifikant), eine Verringerung für Dezember (ALADIN nicht signifikant) simuliert. Im Mittel positive Starkregentrends ergeben sich für alle Modelle im Januar, März sowie Oktober–Dezember, der DMI nimmt im Februar, Mai und Juli–September ab.




Abbildung 5.46: Trends der klimatischen Kennwerte im 21. Jahrhundert für REMO und zwei weitere RCMs (30-jährige gleitende Mittel). Trends der regionalen Mittelwerte mit Signifikanzangabe (gefüllte) sowie Mittelwert, Minima und Maxima der regionalen Trends..

Ein Blick auf die Karten der monatlichen (relativen) Trends je Index (ohne Abbildung) zeigt für R1mmn höhere Ähnlichkeiten von REMO zu RACMO als zu ALADIN. Im März und April sind die Trends schwächer und in ersterem im gesamten UG-Norden eher positiv. Im Oktober treten für RACMO außer im Süden und Südwesten vermehrt (schwache) negative Trends auf, während die erkennbaren Tendenzen für REMO weitestgehend positive Vorzeichen besitzen. Die stärksten Widersprüche zu den anderen beiden Modellen zeigt ALADIN im Januar, Februar, April, November mit flächendeckend gegensätzlichen Vorzeichen. Auch im Juni und Dezember weisen die Trends für Großteile des UG in die andere Richtung.

Für MCD ist das Bild deutlich komplexer. Im Dezember und Januar stimmen REMO und RACMO weitestgehend überein, wobei RACMO im Januar im SO stärkere, im Dezember südlich

des Thüringer Waldes bis ins Fichtelgebirge reichend schwächere negative Trends projiziert. Räumlich relativ homogene Einigkeit aller drei Modelle besteht v.a. im August, wobei die Trockenperiodenzunahmen für REMO am höchsten, für ALADIN am niedrigsten sind. Im April widerspricht ALADIN (flächendeckend positiv) den anderen beiden (REMO flächendeckend negativ, RACMO größtenteils negativ). Auch ansonsten lassen sich bei Betrachtung der Karten eher Unterschiede als Gemeinsamkeiten der drei Modelle erkennen.

Im Dezember und Januar wird das räumliche Trendbild der Starkregenhäufigkeiten in allen drei Fällen von positiven Vorzeichen beherrscht (ALADIN Jan. etwas weniger). Etwas abgeschwächt gilt dies auch für März. Im Februar steht RACMO, im April, Juni und Oktober ALADIN sowie im Juli und August REMO tendenziell im Gegensatz zu den übrigen Modellen. Im Mai und September sind keine gebietsumfassenden Gesamttendenzen auszumachen, je nach Verortung stehen die Ergebnisse der Modelle im Einklang oder Widerspruch. Für den November schließlich sind zwar alle Modelltrends im Mittel positiv, REMO jedoch weist im Nordwesten, ALADIN im Südosten auch gehäuft negative Vorzeichen auf.

Nur wenige Auffälligkeiten sind für die Frosttagetrends (generell negativ) erkennbar: ALADIN projiziert im Mai im (Süd-)Westen sehr starke (relative) Abnahmen, REMO im April und Mai allgemein (außer NO) schwächere als die anderen Modelle, im Oktober sind die REMO-Trends außer im NO sehr gering und im Westen vermehrt positiv und im November fallen die starken ALADIN-Trends über weite Teile des Gebietes auf. Hinsichtlich der Eistage werden von REMO (hier auch Ostunterfranken und östlich angrenzende Gebiete) und ALADIN im März für das Oberrheingebiet sehr niedrige Trends, im Februar von RACMO z.T. auch sichtbar positive Trends simuliert. Im November ist dies für REMO in etwa umgekehrt, die RACMO-Trends sind deutlich schwächer als die der übrigen Modelle. RACMO simuliert großflächig schwächere relative Hitzetagetrends als die anderen beiden Modelle.

Für keinen Monat lässt sich über das gesamte Untersuchungsgebiet Einigkeit aller drei Modelle hinsichtlich der DMI-Trendvorzeichen erkennen. RACMO beispielsweise simuliert im Juli im gesamten Osten und Südosten Feuchtigkeitszunahmen, während die anderen fast flächendeckend mehr Trockenheit anzeigen. Im Februar und Oktober hingegen sich die Tendenzen von RACMO und REMO ähnlich, die von REMO eher widersprüchlich. Im April zeigen REMO (positiv) und ALADIN (negativ) flächendeckend in gegensätzliche Richtungen. Da die Werte des DMI oftmals in Form von Klassen interpretiert werden (siehe Tabelle 2.2), zeigt Abbildung 5.47 zusätzlich eine Gegenüberstellung der Projektionen am Ende des 20. und 21. Jahrhun-

dert im Durchschnitt der drei Modelle. Es sind hierbei die Monate Juni–September sowie die Gesamtjahreswerte dargestellt, doch auch in den übrigen Monaten ergibt sich eine Verschiebung hin zu trockeneren Klassen. Die Abbildung zeigt zunächst die trockensten Verhältnisse im Gebiet Oberrheingraben inkl. Wetterau sowie im (östlichen) Maindreieck. Auch der Bereich der Orlasenke sowie die Umgebung Nürnbergs heben sich durch niedrigere DMI vom Rest des Untersuchungsgebietes ab. Zwischen den beiden Zeiträumen ist eine deutliche Abnahme der Feuchtigkeitsverhältnisse zu beobachten, so dass am Ende des 21. Jahrhunderts von Juli bis September fast ganz Unterfranken sowie der Großteil des Untersuchungsgebietes unterhalb der humiden Klassen einzuordnen ist. Hinsichtlich der Modelle unterscheidet sich ALADIN insofern von den beiden anderen, als dass hier im Juni niedrigere Werte zum Ende des 20. Jahrhunderts projiziert werden, die zum Ende des 21. Jahrhunderts jedoch steigen. Im Juli verändern sich die Werte zwischen den betrachteten Zeiträumen kaum, im August und September sind die Ergebnisse in beiden Perioden höher (weniger Trockenheit).




Abbildung 5.47: DMI-Projektionen Ende des 20. und 21. Jahrhunderts (Multimodellmittelwert).

Klasseneinteilung des DMI siehe Tabelle 2.2.

5.4.3.2 Spätfrost

Während bezüglich der Abnahme der Spätfrosttage bei monatsbezogener Vegetationsperiode große Einigkeit der drei Modelle besteht, sind die Ergebnisse für den Spätfrost mit thermisch definierter Vegetationsperiode komplexer: RACMO simuliert ausschließlich positive Trends,

ALADIN im Mittel positive Trends mit Minimum im negativen Bereich und REMO durchschnittlich negative Trends mit Maximum im positiven Bereich⁵¹.




Abbildung 5.48: Spätfrosttrends im 21. Jahrhundert (30-jährige gleitende Mittel) für REMO und zwei weitere RCMs. Trends der regionalen Mittelwerte (alle signifikant) sowie Mittelwert, Minima und Maxima der regionalen Trends. Symbole siehe Abbildung 5.46-.

Die Unterschiede der Modelle werden durch die räumliche Betrachtung (Abbildung 5.49) – hier der relativen Trends im Vergleich zum Mittelwert 1971–2000 – verdeutlicht. Die Abbildung enthält zum Vergleich zusätzlich die – ebenfalls durch QM11 korrigierten – Simulationen des REMO-Vorläufermodells (REMO2009 anstatt REMO2015), das jedoch auf dem gleichen Globamodell MPI-ESM-LR basiert. Für REMO2015 wird eine VPT-Spätfrostzunahme im TFF und der Rhön sowie schwächer in Teilen der UG-Nordwestens und im zentralen Unterfranken projiziert, im Oberrheingebiet sowie im Südosteck des Untersuchungsgebietes die stärksten Abnahmen. Der Anteil und die Stärke der negativen Werte nimmt dann über ALADIN und REMO2009 zu RACMO ab, die der positiven Tendenzen zu, wobei für das Oberrheingebiet (+Kraichgau) für ALADIN und REMO2009 (schwächer werdende) negative für RACMO dann relativ zum UG-Rest die geringsten positiven Trends simuliert werden.

⁵¹Zum Vergleich: Die MOS-Ergebnisse für REMO sind im Mittel leicht positiv (5,9–8,2 d/100a). Der räumliche Wertebereich der besten MOS-Methode GLM pz2 liegt zwischen -36,4 und 111,4 d/100a (diffuses Raumbild). Für VPM beträgt der Trend der besten MOS-Methode MLR-pz2 -2,4 d (-15,1–9,8 d/100a).

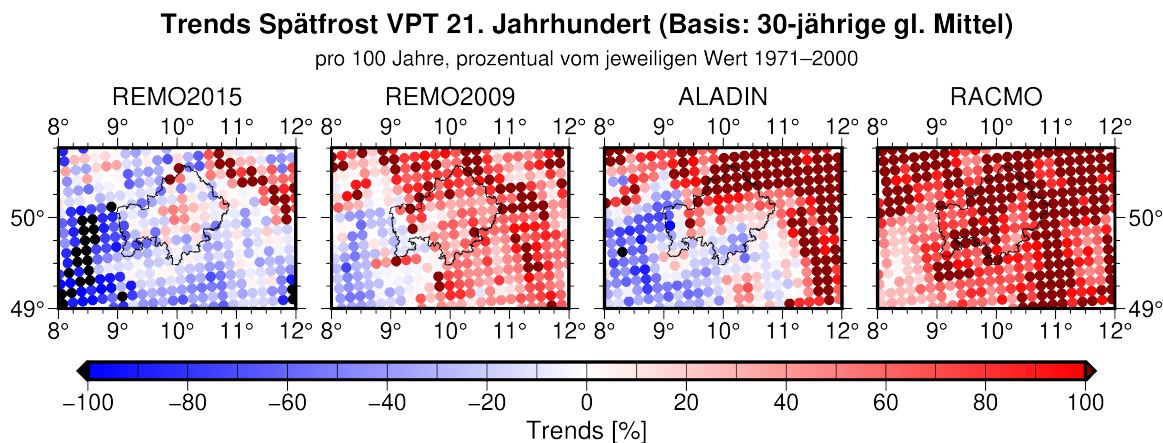


Abbildung 5.49: Karten der VPT-Spätfrosttrends im 21. Jahrhundert relativ zum jeweiligen Mittelwert 1971–2000. REMO2015, REMO2009, ALADIN und RACMO.

5.4.4 Gesamtsynthese

Die Güte der besten Biaskorrekturen übertrifft für alle monatlichen Kennwerte und Monate sowie beide Spätfrostindizes stets diejenige der beiden MOS-Varianten⁵². Hierbei stellt sich überwiegend das nicht-parametrische Quantilmapping, in einigen Situationen jedoch auch das PDF-Matching (parametrisches Quantillmapping) als beste Methode heraus. Diese unterscheiden sich von den anderen beiden Biaskorrekturverfahren insofern, als dass sie die gesamte Verteilung anpassen. Im Vergleich zu dem auf einer parametrischen Verteilung beruhenden PMPE, arbeitet QM11 mit empirischen Quantilen und somit flexibler aber hinsichtlich der Quantilanzahl begrenzt.

Die Zukunftsprojektionen der korrigierten Modelldaten von REMO und den zwei weiteren RCMs ALADIN und RACMO lassen sich wie folgt zusammenfassen, wobei v.a. hinsichtlich der Kennwerte mit Niederschlagsbezug z.T. räumliche und modellbasierte Unterschiede vorhanden sind:

- Tendenziell mehr und längere Sommertrockenheit, mehr Starkregenereignisse im Winter
- Weniger Frost- und Eis- sowie mehr Hitzetage
- Abnahme der Spätfrostereignisse hinsichtlich der monatsdefinierten Vegetationsperiode

⁵²Ausnahme: Eine Situation mit hohen verbleibenden Restfehlern (Frosttage Sep. pQRMSE 171,1 %), wobei diese und je zwei weitere Eis- und Hitzetagssituationen mit wenigen beobachteten Ereignissen und minimalen pQRMSE-Werten von über 100 % nicht in die Zukunftsanalysen eingehen

- Widersprüchliche Ergebnisse hinsichtlich der Spätfrosthäufigkeit gemäß temperaturbasierter Vegetationsperiode: Zunahme im Thüringisch-Fränkischen Wald samt Fichtelgebirge, in Teilen des nordwestlichen Untersuchungsgebietes sowie des zentralen Unterfrankens durch alle betrachteten Modelle simuliert. Abnahmen oder geringe Zunahmen im Oberrheingebiet und Kraichgau.

6 Ertragszahlen

Die MOS-Ergebnisse bezüglich der Erträge aus Landwirtschaft und Weinbau unterscheiden sich in zweierlei Hinsicht von denen der klimatischen Kennwerte:

- Die Erträge sind nicht direkt aus Klimamodelldaten berechenbar. Es existiert also keine modellinterne Vergleichsbasis. Somit kann keine Güte der Verbesserung betrachtet werden.
- Die Beobachtungszeitreihen sind sehr kurz. Sie beginnen für die Landwirtschaft 1983, für den Weinbau 1994. Somit ist keine unabhängige Validierung klimatologischer Statistiken (Richtwert hierfür 30 Jahre) möglich.
- Aufgrund der geringeren räumlichen Auflösung (Frankenwein keine Raumdimension, Landwirtschaftserträge zwölf Landkreise Unterfrankens) ist die Rechenressourcenbeanspruchung deutlich geringer. Es können daher je Einzelsituation die möglichen Methoden durchgeführt und die jeweils beste gewählt werden.

Es wird daher anschließend ausschließlich auf gewählte Optionen, Prädiktoren sowie Güte von MOS REMO-Eval eingegangen (Abschnitt 6.1), um darauf folgend direkt die REMO-basierten Zukunftsprojektionen (6.2) zu beschreiben. Diese werden – wie für die klimatischen Kennwerte – ebenfalls auf Basis eines Multimodellensembles betrachtet (6.3) und die Ergebnisse abschließend zusammengefasst (6.4).

6.1 MOS REMO-Eval

6.1.1 Optionen

Für die 36 Situationen (12 Landkreise \times 6 Feldfrüchte) der zu simulierenden landwirtschaftlichen Erträge werden jeweils alle in Kapitel 4.4.4 beschriebenen Optionen berechnet. Alle einzelnen Möglichkeiten werden je nach Situation gewählt.

Für die Frankenweinerträge resultierten die besten Modelle mit dem Kreuzvalidierungsansatz 12+4+3 Jahre. Für Weiß- und Rotwein werden GLMs mit Gamma-EDM und reziproker Link-

funktion (inverse-Link) gewählt, für die Gesamterträge die MLR-Variante. Die Weiß- und Gesamtweinsimulation ist unter Einbezug von u- und v-Windkomponenten am erfolgreichsten, die Rotweinmodellierung mit Hauptkomponenten aus Basis der zeitbegrenzten PCA. Für die Korrelation zwischen den Prädiktoren gilt die Grenze $|r| < 0,5$. Die Ergebnisse für Weiß- und Rotweinerträge ändern sich durch die Verwendung standardisierter Prädiktoren nicht.

Dies bedeutet zusammengefasst folgende Optionenauswahl:

- Weißwein: GLM-bs12-uv-preco-Gamma(inverse)
- Rotwein: GLM-bs12-pcaf-w-preco-Gamma(inverse)
- Gesamtwein: MLR-bs12-uv-preco

Für alle LW- und FW-Situationen ergeben sich gültige Modelle.

Anders als bei der Ergebnisdarstellung der klimatischen Kennwerte wird anschließend nicht zwischen MLR und GLM unterschieden, sondern stets nur die beste Option verwendet.

6.1.2 Prädiktoren

Wie schon für die klimatischen Kennwerte, finden auch bei der Simulation der landwirtschaftlichen großräumige Prädiktoren (89,2 % PCs) häufiger Anwendung als lokale (11,8 % 3×3 -Fenster). Die relative Häufigkeit der Prädiktorvariablen ist in Abbildung 6.1 dargestellt. Es werden ausschließlich oberflächennahe Variablen genutzt, die nachfolgenden Aussagen beziehen sich stets auf PC-Prädiktoren. Für Hafer werden spezifische Luftfeuchtigkeit und Luftdruck auf Meereshöhe am häufigsten verwendet. Erstere ebenfalls für Silomais, gefolgt von Mittel- und Maximumtemperatur. Der Luftdruck auf Meereshöhe sowie die maximale Windgeschwindigkeit besitzen für die Sommergerste, die spezifische Luftfeuchtigkeit für die Wintergerste die höchste Auswahlanzahl. Für Winterraps ist der Gesamtabfluss gefolgt von der Mitteltemperatur, für Winterweizen die spezifische Luftfeuchtigkeit gefolgt vom Niederschlag der am häufigsten selektierte Prädiktor. Insgesamt werden spezifische Luftfeuchte, Luftdruck auf Meereshöhe sowie Niederschlag am stärksten genutzt.

Lokale Prädiktoren finden bei der Frankenweinsimulation nur für die Gesamterträge Verwendung (Evaporation, sensible Wärmeflüsse, Niederschlag). Ansonsten sind es ausschließlich PC-Prädiktoren. Für den Weißwein werden hierbei Bodenfeuchte, Niederschlag, Luftdruck auf




Abbildung 6.1: Gewählte Prädiktoren der Simulation landwirtschaftlicher Erträge.

Meereshöhe u- und v-Windkomponente selektiert, für den Rotwein Bewölkung, Bodenfeuchte, Oberflächenwindgeschwindigkeit, Maximum- und Minimumtemperatur. Die beiden letztgenannten Variablen fließen doppelt in die Modellierung ein. Der Frankenweingesamtertrag besitzt die meisten Prädiktoren. Neben der genannten lokalen Prädiktoren kommen hierfür zudem PC-Prädiktoren von Evaporation, latenten Wärmeflüssen, Oberflächen- und Gesamtabfluss, Minimaltemperatur sowie u- und v-Windkomponente zum Einsatz.

6.1.3 Modellgüte

Im Gegensatz zu den klimatischen Kennwerten liegen alle Mean Squared Skill Scores der Simulation von LW- und FW-Erträgen im positiven Bereich. Wie Abbildung 6.3 zeigt, liegen für die meisten Situationen sehr gute Simulationsqualitäten der landwirtschaftlichen Erträge vor. Die schlechtesten Ergebnisse weist die Sommergerste für Stadt und Landkreis Würzburg (MSSS und $R^2 < 0,5$) auf. Ansonsten liegt nur der MSSS für Hafer im Landkreis Haßberge unter 0,5 (0,48). Die interne Variabilität (mittlere quadratische Abweichung) der Referenzdaten ist also in den meisten Fällen mehr als doppelt so groß wie Fehler. Ebenso wird bis auf zwei




Abbildung 6.2: Gewählte Prädiktoren der Frankenweinsimulation.

Ausnahmen der Großteil der beobachteten Varianz durch die modellierten Daten beschrieben. Für alle Feldfrüchte und Landkreise liegen die prozentualen Mittelwertfehler (ohne Abbildung) im Kontrollzeitraum unter 10 %. Die stärksten relativen Standardabweichungsfehler treten mit ca. 60 % für den Hafer im Landkreis Haßberge auf. In etwa einem weiteren Viertel der Situationen liegen sie zwischen 20 und 50 %, ansonsten darunter. Die höchsten pQRMSE-Werte liegen für den Winterraps in den Landkreisen Haßberge (12,4 %) und Bad Kissingen (11,0 %) vor, ansonsten betragen sie unter 10 %.

Die Qualität der Modellierung der Frankenweinerträge liegt mit MSSS-Werten von minimal 0,88 (Rotwein) sowie R^2 -Werten von minimal 0,98 (Gesamtwein) noch über derer der Landwirtschaftserträge. Die Abweichungen der simulierten von den beobachteten Werten sind also deutlich geringer als die interne Variabilität der Referenzdaten (MSSS) und der Großteil der Schwankungen wird von den Simulationen erfasst.

Im Kontrollzeitraum betragen die prozentualen Mittelwertfehler -0,7 % (Weißwein), -0,1 % (Rotwein) bzw. -0,2 % (Gesamtwein), die der Standardabweichung 10,2 %, -12,2 % bzw. 10,6 % sowie die pQRMSE 3,2 %, 4,8 % bzw. 2,1 % (ohne Abbildung).

Eine Validierung der REMO-ESM-Ergebnisse ist aufgrund des begrenzten Beobachtungsdatenumfangs nicht möglich. Die Zeitreihen der landwirtschaftlichen Erträge beginnen 1983, die der Frankenweinerträge 1994. Mit dem historischen Zeitraum der REMO-ESM-Daten bis 2005 stehen also 23 bzw. 12 Jahre zur Verfügung. Diese Dauer ist für eine Betrachtung klimatologischer Statistiken zu gering und zudem steht kein unabhängiger Kontrollzeitraum zur Verfügung, da die Jahre 1983–2007/2008 (LW) bzw. 1994–2008/2009 (FW) für das Training der Modelle




Abbildung 6.3: MSSS und R^2 Simulationen landwirtschaftliche Erträge Kontrollzeitraum.

verwendet wurde (siehe Abschnitt 4.4.4.3, Seite 82). Die Wahl der besten Methode erfolgt demnach gemäß der MOS REMO-Eval-Modellgüte wie bereits beschrieben. Anhand dieser werden die Zukunftsprojektionen berechnet.




Abbildung 6.4: MSSS und R^2 Simulationen Frankenweinerträge Kontrollzeitraum.




Abbildung 6.5: Simulierte Trends der landwirtschaftlichen Erträge im 21. Jahrhundert.
Prozentual vom jeweiligen Mittelwert 1971–2000.

6.2 Zukunftsprojektionen

Abbildung 6.5 zeigt die simulierten Trends der landwirtschaftlichen Erträge im 21. Jahrhundert prozentual vom Mittelwert des Basiszeitraum 1971–2000 (alle Angaben pro 100 Jahre). Im Durchschnitt aller Landkreise werden für die Sommerfeldfrüchte Hafer, Silomais und Sommergerste signifikante Ertragsab- (-12,1 %, -7,8 %, -14,3 %), für die Winterfeldfrüchte Wintergerste, -raps und -roggen signifikante Ertragszunahmen (6,0 %, 13,6 %, 5,8 %) projiziert. Für alle untersuchten Anbauprodukte existieren jedoch in mindestens einem der unterfränkischen Landkreise auch gegensätzliche Trends, was für die Wintererzeugnisse häufiger der Fall ist. Für den Landkreis Aschaffenburg werden positive Trends für Hafer und Silomais modelliert (+22,8 % bzw. +7,8 %), für die Stadt Aschaffenburg und den Landkreis Main-Spessart Zunahmen der Sommergersteerträge (+31,8 % bzw. +2,6 %). Für diese drei Fruchtarten sind zudem jeweils die Trends eines Landkreises nicht signifikant (Hafer NES, Silomais HAS, Sommergerste Lkr. AB, alle negativ). Die stärksten Trends belaufen sich auf -44,0 % (Hafer HAS), -27,6 % (Silomais Lkr. SW) bzw. -52,4 % (Sommergerste Kfs. SW). Für die Winterfrüchte bestehen größere Gegensätze. Für Wintergerste liegen die Trends zwischen -17,9 % (Kfs. AB) und 37,9 % (Kfs.

SW), für Winterraps zwischen -18,3 % (HAS) und 61,3 % (Lkr. AB) sowie für Winterweizen zwischen -14,2 % (HAS) und 39,5 % (MIL). Mit Ausnahme der Winterweizentrends für Stadt Würzburg und Landkreis Kitzingen (auch positiv) sind alle Winterfruchttrends signifikant. Für die absoluten Trends treten die Minima und Maxima aller betrachteten Anbauprodukte in den gleichen Landkreisen auf, nur für den Hafer ist das relative (-44,0 %=-17,5 dt/ha HAS) nicht gleich dem absoluten Minimum (-18,2 dt/ha=-39,4 % KT).

Für die zukünftige Entwicklung der Frankenweinerträge ergeben sich durch die Simulation anhand der besten gewählten Methoden widersprüchliche Tendenzen – wie in Abbildung 6.6 ersichtlich. Da Weiß-, Rot- und Gesamtweinertrag unabhängig voneinander modelliert werden, ist die Kohärenz der einzelnen Berechnungen nicht gewährleistet. Während also für die Weiß- und Rotweinerträge negative Trends von -9,8 % bzw. -10,2 % projiziert werden, resultiert für den Gesamtweinertrag eine Zunahme um 11,0 % für das 21. Jahrhundert (alle signifikant).




Abbildung 6.6: Simulierte Trends der Frankenweinerträge im 21. Jahrhundert. Prozentual vom jeweiligen Mittelwert 1971–2000.

6.3 Anwendung auf Multimodellensemble

Werden die Simulationen der landwirtschaftlichen Erträge mit den drei weiteren Regionalklimamodellen ALADIN, HIRHAM und RACMO wiederholt, so ergeben sich im Mittel aller Landkreise Unterfrankens signifikante Trends der gleichen Vorzeichen wie auf REMO-Basis für die betrachteten Feldfrüchte. Diese sind für die Sommerfeldfrüchte auf REMO-Basis am stärksten, für Hafer und Sommergerste auf RACMO- (-6,0 % bzw. -4,1 %), für Silomais auf ALADIN-Basis (-3,3 %) am schwächsten. Die durchschnittlichen Ertragstrends der Winter-




Abbildung 6.7: Simulierte Trends der landwirtschaftlichen Erträge im 21. Jahrhundert durch REMO und drei weitere regionale Klimamodelle. Prozentual vom jeweiligen Mittelwert 1971–2000.

gerste liegen zwischen 5,2 % (RACMO) und 8,5 % (HIRHAM), des Wintererapses zwischen 8,3 % (HIRHAM) und 16,9 % (ALADIN) sowie des Winterweizens zwischen 5,8 % (REMO) und 11,8 % (ALADIN). Für alle Feldfrüchte und Modelle treten in mindestens zwei, maximal fünf Landkreisen (nicht REMO s.o.) signifikante Trends entgegen des jeweiligen Durchschnitts auf. Für die Sommergerste sind alle Trends signifikant, ansonsten liegen die Trends mindestens eines Modells und Landkreises außerhalb des signifikanten Bereichs. Die Ertragsrends der Landkreise betragen für Hafer -44,0–22,8 % (REMO HAS, REMO Lkr. AB), für Silomais -27,6–10,1 % (REMO Lkr. SW, HIRHAM Lkr. AB), für Sommergerste -52,4–31,8 % (REMO Kfs. SW, Kfs. AB), für Wintergerste -25,8–37,9 % (ALADIN Kfs. AB, REMO Kfs. SW), für Wintereraps -51,8–75,2 % (HIRHAM HAS, ALADIN Lkr. AB) sowie für Winterweizen -21,4–39,5 % (HIRHAM HAS, REMO MIL).

Hinsichtlich der Frankenweinerträge wird die beschriebene Inkohärenz durch die Simulationen auf Basis der ALADIN- und RACMO-Daten verringert bzw. aufgehoben (vgl. Abbildung 6.8): Die Trends der Weißweinerträge sind positiv (22,0 % bzw. 4,5 %), die der Rotweinerträge ne-




Abbildung 6.8: Simulierte Trends der Frankenweinerträge im 21. Jahrhundert durch REMO und drei weitere regionale Klimamodelle. Prozentual vom jeweiligen Mittelwert 1971–2000.

gativ (-17,5 % bzw. -16,5 %), sodass je nach Anteil des Weiß- und Rotweins am Gesamtwein dessen simulierter positiver Trend von 10,8 % bzw. 15,0 % eine mögliche Kombination beider darstellt. Die Vorzeichen der basierend auf HIRHAM modellierten Tendenzen entsprechen denen von REMO (Weißwein -12,8 %, Rotwein -15,1 %, Gesamtwein 3,9 %). Einigkeit aller Modelle besteht demnach nur bezüglich einer Zunahme der Gesamtweinerträge.

6.4 Gesamtsynthese

Die Simulation der landwirtschaftlichen Erträge ist je nach Feldfrucht und Landkreis mit unterschiedlichen Methodenkombinationen sowohl hinsichtlich der Regressionsform (MLR, GLM mit verschiedenen EDM-Familien und Linkfunktionen) als auch der gewählten Optionen (Bootstrappingarchitektur, Standardisierung, Setup der PCA u.a.) am erfolgreichsten. Für die Ertragsimulation von Weiß- und Rotwein werden Gamma-GLMs mit inverse-Linkfunktion, für die des Gesamtweins eine Multiple Lineare Regression, jeweils mit 12+4+4 Jahren Bootstrapping verwendet. Weiß- und Gesamtweinsimulation nutzen u- und v-Wind als zusätzliche Prädiktoren, die Hauptkomponenten-Prädiktoren des Rotweins entstammen einer (auf den Beobachtungszeitraum des Frankenweines) begrenzten PCA.

Die in den vorangehenden Abschnitten formulierten Ergebnisse hinsichtlich der Zukunftsprojektionen durch die jeweils besten Methoden lassen sich folgendermaßen zusammenfassen: Im Mittel aller Landkreise werden sowohl von REMO als auch von den drei Regionalmodellen ALADIN, HIRHAM und RACMO abnehmende Sommer- sowie zunehmende Winterfeldfruchterträge für das 21. Jahrhundert simuliert. Hinsichtlich der Frankenweinerträge ist die Übereinstimmung zwischen den Modellen geringer. Während basierend auf REMO- und HIRHAM-Daten fallende Weiß- und Rot-, jedoch steigende Gesamteinertragszahlen (= Widerspruch) projiziert werden, weisen die Ergebnisse auf ALADIN- und RACMO-Basis in Richtung niedriger Rot- sowie höherer Weiß- und Gesamtweinerträge.

7 Diskussion

Um die Ergebnisse dieser Arbeit besser einordnen und ihre Implikationen abschätzen zu können, wird in den folgenden Abschnitten (Kapitel 7.1) auf den Zusammenhang zwischen Klima, Klimawandel und Pflanzenproduktion eingegangen. Anschließend werden die Kernergebnisse der vergangenen Kapitel zusammengefasst (7.2) und diskutiert (7.3)

7.1 Pflanzenproduktion und Klimawandel

7.1.1 Wechselwirkungen zwischen Klima und Pflanzen

Viele atmosphärische Faktoren wirken sich direkt oder indirekt auf Pflanzen, ihr Wachstum und ihre Gesundheit aus. Hierzu gehören neben verschiedenen Aspekten von Temperatur und Niederschlag unter anderem auch die Konzentrationen von troposphärischem Ozon (O₃) und Kohlenstoffdioxid (CO₂), welche nicht in die Analysen dieser Arbeit eingegangen sind.

Troposphärisches Ozon Troposphärisches Ozon entsteht bei hohen Temperaturen und vermehrt bei hohen Methangehalten (z.B. KERSEBAUM *et al.* 2009; BEZNER KERR *et al.* 2022). Es wirkt sich nicht nur negativ auf Ernteerträge, sondern auch auf Makro- und Mikronährstoffgehalte aus (z.B. KERSEBAUM *et al.* 2009; BEZNER KERR *et al.* 2022; SCHALLER & WEIGEL 2007). Hierbei sind in Bezug auf die in dieser Arbeit betrachteten Feldfrüchte Gerste, Hafer, Mais und Wein weniger anfällig als Raps, Weizen zeigt die größten Auswirkungen (KERSEBAUM *et al.* 2009).

Kohlendioxid Die Folgen hoher atmosphärischer bzw. in diesem Fall bodennaher CO₂-Konzentrationen auf die Pflanzenentwicklung ist vielfältiger, wobei gegensätzliche Wirkungen auftreten.

Auf der einen Seite steht der CO₂-Düngeeffekt. Da Kohlenstoffdioxid der limitierende Faktor für die Photosyntheseleistung von C₃-Pflanzen⁵³ ist, führt eine erhöhte CO₂-Konzentration zu einer Verstärkung ihrer photosynthetischen Aktivität und durch die damit einhergehende Assimilationssteigerung zu erhöhter Produktivität. Gleichzeitig steigt die Wassernutzungseffizienz durch verringerte Verdunstung (auch bei C₄-Pflanzen), da die Stomataöffnung der Pflanzen vermindert wird. Die reduzierte Transpiration jedoch induziert eine Erwärmung der Blätter, was wiederum die Atmung verstärkt und somit die Netto-Photosyntheseleistung verringert (DAMATTA *et al.* 2010; GÖMANN *et al.* 2017; KERSEBAUM *et al.* 2009; FISCHER *et al.* 2002; SCHALLER & WEIGEL 2007). Zusätzlich hängt die CO₂-bedingte Photosynthese- und Produktivitätssteigerung von weiteren Faktoren wie der Stickstoff-, allgemein Nährstoff- und Wasser-
verfügbarkeit ab (FISCHER *et al.* 2002; FELBERMEIR 2011; GÖMANN *et al.* 2017; HÖGY & FANGMEIER 2008). WANG *et al.* (2020) stellen eine Abnahme des globalen CO₂-Düngeeffektes in den letzten Jahrzehnten fest, den sie mit verringerter Wasser- und Nährstoffverfügbarkeit in Verbindung bringen.

Je nach Pflanzenart ist eine Assimilationssteigerung nicht unbedingt mit einer Ertragssteigerung gleichzusetzen, da hierdurch vor allem das Wachstum von Knollen bzw. Wurzeln verstärkt wird (FISCHER *et al.* 2002; SCHALLER & WEIGEL 2007). Des Weiteren bedingen gesteigerte CO₂-Konzentrationen Veränderungen der Pflanzenqualität bzgl. ihrer Makro- und Mikronährstoffe. Erhöhte Kohlenhydrat- stehen hierbei verringerten Proteingehalten gegenüber (BMELV 2008; DAMATTA *et al.* 2010; DIER *et al.* 2020; GÖMANN *et al.* 2017; HÖGY & FANGMEIER 2008; SCHALLER & WEIGEL 2007). Die Studienlage zu den konkreten Auswirkungen auf die Mikronährstoffzusammenstellung ist weniger deutlich und teilweise widersprüchlich (DIER *et al.* 2020; HÖGY & FANGMEIER 2008; KERSEBAUM *et al.* 2009; WANG & LIU 2021), wobei häufig von einer Mineralstoffabnahme ausgegangen wird (BEZNER KERR *et al.* 2022; DIER *et al.* 2020; FISCHER *et al.* 2002). Diese Uneindeutigkeit ist vermutlich auf die komplexe Interaktion

⁵³Die meisten Pflanzen sind C₃-Pflanzen. Die Kohlenstoffassimilation im Zuge der Photosynthese erfolgt hier zunächst in Form eines Moleküls mit drei Kohlenstoffatomen (daher C₃-Pflanze), bei den selteneren C₄-Pflanzen mit vier Kohlenstoffatomen. C₄-Pflanzen besitzen eine höhere Photosyntheseleistung, eine höhere Lichtsättigung, ein höheres Photosynthese-Temperaturoptimum und einen niedrigeren CO₂-Kompensationspunkt (im Gegensatz zu C₃-Pflanzen ist dieser nicht temperaturbeeinflusst) als C₃-Pflanzen, zudem findet im Unterschied zu C₃-Pflanzen keine Lichtatmung der Blätter statt. Hinzu kommen weitere physiologische und anatomische Unterschiede. Beispiele für C₄-Pflanzen sind Mais, Zuckerrohr oder Hirse (SCHOPFER & BRENNICKE 2010)

biotischer und abiotischer Rahmenbedingungen (Standort, Boden, Pflanzenart, Nährstoffverfügbarkeit, ...) zurückzuführen (DIER *et al.* 2020; WANG & LIU 2021).

Veränderungen von Temperatur und Niederschlag (Hitze und Trockenheit) können die positiven CO₂-Effekte verringern und die negativen Effekte verstärken (z.B. DAMATTA *et al.* 2010; WANG & LIU 2021).

Temperatur Sowohl die Photosyntheseaktivität als auch die Atmung von C3-Pflanzen sind temperaturabhängig, folgen jedoch keinem linearen Zusammenhang hierzu (vgl. Abbildung 7.1, genaue Werte unterscheiden sich je nach Pflanze und Einflussfaktoren). Die Photosyntheseleistung erreicht ihr Maximum zwischen 20 und 32 °C, die Atmungsrate zwischen 30 und 40 °C (bei Lichtsättigung). Bei heißen Temperaturen übersteigt somit die Atmung die Bruttphotosynthese, was zu einer negativen Nettophotosynthese führt, Assimilation also verhindert (KERSEBAUM *et al.* 2009; PORTER & SEMENOV 2005). Aus Abbildung 7.1 lässt sich auch schließen, dass die Optimaltemperaturen für die Nettophotosynthese- und damit Assimilationsrate etwa zwischen 10 und 15 °C liegen (je nach Pflanze unterschiedlich), bis zu diesen Temperaturen verläuft die Entwicklung in etwa linear zur Temperatur (PORTER & SEMENOV 2005). Das Temperaturoptimum und damit auch die Grenze zum Hitzestress liegt bei C4-Pflanzen höher als bei C3-Pflanzen (z.B. DIEPENBROCK *et al.* 2012). Der Temperatureinfluss auf die Nettophotosynthese hängt primär von der Blatttemperatur ab. Diese wird neben der Einstrahlung und der Lufttemperatur v.a. durch die Wasserversorgung der Pflanze beeinflusst. Ist diese ungenügend, so wird durch Stomataverschluss die Transpiration verringert, was zu einer Erhöhung der Blatttemperatur und damit zur Verringerung der (Netto-)Photosyntheseleistung führt (KERSEBAUM *et al.* 2009; vgl. Abschnitt zum CO₂-Effekt). Hitzestress⁵⁴ kann sowohl die Pflanzenqualität als auch die Erträge negativ beeinflussen (z.B. BEZNER KERR *et al.* 2022; DAMATTA *et al.* 2010; KERSEBAUM *et al.* 2009; WANG & LIU 2021), wobei die Auswirkungen vom Zeitpunkt der erhöhten Temperaturen im Bezug auf die phänologische Entwicklung von Bedeutung ist (KERSEBAUM *et al.* 2009).

PELTONEN-SAINIO *et al.* (2010) fanden eine negative Beeinflussung von Gersten-, Weizen- sowie Raps-erträgen in Europa (1975–2008) durch erhöhte Temperaturen in verschiedenen phä-

⁵⁴ „Der Begriff Hitzestress wird zunehmend verwendet, um diese negativen Auswirkungen hoher Temperaturen auf das Pflanzenwachstum zu beschreiben“ (REZAEI *et al.* 2015)




Abbildung 7.1: Schematische Darstellung zur Temperaturabhängigkeit von Photosynthese und Atmung bei C3-Pflanzen, verändert nach PORTER & SEMENOV (2005).

nologischen Abschnitten. Auch die Reviewartikel von REZAEI *et al.* (2015) und WANG & LIU (2021) bestätigen die negativen Auswirkungen von Hitze auf Getreideerträge. Die Wirkungen auf die Inhaltsstoffe der Pflanzen sind etwa ein erhöhter Eiweißgehalt (mit einhergehendem verringerten Stärke- bzw. Ölgehalt) bei Weizen und Raps. Bei Äpfeln kann es zur Veränderung der Farbe sowie zur Verringerung der Süße kommen, wobei für erstere v.a. erhöhte Nachttemperaturen bedeutsam sind (GÖMANN *et al.* 2017; SCHALLER & WEIGEL 2007).

Allerdings wird auch die Phänologie der Pflanzen hinsichtlich des Beginns sowie der Dauer der einzelnen Phasen durch die Erwärmung verändert (BEZNER KERR *et al.* 2022; GÖMANN *et al.* 2017; SCHALLER & WEIGEL 2007). Dies bringt einige mitunter problematische Folgen mit sich: Zum Einen wird die Kopplung von Temperatur(summen) und Tageslänge (Photoperiodizität) bzw. von Temperatur(summen) und Lichtintensität sowohl innerhalb der pflanzlichen Entwicklung als auch hinsichtlich der Entwicklung von Schadinsekten gestört: Die Vegetationsperiode und einzelne phänologische Stadien sind je nach Pflanzenart nicht nur von der Temperatur, sondern auch von der Photoperiodizität abhängig, das Auftreten von Schädlingen kann in andere – empfindlichere oder weniger empfindliche – Entwicklungsphasen fallen (GÖMANN *et al.* 2017; SCHALLER & WEIGEL 2007; BEZNER KERR *et al.* 2022). Zum Anderen wirkt sich der frühere Vegetationsbeginn auf das Spätfrostisiko aus (z.B. CHMIELEWSKI 2007; SCHALLER & WEIGEL 2007) und kürzere bzw. schnellere Entwicklungsstadien können zur Verringerung

von Erträgen führen (z.B. GÖMANN *et al.* 2017). Problematisch sind zudem (wieder je nach Pflanzenart) relativ hohe Temperaturen in Herbst und Winter, da durch erstere eine Abhärtung der Wintergetreide ausbleibt und zweitens die für die adäquate Entwicklung vieler Kulturen benötigten Kältereiz (Vernalisation) verhindern (GÖMANN *et al.* 2017; SCHALLER & WEIGEL 2007).

Wasserversorgung Wie bereits erwähnt ist die Blatttemperatur abhängig von der Wasserverfügbarkeit, weswegen die Auswirkungen von Wasser- und Hitzestress zum Teil gleich und nicht voneinander trennbar sind (KERSEBAUM *et al.* 2009). Auch die negativen Folgen von Wassermangel variieren je nach phänologischer Phase (GÖMANN *et al.* 2017; KERSEBAUM *et al.* 2009). Nichtsdestotrotz ist Wasser „einer der am häufigsten limitierenden Faktoren für das Pflanzenwachstum“ (KERSEBAUM *et al.* 2009), da nicht nur die Wärmeregulierung, sondern auch Nährstoffversorgung, Photosynthese und viele weitere fundamentale Prozesse innerhalb der Pflanze davon abhängen (KERSEBAUM *et al.* 2009). So führt Wassermangel u.a. zur Photosyntheseabnahme (Stomataverschluss zur Transpirationsverringering) und so zur Assimilationsverringering (KERSEBAUM *et al.* 2009; FISCHER *et al.* 2002).

Die genannten Auswirkungen klimatischer Einflussfaktoren auf die Pflanzenqualität und -quantität sind, wie bereits erwähnt, vom zeitlichen Auftreten hinsichtlich der phänologischen Entwicklung abhängig (PELTONEN-SAINIO *et al.* 2010). Auch positive Effekte etwa durch leichte Temperaturerhöhungen oder gesteigerte atmosphärische CO₂-Gehalte sind möglich (z.B. GÖMANN *et al.* 2017; FALLOON & BETTS 2010), während sich nicht nur Trockenheit, sondern auch starke Niederschläge (je nach Zeitpunkt) negativ auswirken können (PELTONEN-SAINIO *et al.* 2010). Gerade einzelne Extremereignisse die (mitunter) von Mittelwertstatistiken nicht wiedergegeben werden, besitzen eine hohe Relevanz bzgl. Erntemenge und -güte (z.B. GÖMANN *et al.* 2017; LÜTTGER & FEIKE 2018; PORTER & SEMENOV 2005). Hagel ist ein Beispiel hierfür, insbesondere im Wein- und Obstbau, kann jedoch nicht modelliert werden (BUTH *et al.* 2015). Zusätzlich ergeben sich indirekte Klimaeinflüsse z.B. über den Boden oder das Auftreten von Pflanzenschaderegern (GÖMANN *et al.* 2017; EEA 2019).

Pflanzengesundheit Durch Veränderungen von Temperatur und Niederschlag werden nicht nur die Wachstumsbedingungen der Kulturpflanzen, sondern auch von Beikräutern und Schaderegern modifiziert (CHMIELEWSKI 2007; SCHALLER & WEIGEL 2007; BEZNER KERR *et al.*

2022; BUTH *et al.* 2015). Hinsichtlich ersterer ist v.a. mit einem Wechsel des Artenspektrums sowie (wie bei den Kulturpflanzen) einem schnelleren Ablauf der phänologischen Phasen zu rechnen (CHMIELEWSKI 2007; SCHALLER & WEIGEL 2007). Bei zweiteren ist zwischen Pflanzenkrankheiten und Schadinsekten zu unterscheiden. Pilze sind die Hauptverursacher von Pflanzenkrankheiten (SCHALLER & WEIGEL 2007). Da sie auf milde bis warme, vor allem aber feuchte Bedingungen angewiesen sind, hängt ihre zukünftige Relevanz von den jeweiligen konkreten Temperatur- und Niederschlagsvoraussetzungen ab (BUTH *et al.* 2015; CHMIELEWSKI 2007; SCHALLER & WEIGEL 2007). Im Bezug auf Schadinsekten ist mit einer veränderten Artenzusammensetzung aufgrund erhöhter Temperaturen zu rechnen. Das Ausbleiben starker Winterkälte und generell wärmere Bedingungen fördern zudem den Befallsdruck durch erhöhte Überwinterungschancen, früheres Auftreten und mehr Generationen sowie Aktivitätssteigerung (BMELV 2008; BUTH *et al.* 2015; CHMIELEWSKI 2007; SCHALLER & WEIGEL 2007). Hinzu kommt eine höhere Sensitivität der Pflanzen durch veränderte Bedingungen (BUTH *et al.* 2015; CHMIELEWSKI 2007; SCHALLER & WEIGEL 2007). Global wird im Rahmen des Klimawandels von einer Zunahme des Schädlingsdrucks und damit einhergehenden Produktivitätsverlusten ausgegangen (BEZNER KERR *et al.* 2022; FISCHER *et al.* 2002).

Die Wechselwirkungen zwischen Pflanzen(-qualität und -quantität) und ihren vielfältigen abiotischen sowie biotischen Einflussgrößen sind hochkomplex und oftmals noch unzureichend erforscht, was die Abschätzung der konkreten Auswirkungen des veränderten Klimas erschwert (z.B. BARNABÁS *et al.* 2008; DAMATTA *et al.* 2010; LÜTTGER & FEIKE 2018; PORTER & SEMENOV 2005). Hinzu kommen anthropogene Faktoren (vgl. z.B. auch NELSON *et al.* (2014) zu ökonomischen Landwirtschaftsmodellen), etwa hinsichtlich der Bewirtschaftungsintensität, wie das folgende Beispiel der europäischen Getreideertragsentwicklung der letzten Jahrzehnte verdeutlicht.

7.1.2 Stagnationen europäischer Ackerfrucherträge

In vielen Ländern Europas konnte seit den 1990er Jahren eine Stagnation der Getreideerträge (z.T. mit Ausnahme von Mais) beobachtet werden (MOORE & LOBELL 2015; OLESEN *et al.* 2011; SUPIT *et al.* 2010; WIESMEIER *et al.* 2015).

Laut FINGER (2010) ist diese etwa in der Schweiz (keine Stagnation Maiserträge) auf eine politisch motivierte Extensivierung mit dem Ziel eines besseren Umweltschutzes zurückzuführen.

Auch für Frankreich werden vermehrter biologischer Anbau und verringerte Stickstoffdüngung genannt, ebenso wie Modifikationen in der Fruchtfolge sowie politische und finanzielle Gründe, aber auch hitze- und trockenheitsbedingte Einbußen (BRISSON *et al.* 2010; SCHAUBERGER *et al.* 2018). Im aktuellen Sachstandsbericht des IPCC (IPCC 2022b; BEZNER KERR *et al.* 2022) wird der Klimawandel als Grund für die Verringerung der landwirtschaftlichen Produktivitätssteigerungen, global und in den mittleren Breiten angeführt.

Gesamteuropäisch betrachtet sind neben klimatischen Veränderungen solche der Bewirtschaftungsmaßnahmen sowie damit im Zusammenhang stehende politische und ökonomische Gründe als mögliche Ursachen zu nennen (EU-weite gemeinsame Agrarpolitik, Düngeverordnungen, Preisabnahmen) (SUPIT *et al.* 2010; WIESMEIER *et al.* 2015). MOORE & LOBELL (2015) gehen davon aus, dass etwa 90 % der Ertragsstagnation politisch bedingt sind. Für diese politische Komponente spricht auch die Entwicklung der deutschen Weizenerträge, denn „im Vergleich zu seinen Nachbarstaaten Schweiz und Österreich beginnt die Stagnation der Ertragstrends aufgrund der anhaltenden Ertragszunahmen in den neuen Bundesländern der ehemaligen DDR in den 1990er Jahren etwa 10 Jahre später“ (OLESEN *et al.* 2011; vgl. WIESMEIER *et al.* 2015). Die Studie von LÜTTGER & FEIKE (2018) deutet ebenfalls auf die Relevanz nicht-klimatischer Faktoren auf die deutschen Weizenerträge hin, wobei der klimatische Einfluss 2001–2010 im Vergleich zum betrachteten Gesamtzeitraum 1981–2010 stärker ausfällt.

Dass Maiserträge hiervon teilweise nicht betroffen sind (z.B. in Deutschland), könnte neben klimatischen Ursachen (MOORE & LOBELL 2015) insofern politisch bedingt sein, als dass Mais im Rahmen des Ausbaus erneuerbarer Energien (Energiewende) verstärkt zur Energieproduktion verwendet wird (PEICHL *et al.* 2018). Ähnliches gilt für Raps, der im europaweiten Vergleich nur in Dänemark (wahrscheinlich temperatur- und strahlungsbedingt) und Deutschland Ertragssteigerungen erfährt. Neben dem CO₂-Düngeeffekt nennen SUPIT *et al.* (2010) Anpassungen in Bearbeitungstechniken und Pflanzenschutz als mögliche Gründe. Raps wird in Europa zur Biodieselherstellung angebaut, was in vielen Regionen Deutschlands sehr effizient möglich ist (VAN DUREN *et al.* 2015). In Deutschland ist Silagemais die bei weitem wichtigste Energiepflanze für die Biogaserzeugung, Raps für die Biodieselproduktion, Körnermais wird zudem zur Bioethanolherstellung genutzt (FNR 2022a,b).

Hieraus lässt sich erkennen, dass hinsichtlich der Ertragsentwicklungen auch anthropogene Faktoren (politisch, ökonomisch, technisch etc.) von Relevanz sein können.

7.1.3 Feldfrüchte und ihre klimatischen Ansprüche

Zu den klimatischen Ansprüchen der betrachteten Feldfrüchte ist zunächst festzustellen, dass Wintergetreide durch die Aussaat im Herbst des Erntevorjahres und die früheren Erntezeitpunkte eine geringere Sensitivität gegenüber Trockenheit besitzt als Sommergetreide (WEBBER *et al.* 2018; vgl. TRAPP *et al.* 2013a). In langjährigen Feldversuchen in Berlin nahmen die Variationskoeffizienten der Erträge und damit ihre klimatische Beeinflussbarkeit⁵⁵ von Mais über Hafer und Sommergerste zu Winterroggen ab, generell ist Hafer trockenheitsanfälliger als Sommergerste (CHMIELEWSKI & KÖHN 1999). Informationen zur Verwendung der Feldfrüchte findet sich im Anhang A3.

7.1.3.1 Körnergetreide

Weizen Winterweizen ist die wichtigste Feldfrucht Deutschlands (LÜTTGER & FEIKE 2018; SCHALLER & WEIGEL 2007). Er erzielt im Vergleich zu anderen Getreidearten die höchsten Erträge (DIEPENBROCK *et al.* 2012). Allerdings besitzt er einen hohen Wasserbedarf (DIEPENBROCK *et al.* 2012; SCHALLER & WEIGEL 2007), weshalb bei geringer Wasserverfügbarkeit Wintergerste ertragreicher ist (DIEPENBROCK *et al.* 2012). Für Erntequalität und -quantität ist außerdem die Nährstoffversorgung wichtig (DIEPENBROCK *et al.* 2012; DIER *et al.* 2020). Obwohl er milde Winter und warme Sommer bevorzugt, bedarf eine adäquate Entwicklung mindestens 40 Tagen Vernalisation (Temperaturen von max. 5 °C, Sommerweizen 1–14 Tage) und zu hohe – mit Niederschlagsarmut einhergehende – Sommertemperaturen können sich schädigend auswirken (DIEPENBROCK *et al.* 2012; TRAPP *et al.* 2013a). Im Jahr 2006 mit einem von Hitze und Trockenheit geprägten Sommer zeigte die Weizengüte deutliche Abweichungen, allerdings konnten diese Stressauswirkungen bei biologisch angebautem Weizen nicht festgestellt werden, woraus sich eine schützende bzw. puffernde Wirkung durch gesunde Böden und extensive Bewirtschaftung ableiten lässt (SCHALLER & WEIGEL 2007). Allgemein konnte von 1981 bis 2010 ein sich verstärkender (statistischer) Zusammenhang zwischen Weizenerträgen in den Landkreisen Deutschlands und Hitze- bzw. Dürreindikatoren festgestellt werden, wobei im letzten betrachteten Jahrzehnt eine höhere Korrelation zu heißen Temperaturen während der

⁵⁵Hier geschah zwar keine Betrachtung von Einflussfaktoren, die Rahmenbedingungen ließen jedoch ausschließlich klimatische Fluktuationen zu.

Blütezeit vorlag (LÜTTGER & FEIKE 2018). Generell zeigen Studien die hohe Relevanz von Sorte und Standort im Bezug auf klimatische Auswirkungen (KERSEBAUM & NENDEL 2014; MÄKINEN *et al.* 2018; REZAEI *et al.* 2018; WANG & LIU 2021).

Gerste Wintergerste ist das am zweithäufigsten angebaute Getreide Deutschlands (DIEPENBROCK *et al.* 2012; SCHALLER & WEIGEL 2007). Im Vergleich zu Winterweizen besitzt Gerste eine geringere Anfälligkeit im Bezug auf trockene Sommerbedingungen (DIEPENBROCK *et al.* 2012). Sommergerste ist weder hitze- noch trockenheitsempfindlich (SCHALLER & WEIGEL 2007).

Hafer Hafer benötigt viel Wasser (mehr als andere Sommergetreidesorten) und gedeiht am besten bei relativ geringen Temperaturen (DIEPENBROCK *et al.* 2012; SCHALLER & WEIGEL 2007).

7.1.3.2 Andere betrachtete Feldkulturpflanzen

Mais In den letzten Jahrzehnten dehnte sich die Maisanbaufläche in Deutschland deutlich aus (OLESEN *et al.* 2011), was unter anderem auf seine Nutzung als Energiepflanze für die Erzeugung von Strom, Wärme und Brennstoff zurückzuführen ist (PEICHL *et al.* 2018; FNR 2022a,b). Dennoch nimmt die Verwendung von Silomais zur Biogaserzeugung nur den zweiten Rang nach der Nutzung als Viehfutter ein (FNR 2022b). Mais als (einzige betrachtete) C4-Pflanze benötigt mehr Wärme und Strahlung, jedoch weniger Wasser als C3-Pflanzen. Der größte Wasserbedarf liegt im Juli und August vor. Da Silomais im Vergleich zu Körnermais vorzeitig geerntet wird, sind die Wärmeansprüche geringer (DIEPENBROCK *et al.* 2012; SCHALLER & WEIGEL 2007).

Raps 99,6 % des deutschen Rapsanbaus fällt auf Winterraps. Raps wird auf 78,0 % der bayrischen Ölsaatenanbaufläche angebaut und umfasst 81,2 % der Ölsaatenerträge (alle Zahlen zu Raps aus dem Jahr 2021, LEL & LFL 2022). Er ist auf eine gute Wasserversorgung angewiesen, wobei Winterraps wie die erwähnten Wintergetreidesorten von der Feuchtigkeit aus den Wintermonaten profitiert und auch im Sommer niedrige Temperaturen bevorzugt (DIEPENBROCK *et al.* 2012; SCHALLER & WEIGEL 2007).

7.1.3.3 Klimatische Anbaubeschränkungen

Eine Umfrage in 26 europäischen Ländern zu Klimawandel und Landwirtschaft (OLESEN *et al.* 2011) ergab für die kontinentale Zone (in der sich das Untersuchungsgebiet befindet) derzeitige klimatische Beschränkungen für Winterweizen v.a. durch Wasser (zu viel, zu wenig, während Aussaat bzw. Ernte), für Sommergerste durch Trockenheit, für Körnermais durch Trockenheit sowie Regen während Aussaat oder Ernte sowie für den Weinbau durch Früh- und Spätfrost. Hinzu kommen für die beiden letztgenannten noch die Länge der Vegetationsperiode sowie das Hagelrisiko. Für die Zukunft werden Besserungen der Ernte- bzw. Saatbedingungen sowie geringere Frost- und Hagelgefahr angenommen. Demgegenüber stehen jedoch erwartete Verstärkungen im Bezug auf Hitzestress, Krankheitsbefall, Stickstoffverluste, saisonale Variabilitäten, Trockenheit und Erosion. Im Bezug auf alle betrachteten Länder wird Trockenheit schon heute als der wichtigste Faktor gesehen.

7.1.4 Simulation von Feldfruchterträgen

Die Simulation landwirtschaftlicher Erträge kann statistisch (wie in dieser Arbeit) oder prozessbasiert (durch so genannte Crop Models) erfolgen. Die durch Literatur belegten Studien hierzu erstrecken sich in der Regel auf größere Gebiete als das in dieser Arbeit untersuchte und nutzen globale oder regionale Klimamodelle.

7.1.4.1 Prozessbasierte Modelle

KERSEBAUM & NENDEL (2014) beispielweise nutzen das prozess-basierte Modell HERMES unter Verwendung von statistisch (WETTREG) downgescalten GCM-Daten und einem mittlerem Emissionsszenario für die Simulierung der deutschen Weizenerträge. Für den Zeitraum 2021–2050 im Vergleich zu 1961–1990 resultieren leichte Ertragssteigerungen, jedoch nur bei Beachtung des CO₂-Düngereffektes. Ansonsten werden aufgrund abnehmender Niederschläge deutlichere Einbußen projiziert. Hierbei treten standortspezifische Unterschiede auf.

Kleinräumiger sind die Untersuchungen von RIEDIGER *et al.* (2014) zur Simulation des Bewässerungsbedarfs verschiedener Feldfrüchte anhand eines boden- und pflanzenspezifischen Evapotranspirationsmodells (keine Ertragsmodellierung) für den Landkreis Uelzen in Niedersachsen (3 GCMs, statistisch downgescalt mit STARS II (ORLOWSKY *et al.* 2008)). Die Pro-

jektionen ergeben eine Ausweitung des Bewässerungsbedarfs. Je nach Temperaturanstieg (trotz gleicher Szenarien fällt dieser für die drei Modelle unterschiedlich stark aus) übersteigt die notwendigen Grundwasserentnahme die zugelassenen Mengen.

In der Untersuchung von SEMENOV & SHEWRY (2010) auf Basis des Weizensimulationsmodells Sirius mit Daten aus 15 CMIP3-GCMs werden die europäischen Erträge in Zukunft insbesondere von heißen Temperaturen während des Blütezeit betroffen sein, wohingegen Sommertrockenheit (trotz Zunahme in den Projektionen) aufgrund früherer Erntereife weniger negative Auswirkungen haben wird. DONATELLI *et al.* (2015) hingegen sehen Niederschlag bzw. dessen Mangel als ausschlaggebend für die projizierten Weizen-ertragsabnahmen sowie Raps-ertragsstagnationen bis -abnahmen in Europa in den nächsten Jahrzehnten (CropSyst-Modell mit RCM-Daten und mittlerem Szenario, mit Anpassungen s.u. werden Zuwächse projiziert).

Die Auswirkungen von Hitze- und Trockenstress auf Körnermais und Winterweizen in Europa werden von WEBBER *et al.* (2018) mithilfe eines Ensembles aus sechs (Mais) bzw. acht (Weizen) Crop Models analysiert. Für die Projektionen der zukünftigen Veränderungen werden Daten aus fünf CMIP5-GCMs hinzugezogen und der Zeitraum 2040–2069 (verschiedene RCP-Szenarien) mit 1981–2010 verglichen. In Jahren mit geringen Erträgen sind die Einbußen hauptsächlich auf Trockenstress zurückzuführen (kein positiver CO₂-Effekt), wobei im Bezug auf alle Jahre Trockenstress für Weizen – im Gegensatz zu Mais – kaum eine Rolle spielt. Etwa ein Viertel der Variabilität beider Feldfrüchte wird durch Schwankungen der Mitteltemperatur beschrieben, wobei die Hinzunahme von Hitzestress über alle Jahre betrachtet keinen Mehrwert mit sich bringt. Ein Vergleich der interannuellen Variabilität beider Pflanzen zeigt geringere Schwankungen für Weizen (Beobachtungen und Simulationen), was auf eine höhere Abhängigkeit des Mais von meteorologischen Bedingungen schließen lässt⁵⁶. Die Zukunftssimulationen zeigen sinkende Erträge für Mais (europaweit etwa 20 %) sowie steigende Erträge für Weizen (4 %), letztere jedoch nur bei Einbezug des CO₂-Düngeeffektes (ansonsten -9 %, kaum Relevanz bei Mais). Für Deutschland (Zukunft) ist Trockenheit die wichtigste Modelleinflussgröße, verstärkt in ertragsarmen Jahren. Der Einfluss der Mitteltemperatur ist für stärkere Szenarien größer als für schwächere Szenarien. Hitzestress ist als Prädiktor kaum von Relevanz.

⁵⁶Hierbei ist zu beachten, dass indirekte Auswirkungen wie Krankheiten, Vernässung oder Umknicken nicht Teil der Modelle sind.

Die Ergebnisse deuten auf die bereits erwähnte bessere Trockenheitsresistenz von Wintergetreide hin (WEBBER *et al.* 2018).

Die Effekte von schrittweisen Temperatur- und Niederschlagsveränderungen auf Weizenerträge in Finnland, Deutschland und Spanien werden von PIRTIOJA *et al.* (2015) mithilfe eines prozessbasierten Modellensembles untersucht. Ein Ertragsrückgang ist hierbei durch Temperaturzu- und Niederschlagsabnahmen, ein Ertragszuwachs durch Niederschlagszunahmen zu verzeichnen.

Insgesamt und global betrachtet sind die Projektionen (Prozessmodell GTAP-W auf Basis von GCM-Daten und zwei Zukunftsszenarien bis Mitte des 21. Jahrhunderts) der durch die Temperaturzunahme bedingten Ertragsabnahme stärker als die der CO₂-bedingten Ertragszunahme, es wird also von einem Rückgang der landwirtschaftlichen Produktion ausgegangen (CALZADILLA *et al.* 2013). Auch die Simulationen von ASSENG *et al.* (2019) legen ein Überwiegen der negativen Auswirkungen von Temperatur- und Niederschlagsentwicklung im Vergleich zum positiven CO₂-Effekt bis 2050 auf die globale Weizenertragsmenge und -qualität nahe (Basis: 32 Weizenmodelle, 5 GCMs, RCP8.5 2040–2069). ROSENZWEIG *et al.* (2014) modellieren ebenfalls weltweit klimawandelbedingte Ertragsverluste (Landwirtschaft insgesamt), wobei die Effekte stärker ausfallen, wenn die Modelle eine Simulation der Stickstoffversorgung beinhalten (auch ASSENG *et al.* (2019) stellen die Abhängigkeit des CO₂-Düngeeffektes von der Stickstoffversorgung fest). Die Signale im Bezug auf die Erträge im Gebiet *Unterfranken+* (Untersuchungsgebiet dieser Arbeit) sind nicht klar erkennbar, zeigen aber für Mais und Weizen tendenziell in positive Richtung (ROSENZWEIG *et al.* 2014).

Bei all diesen Ergebnissen ist zu beachten, dass die Effekte von Hitze- oder Froststress nicht oder nur unzureichend in prozessbasierten Modellen implementiert sind (BARLOW *et al.* 2015).

7.1.4.2 Statistische Modelle

Vergangenheitsrekonstruktion Viele statistische Ertragsmodellierungsansätze beziehen sich ausschließlich auf die Rekonstruktion der Vergangenheit auf Basis von Beobachtungsdaten zur Abschätzung relevanter meteorologischer (und anderer) Einflussfaktoren, so etwa folgende Beispiele:

KERN *et al.* (2018) simulieren die Erträge von Winterweizen, Raps, Mais und Sonnenblumen in Ungarn 2000–2016 mittels multipler linearer Regression. Neben meteorologischen Daten wer-

den hierfür weitere Prädiktoren verwendet (Bodenwasser, Düngung, fernerkundungsbasierte Vegetationsindizes). Hohe Minimumtemperaturen führen hierbei zu deutlichen Ertragsverlusten. Drei verschiedene Regressionsarten werden von GORNOTT & WECHSUNG (2016) zur (erfolgreichen) Simulation deutscher Winterweizen- und Silomaisertragsänderungen genutzt, wobei auch nicht-klimatische Prädiktoren einbezogen werden.

Auch künstliche Intelligenz wird für die Simulation von deutschen Feldfruchterträgen benutzt, von LISCHIED *et al.* (2022) beispielsweise die Machine Learning-Verfahren Random Forest und Support Vector Machines. Hierbei werden Silomais sowie Winterweizen, -raps und -gerste in 351 deutschen Landkreisen 1978–2017 simuliert. Der direkte anthropogene Einfluss (Kulturtechniken, Züchtung) wird anhand eines nichtlinearen Trends der 95. Perzentile der Beobachtungsdichten geschätzt und vor dem Simulieren entfernt. Durch ihn können bis zu 34 % der Varianz beschrieben werden, was auf die bereits angesprochene hohe Relevanz menschlicher Einflussnahme auf die Erträge hindeutet. Die Modellgüte auf Basis verschiedener Prädiktorenkombinationen (monatliche meteorologische Variablen und Bodenfeuchte sowie zeitlich invariante Bodenwasserhaltekapazität) ist zum Teil sehr ähnlich, wobei Niederschlag und Minimumtemperatur am häufigsten gewählt werden (Mitteltemperatur nicht einbezogen, $r_p = 0,97$ zwischen Maximum- und Minimumtemperatur). POLLINGER *et al.* (2017) nutzen sowohl Random Forest als auch MLR (in zwei Varianten) für die Perfect Prog-Simulation der Phänologieentwicklung in Bayern. Die Zukunftsprojektionen zeigen für alle Methoden und ein mittleres sowie hohes Szenario (unterschiedlich ausgeprägt) ein früheres Einsetzen der Forsythienblüte, wobei aufgrund der Beschränkung der Random Forest-Simulationsbreite auf den beobachteten Wertebereich von dieser Methode abgeraten wird.

Für die globale Simulation (Vergangenheitsrekonstruktion auf Basis von Beobachtungsdaten) von Anomalien der Mais-, Sojabohnen-, Reis- und Sommerweizenerträge nutzen VOGEL *et al.* (2019) ebenfalls Random Forest-Modelle. Je nach Fruchtart werden hierbei unter Verwendung monatlicher Werte von Temperatur und Niederschlag sowie sieben Extremindizes 20–49 % der Gesamtvarianz der globalen Durchschnittsertragsanomalien beschrieben (R^2 , auf Ebene der Kontinente nur für Mais in Afrika und Sommerweizen in Ozeanien über 50 %; Europa Mais 47 %, Sommerweizen 28 %, Reis und Soja 6 %). Hierdurch zeigt sich, dass weitere Aspekte in die realistische Modellierung miteinbezogen werden müssen. Nichtsdestotrotz eröffnet der Vergleich mit einer Simulation ohne die Indexprädiktoren die zum Teil hohe Relevanz von Extremereignissen auf die Simulation der Ertragsanomalien. So sind je nach räumlichem Maßstab,

Verortung und Feldfrucht Extremereignisse für einen Großteil der simulierten Ertragsschwankungen verantwortlich. Dabei ist der Einfluss der Temperatur (sowohl -mittel als auch -extrema) größer als der des Niederschlages, sowohl extreme Kälte als auch extreme Hitze wirken sich ertragsmindernd aus.

PAETH *et al.* (2008) nutzen einen ähnlichen Ansatz wie in der vorliegenden Arbeit für Simulation von landwirtschaftlichen Erträgen in Benin. Hierbei wird eine MLR-Transferfunktion mit Temperatur-, Niederschlags-, und rel. Luftfeuchtigkeitsprädiktoren auf Basis von REMO-Eval-Daten erstellt und anschließend auf REMO-Daten mit Antrieb durch ein GCM sowie Implementierung von Landnutzungs- und Bodenqualitätsänderungen übertragen.

Vergleich statistischer und prozessbasierter Modelle Um die Güte statistischer Modelle abzuschätzen werden von einigen Studien Crop Model-Ergebnisse als Pseudorealität bzw. Vergleichsbasis genutzt:

Einen Vergleich zwischen dem Potential statischer Modelle (drei regressionsbasierte Varianten) mit einem prozessbasierten Maismodell (Afrika südlich der Sahara) stellen LOBELL & BURKE (2010) an. Zum Einen zeigen die Ergebnisse den Einfluss der höheren räumlichen und zeitlichen Variabilität der Niederschläge im Vergleich zur Temperatur. Zum Anderen werden die Medianwerte zwar meist gut simuliert, die Einzelwerte zeigen jedoch deutliche Abweichungen. Eine räumliche Aggregation führt zur Verbesserung der Ergebnisse. Hierbei ist zu beachten, dass die Regressionen jeweils nur auf zwei Durchschnittsprädiktoren (Niederschlag und Temperatur über die gesamte bzw. gedrittelte Wachstumsperiode) basieren. Es werden also weder kürzere Zeitperioden wie etwa Monate, noch Extremereignisse widergespiegelt.

VOGEL *et al.* (2021) nutzen ein GLM-basiertes statistisches Modell, um Weizenertragsausfälle eines Crop Models zu reproduzieren und hinsichtlich möglicher Treiber zu untersuchen. Unter anderem in Zentraleuropa werden gute Regressionsergebnisse erzielt. Die Transferfunktionen basieren auf der Kombination verschiedener Variablen (Mittelwerte und Extrema) aus verschiedenen Monaten, wobei das Wasserdampfdefizit den wichtigsten Prädiktor darstellt.

Zukunftssimulationen mit Perfect Prog-Modellen Folgende Studien schließen auch Zukunftssimulationen ein, die dafür verwendeten Transferfunktionen basieren jedoch auf Beobachtungsdaten, weshalb es sich definitionsgemäß nicht um MOS-, sondern um Perfect Prog-Ansätze handelt. Dies bedeutet, dass keine Modellkorrektur beinhaltet ist, sondern davon aus-

gegangen wird, dass sich die simulierten wie die beobachteten Prädiktoren verhalten (vgl. Abschnitt 4.4).

Starke Abnahmen der deutschen Silomaiserträge für die Mitte und insbesondere das Ende des 21. Jahrhunderts werden von einem statistischen Modell (reduced-form panel approach) auf Basis von Bodenfeuchte- (Juni, August), Niederschlags- und Temperaturanomalien (beide Juli) aus fünf ECHAM5-getriebenen RCMs unter Verwendung eines mittleren Emissionsszenarios simuliert. Diese fallen in Süddeutschland höher aus. Durch Anpassungsmaßnahmen und Einbezug des CO₂-Düngeeffektes jedoch können leichte Ertragssteigerungen verzeichnet werden. Durch einen Bodenfeuchteindex auf Basis eines hydrologischen Modells wird hierbei eine prozessbasierte Komponente einbezogen. Es handelt sich bei dieser Studie von PEICHL *et al.* (2019) um Simulationen der Ertragsanomalien durch die Anomalien hydro-meteorologischer Variablen.

Bei der Modellierung von Winterweizenerträgen in Dänemark (KRISTENSEN *et al.* 2011) basierend auf agrarklimatischen Indizes (mittlere Temperatur-, Niederschlags- und Strahlungswerte für alle drei festgelegte Zeiträume) werden für die Zukunft (2 ENSEMBLES⁵⁷-RCMs mit mittlerem Szenario) abnehmende Erträge simuliert, wobei die Temperaturen von Mitte Juni bis Ende Juli den wichtigsten Prädiktor darstellen.

Das Ertragsmodell für verschiedene europäische Feldfrüchte von MOORE & LOBELL (2014) enthält nicht-meteorologische Prädiktoren in Form von ökologischen und ökonomischen sowie staatspezifischen Faktoren, linearen und quadratischen Trends. Hinzu kommen 30-jährige Mittelwerte der Temperaturen und Niederschläge in der Wachstumsperiode (WP) sowie deren Quadrate. Kurzfristige meteorologische Effekte werden durch quadrierte Abweichungen der VP-Temperaturen und -Niederschläge von der jeweiligen 30-Jahres-Referenz einbezogen. Das entstehende Perfect Prog-Modell wird zusätzlich ohne den Term zum kurzfristigen Wetter berechnet, um Anpassungsmöglichkeiten abzuschätzen. Es zeigt sich eine geringere Sensitivität von Mais und Ölsamen (Raps, Sonnenblumen u.a.) gegenüber steigenden Temperaturen im Vergleich zu Weizen und Gerste, für welche klimatische Aspekte wichtiger sind als andere Einflüsse. Demnach ergeben die Zukunftsprojektionen (13 ENSEMBLES-RCMS, mittleres Szenario, 2030–2049 verglichen mit 1960–1989) Ertragsabnahmen für Weizen und Gerste, hinsichtlich derer Anpassungsmaßnahmen wenig Verbesserungspotential aufweisen. Die leicht negativen

⁵⁷Durch die Europäische Kommission finanzierte Klimamodellierungsinitiative, die unter anderem ein Ensemble regionaler Klimamodelle beinhaltet (HEWITT & GRIGGS 2004; VAN DER LINDEN & MITCHELL 2009)

Projektionen für Mais hingegen sind den Ergebnissen nach durch entsprechende Maßnahmen besser abwendbar.

Auch für die Simulation außereuropäischer Erträge werden Perfect Prog-Ansätze verwendet, beispielsweise für verschiedene Hülsenfrüchte, Getreide und andere wichtige Anbauprodukte in Benin (AWOYE *et al.* 2017).

Fazit zur statistischen Modellierung zukünftiger Erträge Es existieren in der Literatur also viele Studien zur Perfect Prog-Simulation vergangener und auch zukünftiger Erträge. Der in dieser Arbeit gewählte Ansatz ist nach Kenntnis der Autorin hingegen eine Neuerung und bringt den Vorteil der impliziten Biaskorrektur der Modellprädiktoren mit sich. Der Unterschiedlichkeit der RCM-Daten wird durch die vorherige QM-Anpassung an die den Transferfunktionen zugrundeliegenden REMO-Eval-Daten Rechnung getragen.

7.1.4.3 Ergebnisse der Simulationen

Unabhängig von der gewählten Methoden lassen sich folgende Resultate hinsichtlich der zukünftigen Entwicklungen finden: ZHAO *et al.* (2017) fassen die Ergebnisse von prozessbasierten und statistischen Modellen sowie Feldversuchen im Bezug auf globale Ertragsänderungen durch steigende Temperaturen zusammen: Sowohl für Weizen als auch für Mais (und Reis und Soja) ist mit Verlusten zu rechnen (CO₂-Düngung und Anpassungsmaßnahmen nicht einbezogen). Weitere (Einzel-)Studien sprechen ebenfalls für klimawandelbedingte Rückgänge der globalen Weizen- (z.B. ASSENG *et al.* 2019) und generell Landwirtschaftserträge (z.B. CALZADILLA *et al.* 2013; ROSENZWEIG *et al.* 2014). Auch für Europa (z.B. DONATELLI *et al.* 2015; MOORE & LOBELL 2014; SEMENOV & SHEWRY 2010; WEBBER *et al.* 2018) und Deutschland (z.B. KERSEBAUM & NENDEL 2014) werden abnehmende Weizenernten projiziert, z.T. können diese Verluste jedoch bei Einbezug des CO₂-Düngeeffektes abgewendet und in leichte Steigerungen gekehrt werden (KERSEBAUM & NENDEL 2014; WEBBER *et al.* 2018). Ebenfalls auf Europa bezogen legen Modellierungen stagnierende bis leicht abnehmende Raps- (DONATELLI *et al.* 2015) sowie zurückgehende Gersten- (MOORE & LOBELL 2014) und Maiserträge (MOORE & LOBELL 2014; WEBBER *et al.* 2018) nahe. Letzteres wird für Deutschland von PEICHL *et al.* (2019) für Silomais bestätigt.

7.1.5 Anpassungsmaßnahmen

Einige der aufgeführten Modellierungen beinhalten die Möglichkeit zum Einbezug von Anpassungsmaßnahmen, durch die negative Auswirkungen teilweise verringert oder abgewendet werden können. Im Folgenden werden einige landwirtschaftliche Anpassungsmaßnahmen im Bezug auf den Klimawandel und seine Auswirkungen genannt. Die Ausführungen erheben keinen Anspruch auf Vollständigkeit und beziehen sich primär auf den Ackerbau. Teilweise sind sie aber auch auf Dauerkulturen anwendbar, beispielsweise hinsichtlich Bodenbearbeitung, -bedeckung und Bewässerung.

Eine Möglichkeit ist die Veränderung der Terminierung der Aussaat (und daraus folgender Tätigkeiten) (BEDNAR-FRIEDL *et al.* 2022; BEZNER KERR *et al.* 2022; BMELV 2008; EEA 2019; GÖMANN *et al.* 2017; KURUKULASURIYA & ROSENTHAL 2003; OLESEN *et al.* 2011). Dies ist laut einer europäischen Umfrage die bisher am häufigsten getätigte Anpassungsmaßnahme und hat zwei Vorteile: Zum Einen profitieren die Pflanzen stärker von der winterlichen Feuchtigkeit und zum Anderen erfolgt die Ernte früher, wodurch trocken-heiße Sommerbedingungen umgangen werden (OLESEN *et al.* 2011). Schon heute kommt es bei Weizen in Teilen Europas aus letztgenanntem Grund zur früheren Reife, was jedoch die Erträge schmälert (SEMENOV *et al.* 2014).

In einer Umfrage in Deutschland wird der Anbau geeigneter Sorten als wichtigstes Adaptionsinstrument genannt, wobei Erträge, Anfälligkeit gegenüber Trockenheit, Abknicken und generell gegenüber Umwelteinflüssen Hauptauswahlkriterien sind (MACHOLDT & HONERMEIER 2016; vgl. MACHOLDT *et al.* 2013). Das häufig aufgeführte Mittel der Sorten- oder Kultivarwahl (CHMIELEWSKI 2007; BEZNER KERR *et al.* 2022; BMELV 2008; EEA 2019; GÖMANN *et al.* 2017; OLESEN *et al.* 2011; VERBAND DER LANDWIRTSCHAFTSKAMMERN 2010) impliziert oftmals auch die Züchtung (BEZNER KERR *et al.* 2022; BMELV 2008; DAMATTA *et al.* 2010; EEA 2019; IPCC 2022b; OLESEN *et al.* 2011) neuer, im Bezug auf CO₂- und Temperaturanstieg, Hitze, Trockenheit sowie anderen Extremen (DAMATTA *et al.* 2010; OLESEN *et al.* 2011; SEMENOV *et al.* 2014; WANG & LIU 2021) angepasster Sorten.

Weitere Maßnahmen sind Anpassungen der Fruchtfolge (BEZNER KERR *et al.* 2022; BMELV 2008; CHMIELEWSKI 2007; EEA 2019; KURUKULASURIYA & ROSENTHAL 2003; VERBAND DER LANDWIRTSCHAFTSKAMMERN 2010) und -wahl (BEDNAR-FRIEDL *et al.* 2022; BEZNER KERR *et al.* 2022; BMELV 2008; CHMIELEWSKI 2007; EEA 2019; GÖMANN *et al.* 2017;

KURUKULASURIYA & ROSENTHAL 2003; OLESEN *et al.* 2011; VERBAND DER LANDWIRTSCHAFTSKAMMERN 2010)⁵⁸, der Pflanzennährstoffversorgung (BEZNER KERR *et al.* 2022; GÖMANN *et al.* 2017; WANG & LIU 2021), des Pflanzenschutzes (BMELV 2008; GÖMANN *et al.* 2017; OLESEN *et al.* 2011; VERBAND DER LANDWIRTSCHAFTSKAMMERN 2010) – auch durch natürliche und mechanische Verfahren und Bewirtschaftungsweisen (KURUKULASURIYA & ROSENTHAL 2003; VERBAND DER LANDWIRTSCHAFTSKAMMERN 2010) – sowie eine (künstliche) Bedeckung von Boden und Pflanzen (BEDNAR-FRIEDL *et al.* 2022; GÖMANN *et al.* 2017; EEA 2019). Eine Diversifizierung der Feldfrüchte streut nicht nur das Risiko von Ernteverlusten, sondern liefert auch einen ökologischen Zusatznutzen (BEZNER KERR *et al.* 2022; BMELV 2008; EEA 2019; GÖMANN *et al.* 2017; IPCC 2022b; KURUKULASURIYA & ROSENTHAL 2003).

Von zentraler Bedeutung ist die Wasserversorgung der Pflanzen. Hier (und hinsichtlich weiterer Aspekte wie z.B. Erosion) spielt die Bodenbearbeitung zur Verbesserung der Bodenwasserverfügbarkeit (Infiltration, Durchwurzelung, ...) eine große Rolle (BMELV 2008; IPCC 2022b; OLESEN *et al.* 2011). Auch die Saatkichten und -tiefen beeinflussen die Wasserversorgung (BMELV 2008). Ebenso kann Bewässerung sinnvoll und notwendig sein (BEDNAR-FRIEDL *et al.* 2022; BEZNER KERR *et al.* 2022; BMELV 2008; CHMIELEWSKI 2007; GÖMANN *et al.* 2017; IPCC 2022b), wobei dem nachhaltigen Wassermanagement und der Wassernutzungseffizienz eine zentrale Bedeutung zukommt (EEA 2019; KURUKULASURIYA & ROSENTHAL 2003; IPCC 2022b; OLESEN *et al.* 2011; VERBAND DER LANDWIRTSCHAFTSKAMMERN 2010), um Grundwasserressourcen zu schützen, Versalzung vorzubeugen und lokal- und regionalklimatische Auswirkungen zu verringern (IPCC 2022b). Je stärker die Temperaturen steigen, desto weniger Wasser wird jedoch für die Bewässerung zur Verfügung stehen (BEDNAR-FRIEDL *et al.* 2022).

Die Auswahl geeigneter Anpassungsmaßnahmen beinhaltet die Beachtung verschiedener Zeitskalen sowohl der Adaptioninstrumente (z.B. Aussattermin im Vergleich zu Installation aufwändiger Bewässerungsanlagen) als auch der Klimawandelauswirkungen (langfristige Mittelwertänderungen im Vergleich zu Jahresschwankungen und Extremereignissen) (KURUKULASURIYA & ROSENTHAL 2003; MOORE & LOBELL 2014; OLESEN *et al.* 2011). Anzustreben

⁵⁸So wurde in den letzten Jahren in Kontinentaleuropa u.a. aus klimatischen Gründen vermehrt Silo- und Körnermais angebaut (OLESEN *et al.* 2011)

sind hierbei nachhaltige, resilienzfördernde Aktivitäten mit positiven Nebeneffekten (nicht nur) im Bezug auf Klimawandelvermeidung und Biodiversität, etwa im Rahmen einer extensiven oder biologischen Landwirtschaft oder Agrarforstwirtschaft (vgl. BEZNER KERR *et al.* 2022; EEA 2019; IPCC 2022b).

Bisherige Maßnahmen können die globalen klimawandelbedingten Verluste nicht abwenden und selbst bei vollem Ausschöpfen bestehender Methoden ist weiterhin von Ernterückgängen auszugehen (BEZNER KERR *et al.* 2022). In Europa wäre ein größeres Ausmaß an Anpassungen nötig als bisher umgesetzt oder geplant, um Ertragsverlusten vorzubeugen (BEDNAR-FRIEDL *et al.* 2022). Hierbei behindern politische, ökonomische und andere Faktoren die Anpassung der Landwirtschaft an den Klimawandel (nicht nur, aber auch in Europa) (IPCC 2022b,a).

Laut der prozessbasierten Modellierung von DONATELLI *et al.* (2015) kann die simulierte zukünftige Weizenenertragsabnahme sowie die Rapsstagnation bis -abnahme in *Unterfranken*+ durch Anpassungsmaßnahmen abgewendet werden, sodass leichte Ertragssteigerungen projiziert werden. Die erfolgreichsten Maßnahmen sind hierbei die Verwendung von Kultivaren mit verlängerter Reifezeit sowie eine spätere Aussaat (im Gegensatz zur von OLESEN *et al.* (2011) genannten früheren Aussaat).

7.1.6 Weinbau

Im Vergleich zu den einjährigen Feldfrüchten kommt dem Wein als Dauerkultur eine Sonderstellung zu. Im Weinbausektor müssen langfristige Entscheidungen getroffen werden und beispielsweise Schädigungen der Pflanzen können langfristige Auswirkungen haben.

7.1.6.1 Studienlage im Bezug auf den Klimawandel

Durch die Temperaturabhängigkeit der Rebphänologie führt die Klimaerwärmung zu einer Veränderung – und zwar Verfrühung und Verkürzung – der phänologischen Phasen (DROULIA & CHARALAMPOPOULOS 2021; JONES & WEBB 2010; VAN LEEUWEN & DARRIET 2016; HOPPMANN *et al.* 2010). Dies konnte in den vergangenen Jahrzehnten auch in Deutschland z.B. in Rheinland-Pfalz (KOCH *et al.* 2018) sowie in Franken beobachtet werden (BOCK *et al.* 2011). Hieraus – sowie allgemein aus höheren Temperaturen – resultieren zum Einen höhere Zuckergehalte, zum Anderen aber auch Säureabbau und Aromaveränderungen (HOPPMANN *et al.* 2010;

JONES & ALVES 2012; VAN LEEUWEN & DARRIET 2016; GÖMANN *et al.* 2017). Auch Zukunftsprojektionen für die baden-württembergischen Weinbaugebiete auf Basis von multipler linearer Regression aus drei bioklimatischen Indizes zeigen gesteigerte Zucker- sowie verringerte Säuregehalte (NEUMANN & MATZARAKIS 2014).

Auch in Franken konnten in den vergangenen Jahrzehnten die generell beobachtbaren Tendenzen festgestellt werden: Eine Verkürzung und Verfrühung der phänologischen Phasen sowie höhere Zucker- und geringere Säuregehalte. Gleichzeitig nahmen die Erträge zu (BOCK *et al.* 2011, 2013). Regressionsanalysen legen nahe, dass neben klimatischen Faktoren (Temperatur allein sowie in Kombination mit Sonnenschein und Niederschlag) ein großer anthropogener Einfluss auf den Mostzuckergehalt und vor allem auf die Erntemenge besteht (BOCK *et al.* 2013).

Generell hängt die Weinqualität und -quantität neben natürlichen Faktoren auch von menschlichen – technischen – Faktoren ab. Die technologischen Veränderungen bzw. Verbesserungen im 20. Jahrhundert und darüber hinaus nahmen daher sicherlich großen Einfluss auf die Ertragsentwicklung und z.T. auch auf die Zusammensetzung. Nichtsdestotrotz ist das Klima ein wichtiger Faktor, v.a. im Bezug auf die Phänologie, deren Dauer und damit die Traubeninhaltsstoffe (HOPPMANN *et al.* 2010; JONES *et al.* 2005; JONES & DAVIS 2000; VAN LEEUWEN & DARRIET 2016; SCHULTZ 2016; BOCK *et al.* 2013, 2011).

Die beobachteten Veränderungen hinsichtlich Zucker- und Säuregehalt bedeuten eine Abweichung von den typischen Frankenweincharakteristika (z.B. BOCK *et al.* 2011), die durch die Lage an der nördlichen Weinbaugrenze mit relativ kühlem Klima durch eine ausgeprägte Säure- und Aromaentwicklung bestimmt sind bzw. waren (HOPPMANN *et al.* 2010; JACKSON 2000). Eine zukünftige Weiterführung der beobachtbaren Trends würde somit einen Verlust der Alleinstellungsmerkmale des Frankenweins mit sich bringen.

Die beschriebenen Veränderungen wirken sich nicht nur auf die Zusammensetzung aus, sondern können auch dazu führen, dass der Anbau bisher typischer Sorten in den jeweiligen Weinbauregionen in Zukunft nicht mehr möglich ist. Für jede Sorte existieren optimale klimatische Wachstumsbedingungen, welche in der Vergangenheit für die Etablierung typischer Rebsorten je Region entsprechend der dort vorherrschenden Klimaverhältnisse verantwortlich waren. Verändert sich nun das Klima in Bereiche außerhalb der jeweiligen Nische bedeutet dies eine Verringerung bzw. einen Verlust der Anbaueignung traditionell regionaltypischer Sorten (TATE 2001; JONES & WEBB 2010; VAN LEEUWEN & DARRIET 2016; SCHULTZ & JONES 2010;

JONES & ALVES 2012; JONES *et al.* 2005; DROULIA & CHARALAMPOPOULOS 2021). Die zukünftige räumliche Veränderung der Anbaueignung besteht also nicht nur in einer Ausweitung potenziell geeigneter Gebiete (z.B. DROULIA & CHARALAMPOPOULOS 2021), sondern auch in Veränderungen bzgl. Sorte und Charakteristika in bestehenden Regionen. Bei der Abschätzung dieser Veränderungen ist problematisch, dass Rebsorteneignung in der Regel über untere thermische Grenzen definiert wird, die obere Grenze der Eignung jedoch kaum bekannt sind (SCHULTZ 2016). Genau diese oberen Grenzen werden jedoch in Zukunft mehr und mehr überschritten werden (s.o. und z.B. JONES *et al.* 2005).

Die Anbaueignung des für Franken traditionell typischen Silvaners (HOPPMANN *et al.* 2010; KOCH *et al.* 2018) ist somit durch den erwarteten Temperaturanstieg und dessen Folgen bedroht, während sich die Bedingungen mehr in Richtung Rotweinanbau verändern (KOCH *et al.* 2018) (vgl. auch Abschnitt 7.1.6.2). Hinzu kommt, dass rote Rebsorten in der Regel eine höhere Trockenheitsresistenz besitzen als weiße (HOPPMANN *et al.* 2010).

Ebenso wie in der für diese Studie getätigten Befragung (Abbildung 2.8), wurde in einer Umfrage unter deutschen Weinbauern der Niederschlag als wichtigster klimatischer Aspekt genannt (BATTAGLINI *et al.* 2009 bzgl. Weinqualität). Auch wenn sommerliche Trockenheit zuträglich für die Weinqualität sein kann, ist Wassermangel insbesondere im Frühjahr und Frühsommer problematisch (HOPPMANN *et al.* 2010; JACKSON 2000). Gleichzeitig kann eine gute Wasserverfügbarkeit die negativen Folgen sehr hoher Temperaturen deutlich verringern (SCHULTZ 2016). Bei der Wasserversorgung spielen jedoch abgesehen von den atmosphärischen Bedingungen auch die Rebsorte (Riesling ist z.B. resistenter als Silvaner oder Müller-Thurgau), Boden, Bewirtschaftung und weitere Faktoren eine Rolle (HOPPMANN *et al.* 2010).

Hinsichtlich der Pflanzengesundheit kann eine Erhöhung der Temperaturen bei gleichzeitiger verstärkter Trockenheit allerdings auch positive Auswirkungen mit sich bringen. Die Ausbreitung von Pilzkrankheiten (z.B. Mehltau) ist auf feuchte Bedingungen angewiesen (HOPPMANN *et al.* 2010), insbesondere bei stärkeren Temperaturanstiegen wird daher z.B. für die östlichen italienischen Alpen eine Abnahme des Mehлтаubefalls simuliert (CAFFARRA *et al.* 2012). Wichtig ist aber auch hier nicht die jährliche Wasserbilanz, sondern die Verteilung der Feuchtigkeitsbedingungen über das Jahr (vgl. TRAPP *et al.* 2013b). Abgesehen hiervon profitieren jedoch viele Schädlinge auch von erhöhten Temperaturen, etwa durch die verstärkte Ausbreitung in bisher zu kalte Gebiete (HOPPMANN *et al.* 2010; TATE 2001). Für den Traubenwickler wird eine Erhöhung der Generationenzahl (von zwei auf drei) durch wärmere Bedingungen erwartet

(HOPPMANN *et al.* 2010), hierbei ist auch die zeitliche Übereinstimmung pflanzlicher und parasitärer Entwicklungsstadien relevant (STOCK *et al.* 2005). CAFFARRA *et al.* (2012) modellieren für die östlichen italienischen Alpen negative Auswirkung durch die Verschiebung der Entwicklungsstadien, sehen jedoch aufgrund der tendenziell früheren Weinlese in einer weiteren Generation der Schädlinge ein weniger bedeutsames Problem. Auch wenn durch die unterschiedlichen Auswirkungen verschiedener klimatischer Aspekte auf verschiedene Krankheitserreger und Schädlinge eine Gesamtbilanz schwer abzuschätzen ist, wird das sich verändernde Klima zu Veränderungen hinsichtlich der Schädlings- und Krankheitsbelastung führen (vgl. KOCH *et al.* 2018).

Nicht thematisiert werden in der vorliegenden Arbeit – sowohl hinsichtlich des Weinbaus als auch allgemein – das Hagelrisiko, welches unter anderem aufgrund mangelnder Beobachtungsdaten kaum bis nicht modellier- und daher projizierbar ist (vgl. Abschnitt 2.2, HOPPMANN *et al.* 2010), die Auswirkungen erhöhter atmosphärischer CO₂-Konzentrationen (siehe z.B. TATE 2001 bzgl. Weinquantität und -qualität) sowie Strahlungseinflüsse auf Weinmenge und -güte (vgl. z.B. VAN LEEUWEN & DARRIET 2016).

FRAGA *et al.* (2016a) simulieren auf Basis eines RCM-Ensembles (ein RCM mit vier GCM-Antrieben) mit Hilfe eines Ertragsmodells die zukünftigen Weinernteentwicklungen in Europa. Außer in Teilen Südeuropas resultieren hierbei ausschließlich gesteigerte Erträge für die Zukunft (2041–2070 im Vergleich zu 1980–2005, RCP8.5). Diese Projektionen sind jedoch in ihrer Aussage insofern begrenzt, als dass für ganz Europa Pinot noir, also Spätburgunder, als einzige angebaute Rebsorte angenommen wird⁵⁹.

Die erwarteten Temperatur- und Feuchtigkeitsveränderungen machen Anpassungsmaßnahmen notwendig (vgl. Abschnitt 7.1.5). Der Anbau wärmeliebender Sorten ist eine mögliche Option, bedeutet jedoch den Verlust traditioneller Sorten und damit regionaler Alleinstellungsmerkmale (SCHULTZ & JONES 2010; STOCK 2005; STOCK *et al.* 2005), wie im Exkurs in Abschnitt 7.1.6.2 erkennbar wird. Dies ist mitunter durch Bewirtschaftungsmaßnahmen abwendbar (vgl. STOCK *et al.* 2005 für Baden). Zum Einen kann Einfluss auf die mikroklimatischen Bedingungen genommen werden (Laub, Boden(bewuchs), Bewässerung etc.), zum Anderen ist eine „klimatische Anpassung der autochthonen weißen Rebsorten an den Klimawandel durch Klonsselektion und die Erprobung mediterraner Unterlagsrebsorten“ (HOPPMANN *et al.* 2010)

⁵⁹Zudem werden geringe anthropogene Maßnahmen einheitlich für ganz Europa angenommen.

möglich. Die Auswahl geeigneter Unterlagen (Wurzelstöcke, auf denen die Edelreben aufgepropft werden (vgl. z.B. JACKSON 2000; MIEDANER 2018)) sowie Klonenselektion innerhalb einer Sorte kann sowohl die Widerstandsfähigkeit gegenüber Wasserstress erhöhen als auch die Geschwindigkeit der phänologischen Entwicklung verringern, während die Charakteristika des Weins erhalten bleiben (VAN LEEUWEN & DARRIET 2016; vgl. z.B. MEGGIO *et al.* 2014; VERDUGO-VÁSQUEZ *et al.* 2021).

7.1.6.2 Exkurs: Rebsorten im Frankenweingebiet und deren thermische Eignung

Ein häufig für die Abschätzung der Rebsorteneignung verwendeter (z.B. STOCK *et al.* 2007; KOCH *et al.* 2018; MARTINS *et al.* 2021; MORIONDO *et al.* 2013; SCHULTZ & JONES 2010; NEUMANN & MATZARAKIS 2011, 2014) Kennwert ist der Temperatursummenindex nach HUGLIN (1976) – genannt Huglin-Index (HI):

$$HI = \sum_{Apr-Sep} \frac{(T_{mean} - 10) + (T_{max} - 10)}{2} \cdot k \quad (7.1)$$

mit T_{mean} Tagesmittel- und T_{max} Tagesmaximumtemperatur. Der Faktor k stellt eine Breitengradkorrektur dar. HUGLIN (1976) definiert feste Werte in 1,9° breiten Klassen zwischen 40,1 und 50°. Da das Untersuchungsgebiet jedoch über 50° N hinausgeht, wird k wie in STOCK *et al.* (2007) berechnet⁶⁰. Wie die Gleichung zeigt, werden ausschließlich Tagesmittel- und -maximumtemperaturen zwischen April und September betrachtet, der Index kann also nur als erster Anhaltspunkt dienen, lässt jedoch trotzdem Schlussfolgerungen zu.

Wird der Huglin-Index für die den fränkischen Weinorten am nächsten gelegenen Gitterzellen im EUR11-Gitter aus den Daten von REMO und den beiden anderen betrachteten RCMs ALADIN und RACMO berechnet und anschließend mit der als besten identifizierten Korrekturmethode QM11 biaskorrigiert, so ergibt sich das in Abbildung 7.2 dargestellte Bild (Multimodellmittel, MMM). Die Werte des Huglin-Index sind in Eignungsklassen eingeteilt (HUGLIN 1976), welche ebenfalls in der Abbildung gezeigt werden. Bei diesen Ergebnissen ist zu beachten, dass durch die Exposition der für den Rebanbau genutzten Hänge 1,5–2 °C höhere Temperaturen als an den entsprechenden Wetterstationen und damit auch höhere Temperatursummen vorliegen (HOPPMANN *et al.* 2010). Es ist also davon auszugehen, dass die tatsächlichen HI-Werte

⁶⁰ $k = 1,02$ für $\Phi \leq 40^\circ$, $k = 1,06$ für $\Phi \geq 50^\circ$ und $k = 1,02 + 0,04 \frac{\Phi - 40^\circ}{10^\circ}$

auf den Rebflächen die hier gezeigten Gitterzellenmittelwerte übersteigen. Die Berechnungen ergeben im Zeitraum 1971–2000 eine Anbaueignung (Müller-Thurgau, blauer Portugieser) in nur zwei der 47 Gitterzellen. Für 2011–2040 liegen die Werte höher, erreichen jedoch maximal die Klasse, in der sich Spätburgunder, Riesling und Silvaner befinden. 2041–2070 finden sich im Maindreieck verbreitet Gitterzellen mit thermischer Eignung für Cabernet franc und Blaufränkisch, um bzw. leicht südlich von Würzburg sowie am Nordwestrand Unterfrankens wird bereits die Klasse Cabernet Sauvignon / Chenin blanc / Merlot erreicht. Im letzten betrachteten Zeitraum 2071–2100 schließlich ist die Eignung für wärmeliebende Weinsorten von Cinsaut / Grenache / Syrah bis zu Carignan vorherrschend, im südlichen Maindreieck werden thermische Anbaubedingungen für Aramon projiziert. Die Werte von REMO liegen tendenziell unter dem MMM, die von ALADIN (v.a. Mitte und Ende des 21. Jahrhunderts) und RACMO darüber. Der lineare Trend des Multimodellmittels für das 21. Jahrhundert⁶¹ beträgt 886,7 pro 100 Jahre (entspricht 63,9 % mit 1971–2000 als Basis).

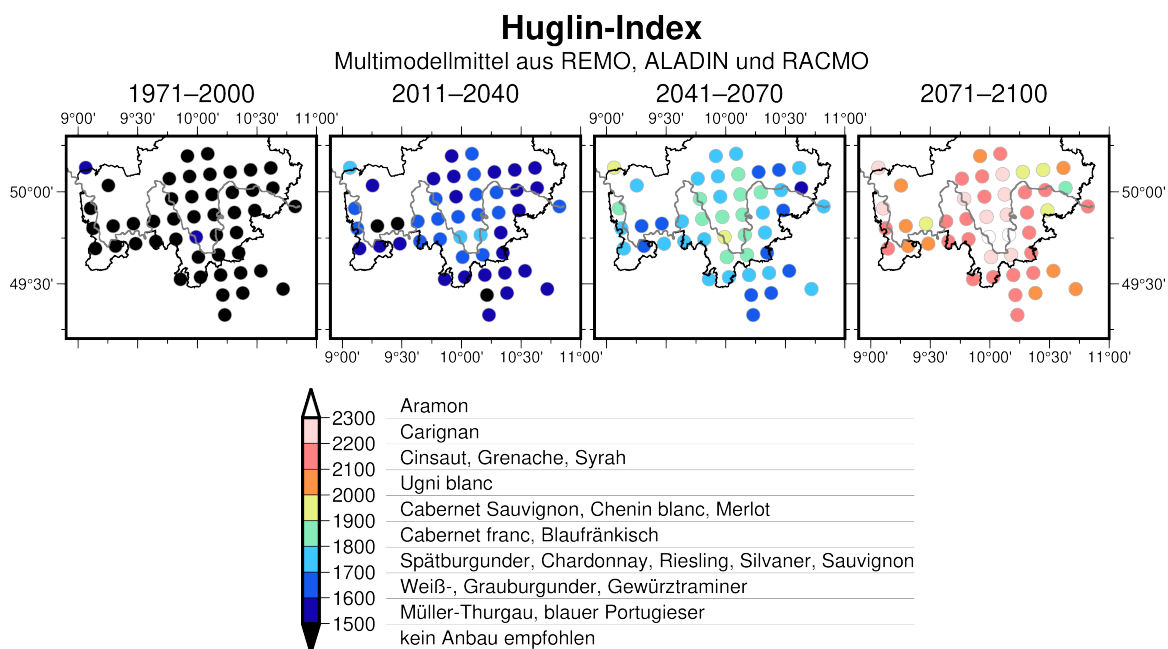


Abbildung 7.2: Huglin-Index 1971–2000, 2011–2040, 2041–2070 sowie 2071–2100 für die den fränkischen Weinbaugemeinden am nächsten liegenden Gitterpunkte. Multimodellmittel aus REMO, ALADIN und RACMO, biaskorrigiert mit QM11. Klassen nach HUGLIN (1976) mit Synonymen bzw. Übersetzungen der Rebsorten nach ZR (2022).

⁶¹2006–2100, 30-jährige gleitende Mittel

Zur tatsächlichen Rebsortenverteilung der letzten Jahre lässt sich Folgendes festhalten: In den Jahren 2015, 2020, 2021 (DESTATIS 1996, 2016, 2021, 2022) blieb der Anteil der mit Weiß- (81 bzw. 82 %) bzw. Rotwein (19 bzw. 18 %) bestockten Flächen an den Gesamtrebflächen etwa gleich. Die am stärksten verbreitetsten Weißweinsorten waren dabei Silvaner (29,0 | 30,5 | 30,5 %), Müller-Thurgau (33,3 | 28,1 | 28,8 %), Bacchus (14,7–14,9 %) sowie Riesling (6,7–6,8 %, jeweils an der Gesamtweißweinfläche). Alle übrigen Weißweinsorten machten jeweils unter 5 % der bestockten Weißweinfläche aus. Beim Rotwein waren die häufigsten Sorten (Rest jeweils unter 5 %) Domina (29,0 | 27,9 | 28,2 %), blauer Spätburgunder (22,6 | 25,2 | 24,8 %), Dornfelder (12,7 | 12,2 | 12,3 %), Regent (11,8 | 11,2 | 11,3 %), Schwarzriesling (6,7 | 6,1 | 6,1 %) sowie blauer Portugieser (5,1 | 4,2 | 4,4 %, jeweils der Gesamtrötweinfläche). Werden nun die Huglin-Index-Klassen (Abbildung 7.2) gemeinsam mit dieser Sortenaufzählung betrachtet, so lässt sich folgendes erkennen: Hinsichtlich der Weißweine befinden sich die bisher am meisten angebauten Sorten im Bereich 1500–1700 (für Bacchus als Kreuzung (Silvaner X Riesling) X Müller-Thurgau (ZR 2022) wird hier von einem HI-Wert im Bereich der drei Herkunftsorten ausgegangen). Für den Rotwein gestaltet sich dies etwas komplizierter: Dornfelder und Regent sind höhergradige Kreuzungen aus z.T. ebenfalls aus Kreuzungen hervorgegangenen Elternreben (ZR 2022), sodass eine Herleitung des typischen Huglin-Indexwertes nicht möglich ist. Domina stellt eine Kreuzung aus blauem Portugieser und blauem Spätburgunder dar, Schwarzriesling eine Mutation des blauen Spätburgunders (ZR 2022). Mit Ausnahme der somit nicht zuordenbaren Rebsorten Dornfelder und Regent, kann jedoch auch beim Rotwein von einem HI-Bereich zwischen 1500 und 1700 ausgegangen werden. Auch in den letzten Jahren wurden schon vereinzelt Rebsorten aus höheren Huglin-Klassen angebaut, jedoch mit sehr geringen Flächenanteilen (z.B. Cabernet Sauvignon (0,26 | 0,46 | 0,45 %), Merlot (0,87 | 0,99 | 1,00 %)). Diese werden – rein thermisch betrachtet – in Zukunft voraussichtlich eine bessere Eignung erfahren. In den letzten Jahrzehnten hat sich bereits ein deutlicher Wandel hin zu mehr Rotweinflächen, einem geringeren Müller-Thurgau-Anteil innerhalb der Weiß- sowie geringeren Spätburgunder- und höheren Dominaanteilen innerhalb der Rotweinsorten abgezeichnet⁶² (DESTATIS 1996, 2016, 2021, 2022).

⁶²1989/90 bzw. 1995: Weißwein 96 bzw. 94 % an Gesamtweinbauflächen. Müller-Thurgau 49,2 bzw. 47,1 %, Silvaner 29,4 bzw. 21,7 %, Bacchus 10,9 bzw. 11,3 %, Kerner 6,9 bzw. 6,8 % an Weißweinflächen. Spätburgunder 40,9 bzw. 40,4 %, Domina 16,7 bzw. 22,0 %, Schwarzriesling 18,3 bzw. 17,0 % sowie blauer Portugieser 18,7 bzw. 15,6 % an Rotweinflächen (DESTATIS 1996, Franken als Summe aus Mittel- und Unterfranken)

7.1.7 Forstwirtschaft

Die Kombination der langen Lebensdauer von Bäumen mit der hohen Geschwindigkeit des Klimawandels bedingt dessen hohe Relevanz für die Forstwirtschaft (BOLTE & DEGEN 2010). Hinsichtlich der Klimawandelauswirkungen auf die Forstwirtschaft bzw. das Baumwachstum gelten grundsätzlich die in Kapitel 7.1.1 getätigten Aussagen. Im Folgenden werden diese spezifiziert und ergänzt.

7.1.7.1 Direkte und indirekte Wirkung klimatischer Veränderungen

Wie bereits in Abschnitt 7.1.1 beschrieben, kann eine erhöhte atmosphärische CO₂-Konzentration zu einer höheren Photosyntheserate und besseren Wassernutzungseffizienz führen, was jedoch von der Wasser- und Nährstoffversorgung abhängig ist und durch temperaturbedingte Atmungsverstärkung ausgeglichen oder übertroffen werden kann (vgl. z.B. auch KALLARACKAL & ROBY 2012; BMU *et al.* 2008). Zusätzlich ist der positive CO₂-Düngeeffekt in jungen Bäumen stärker (KALLARACKAL & ROBY 2012) und mit der Zeit kann ein Gewöhnungseffekt der Photosyntheseleistung auftreten (KALLARACKAL & ROBY 2012; REYER *et al.* 2014; SPERLICH *et al.* 2020). Letzteres ist jedoch in Freilandstudien seltener zu beobachten als in Kammerexperimenten (KALLARACKAL & ROBY 2012). Die artenspezifisch unterschiedlich hohe Wirksamkeit der Kohlendioxiddüngung kann zudem zu Veränderungen in der Konkurrenzfähigkeit zwischen verschiedenen Baumarten (und auch anderen Pflanzenarten) führen und dadurch ökosystemare Auswirkungen mit sich bringen (KALLARACKAL & ROBY 2012).

Ähnlich wie beim Getreide (vgl. Abschnitte 7.1.4.1 und 7.1.4.2) projizieren Waldwachstumsmodelle für die Zukunft meist nur aufgrund des CO₂-Düngeeffektes positive Entwicklungen (siehe Abschnitt 7.1.7.2). Allerdings ist die Studienlage zu dessen Ausmaß unzureichend und er wird daher in vielen Modellen zu hoch angesetzt (KIRILENKO & SEDJO 2007; vgl. LINDNER *et al.* 2014). Einige Simulationen jedoch beachten die möglichen Gewöhnungseffekte (z.B. REYER *et al.* 2014).

Ein Anstieg der Temperatur kann bis zu einer bestimmten Höhe und bei gleichzeitiger ausreichender Nährstoff- und Wasserverfügbarkeit wachstumsfördernd wirken, ebenso wie die durch sie bedingte längere Vegetationsperiode (z.B. KAISER 1994; KERSEBAUM *et al.* 2009; KÖHL *et al.* 2017; vgl. Abschnitt 7.1.1). Ein früheres Einsetzen und längeres Andauern der Vegetationsperiode wurde an den bayerischen Waldklimastationen bereits festgestellt (DIETRICH *et al.*

2018). Dies kann je nach Temperaturbedingungen nach dem Blattaustrieb das Spätfrostrisiko erhöhen (KAISER 1994; KÖHL *et al.* 2017). Zudem bedeutet ein stärkeres Baumwachstum auch ein frühzeitiges Altern (KAISER 1994).

Demgegenüber führt Hitze insbesondere bei gleichzeitiger Trockenheit durch verschiedene Mechanismen zum Wachstumsrückgang und zur Schwächung der Pflanzen sowie zu einer Erhöhung der Waldbrandgefahr (z.B. BMELV 2008; BMU *et al.* 2008; KAISER 1994; KERSEBAUM *et al.* 2009; vgl. Abschnitt 7.1.1). Neben Dürren und Spätfrost wirken sich auch andere Extremereignisse wie Stürme negativ auf Waldwachstum bzw. -vitalität aus (KAISER 1994; KIRILENKO & SEDJO 2007). Allerdings basieren Waldwachstumsmodellierungen oft nur auf Durchschnittswerten von Temperatur und Niederschlag und beziehen weder Extrema noch indirekte klimatische Effekte (Schädlinge, Waldbrand etc.) ein (KIRILENKO & SEDJO 2007). In einer Umfrage unter Personen mit forstlicher Expertise in 23 europäischen Ländern zu den wichtigsten forstrelevanten Klimaveränderungen wurden neben Temperaturanstieg und Niederschlagsveränderungen v.a. Sommertrockenheit, häufigere Extrema und Sturm genannt. Es wird daher von Wachstumsrückgängen (in trockenheitsempfindlichen Regionen), einer längeren Vegetationsperiode sowie mehr Krankheiten und Schädlingen ausgegangen (SPATHELF *et al.* 2014).

Bezüglich letzter Erwartung ist die Studienlage ähnlich derer zu Pflanzen allgemein (Abschnitt 7.1.1). Hinsichtlich pathogener Pilze werden höhere Schädigungen insbesondere aufgrund höherer Vulnerabilität der Bäume erwartet (IMMLER & BLASCKE 2007). Diese kann z.B. durch Sturm- oder Trockenschäden bedingt sein (IMMLER & BLASCKE 2007; KERSEBAUM *et al.* 2009; KÖHL *et al.* 2017) und bezieht sich auch auf die Anfälligkeit gegenüber Schadinsekten. Diese profitieren hinsichtlich ihrer Aktivität und Reproduktion von erhöhten Temperaturen (BMU *et al.* 2008; BEZNER KERR *et al.* 2022; IMMLER & BLASCKE 2007; KERSEBAUM *et al.* 2009). So wird beispielsweise im Bezug auf Borkenkäfer (früher und höhere Wahrscheinlichkeit für dritte Generation) und Eichenprozessionsspinner (Bevorzugung warmes und trockenes Klima) von einer stärkeren Schadwirkung ausgegangen (BMU *et al.* 2008; IMMLER & BLASCKE 2007). Gleichzeitig zeigen Projektionen zum Nonnenfalter im Großteil des *Unterfranken+*-Gebietes in den letzten Jahrzehnten Bedingungen für Massenausbrüche (1981–2010, Ausnahme Oberrheingraben und Mittelgebirge wegen Über- bzw. Unterschreiten der Optimaltemperaturbedingungen), während der Temperaturanstieg bis Mitte des 21. Jahrhunderts (2031–2060) zwar ein Vorkommen der Schädlinge in Großteilen des Gebietes (im Oberrheingraben dann zu heiß), Massenvorkommen jedoch nur noch im Norden und Osten (Mittelgebirge) bedingt

(LASCH-BORN *et al.* 2015). Durch veränderte klimatische Bedingungen und die Verbreitung neuer Pflanzenarten (s.u. bzgl. Waldumbau) wird auch mit Veränderungen der Artenzusammensetzung von Schaderregern (Insekten wie auch Pilze) gerechnet (BEZNER KERR *et al.* 2022; IMMLER & BLASCKE 2007; KERSEBAUM *et al.* 2009; KIRILENKO & SEDJO 2007).

Besonders vulnerabel bzgl. klimatischer Veränderungen, Extrema und Schädlinge sind Bäume, deren Standorte nicht den für die Baumart natürlichen Standortbedingungen entsprechen (BMU *et al.* 2008; KAISER 1994; SCHULDT *et al.* 2020). Dies betrifft im betrachteten Gebiet momentan insbesondere Fichten (BMU *et al.* 2008; SCHULDT *et al.* 2020), wie weiter unten noch näher beschrieben wird.

7.1.7.2 Modellierung der Forsterträge

Simulationen des Waldwachstums in Deutschland bis zur Mitte des 21. Jahrhunderts zeigen ohne Einbezug des CO₂-Düngeeffektes für das Gebiet *Unterfranken+* Stagnationen bis leichte Zunahmen, hinsichtlich Buchen z.T. leichte Abnahmen. Wird die Kohlendioxidwirkung einbezogen, so ergeben sich stärkere, ausschließlich positive Veränderungen (für ganz Deutschland). Zudem steht (*Unterfranken+* außer kleiner Bereich im Nordwesten) einer Abnahme der Perkolationsrate eine Zunahme der Waldbrandgefahr gegenüber (LASCH-BORN *et al.* 2015). Für Buchen und Tannen im Schwarzwald wird bis Mitte des 21. Jahrhunderts eine Zunahme, danach eine Abnahme der Nettoprimärproduktion simuliert (drei RCP-Szenarien, ohne CO₂-Düngung nur Abnahme), im stärksten Szenario (RCP8.5 wie in dieser Arbeit) überwiegt über das gesamte Jahrhundert die Zunahme. Die Rückgänge sind v.a. trockenheitsbedingt, wobei in den ersten Jahrzehnten „die verbesserte Wassernutzungseffizienz die Trockenheitseffekte auf die Nettoprimärproduktion abschwächt“ (SPERLICH *et al.* 2020). Hierbei profitieren Tannen stärker von erhöhten CO₂-Konzentrationen und reagieren weniger empfindlich auf Trockenheit als Buchen (SPERLICH *et al.* 2020). Auch in der Arbeit von ALBERT *et al.* (2018) zur Simulierung von Kiefer-, Buchen- und Eichenwachstum in zwei Regionen des Norddeutschen Tieflandes wird ein zunächst positiver Effekt (hier durch Temperaturanstieg) im Laufe des 21. Jahrhunderts umgekehrt (durch Trockenheit).

Mögliche Gewöhnungseffekte im Bezug auf die Kohlendioxiddüngung werden in der Waldwachstumsmodellierung von REYER *et al.* (2014) für 132 Standorte in zehn europäischen Umweltzonen untersucht. Fichte, Kiefer, Buche und Eiche werden betrachtet, wobei für die

kontinentale Region (beinhaltet *Unterfranken+*, Betrachtung Kombination aus mehreren RCM-Modellen, Szenarien und drei 30-Jahres-Zeitscheiben im 21. Jahrhundert verglichen mit 1971–2000) mit Einbezug der Gewöhnung im Median kaum Veränderung, ohne Einbezug der Gewöhnung positive Entwicklungen projiziert werden. Die zentraleuropäisch gelegenen Fichtenstandorte zeigen meist Wachstumsabnahmen.

Bis auf wenige Trockenstandorte sind die Auswirkungen des Klimawandels auf die Holzproduktion in Deutschland (prozessbasiertes Waldwachstumsmodell, 5 RCM-Modelle, 3 Szenarien) meist positiv, gleichzeitig besitzen Unterschiede im Waldmanagement einen größeren Einfluss als das Klima (GUTSCH *et al.* 2018).

In diesen Modellierungen werden Störungen und indirekte Effekte (sowie z.T. Extremereignisse) nicht explizit einbezogen. REYER *et al.* (2017) betrachten auch die Veränderungen und damit einhergehenden Auswirkungen von Feuer, Sturm und Insekten auf das Waldwachstum (sieben Fallstudien in Europa mit verschiedenen Prozessmodellen und Extrapolationen). Die Ergebnisse zeigen meist negative Folgen von Störungen bezüglich der Forstproduktivität, wobei beispielsweise Feuer je nach Stärke auch einen Düngeffekt oder eine positive Ausdünnung bedingen können.

Bei den genannten Studienergebnissen ist jedoch zu beachten, dass eine Wachstumssteigerung nicht uneingeschränkt mit einer Produktivitätszunahme gleichzusetzen ist. So zeigen etwa Langzeitstudien in Süddeutschland (Kiefer, Fichte, Buche, Eiche; viele Standorte auch im Gebiet *Unterfranken+*) seit 1900 Wachstumssteigerungen hinsichtlich des Volumens, jedoch Abnahmen im Bezug auf die Holzdichte. Diese impliziert eine geringere Widerstandskraft und Kohlenstoffspeicherung der Bäume (PRETZSCH *et al.* 2018).

7.1.7.3 Dürresommer 2018

Im Bezug auf – zukünftig mitunter häufiger auftretende – extrem trockene Klimabedingungen sind die Dürresommer 2003 und 2018 wichtige Anhaltspunkte. Das Dürreereignis 2018 war sowohl klimatisch als auch bezüglich der forstlichen Auswirkungen stärker als das im Jahr 2003 (BURAS *et al.* 2020; SCHULDT *et al.* 2020). In den gemäßigten Wäldern der DACH-Region (Deutschland, Österreich, Schweiz) traten starke Auswirkungen auf – sichtbar v.a. durch Blattfärbung und frühen Laufwurf – sowie eine „noch nie dagewesene dürrebedingte Baumsterblichkeit vieler Baumarten“ (SCHULDT *et al.* 2020). Auf Basis von Satellitendaten stellen auch

BRUN *et al.* (2020) für 2018 verfrühtes Welken (auch Welken von Nadelbäumen) sowie verfrühten Blattwurf in Mitteleuropa fest. Auch im *Unterfranken+*-Gebiet war verfrühtes Welken weit verbreitet.

In Spessart, Haßbergen und Fichtelgebirge (niedrige Höhenlagen) führten die heißen Dürren 2018 und 2019 zu einer hohen Buchen- und Fichtensterblichkeit. Die Analysen langjähriger Baumring- und Klimadaten zeigen einen hohen Zusammenhang zwischen Wachstum und Trockenheit im April–Juni (Buche) bzw. Juni–August (Kiefer). Auch Schädlinge (großer Borkenkäferinfluss auf Fichten in Spessart und Haßbergen 2018) und Standortbedingungen (z.B. Tongehalt) können die Sterblichkeit beeinflussen (OBLADEN *et al.* 2021).

Die Auswirkungen der Dürre 2018 führten nachweislich auch im Folgejahr noch zu einer Schwächung der Bäume (BRUN *et al.* 2020; SCHULDT *et al.* 2020) und es wird von einer längerfristigen Beeinflussung ausgegangen (BURAS *et al.* 2020).

Auch wenn diese Beobachtungen kein Sterben, sondern nur einen Wandel der Wälder bedeutet, zeigt sich zum Einen eine höhere Vulnerabilität als erwartet und zum Anderen eine größere Beeinträchtigung bei standortfremden Arten wie der Fichte (SCHULDT *et al.* 2020).

7.1.7.4 Forstliche Anpassung an den Klimawandel

Dies führt zur Frage nach der forstlichen Anpassung an den Klimawandel. Die eben genannte Vulnerabilität bzw. Sensitivität deutet darauf hin, dass die Resilienz der momentanen Wälder bzw. der dort wachsenden Baumarten unzureichend für die erwarteten klimatischen Veränderungen ist bzw. sein könnte (BMELV 2008; BMU *et al.* 2008; BRANG *et al.* 2008). Die Schädigung der Wälder etwa durch Luftschadstoffe mit einhergehender Versauerung der Böden (insbesondere in der Zeit nach dem zweiten Weltkrieg vor der gesetzlichen Eindämmung) trägt hierzu bei (KAISER 1994). Hinzukommt die hohe Geschwindigkeit der klimatischen Veränderungen, die eine selbstständige Anpassung der Wälder verhindert (GRASSL 2007; KÖHL *et al.* 2017), zumindest insofern, als dass sie eine weitere ökonomische Nutzung der Wälder, der Forste, ermöglichen würde (BOLTE & DEGEN 2010; BRANG *et al.* 2008).

Hinsichtlich der möglichen Anpassungsmaßnahmen werden – ähnlich wie bei den Feldfrüchten, allerdings aufgrund der deutlich längeren Umtriebszeiten verstärkt – unterschiedliche Zeitskalen relevant (BRANG *et al.* 2008). Langfristig notwendig ist ein Waldumbau hin zu Baumbeständen mit guter Anpassung an (zukünftige) Klima- und allgemein Standortbedingungen (BMELV

2008; BOLTE & DEGEN 2010; BRANG *et al.* 2008; BROSINGER & TRETTER 2007; IPCC 2022b; KÖLLING *et al.* 2005; KIRILENKO & SEDJO 2007; LINDNER *et al.* 2014; SCHULZ & KÖLLING 2007; SPATHELF *et al.* 2014; STMELF 2020).

Dies kann mehrere Implikationen haben. Zum Einen der verstärkte Einsatz bzw. die Unterstützung natürlich vorkommender Arten (Orientierung an potenziell natürlicher Vegetation) (BMU *et al.* 2008; BROSINGER & TRETTER 2007) und zum Anderen der Wechsel zu neuen (nicht-heimischen) Arten mit z.B. höherer Trockenheitstoleranz. Die Leitlinien der Bayerischen Forstverwaltung (STMELF 2020, wörtliche Übernahme) sehen hierbei folgende Priorisierung vor:

1. Verschiebung des Vorkommens heimischer Baumarten innerhalb Bayerns (Assisted Population Migration)
2. Stärkung seltener heimischer Baumarten
3. Alternative Herkünfte heimischer Baumarten (aus anderen Regionen Europas)
4. Alternative Baumarten – wissenschaftliche Einteilung in 4 Eignungskategorien

Bei letzter erfolgt die Klassifizierung ebenfalls in Abhängigkeit von der Herkunft, wobei Bäume betrachtet werden, deren „natürliches Verbreitungsgebiet vor Beginn der Neuzeit (= Entdeckung Amerikas) nicht in Deutschland“ lag (STMELF 2020). Auch die Fürstlich Castell'sche Forstverwaltung – KMU-Partner im Projekt *BigData@Geo* – setzt zunächst auf den Einsatz heimischer Arten mit hoher klimatischer Eignung einschließlich seltenerer Arten wie z.B. Obstbäume, sucht aber parallel dazu bereits nach Baumarten anderer Regionen, die eine gute Anpassung an die zukünftigen klimatischen Bedingungen aufweisen (REISSENWEBER & POHL 2019, 2021). Aufgrund der Komplexität im Bezug auf Eignung und mögliche (z.B. ökologische) Folgen ist heimischen Arten stets der Vorzug zu geben (KÖLLING *et al.* 2005).

Die mitteleuropäische Forstwirtschaft ist von Nadelbäumen geprägt, was der natürlichen Vegetation ebenso wie den in Zukunft erwarteten klimatischen Bedingungen mit höheren Temperaturen und geringerer Wasserverfügbarkeit widerspricht (KÖLLING *et al.* 2005). In Unterfranken sind zwar Buche (26 %) und Eiche (22 %) die häufigsten Baumarten, die starke Verbreitung von Fichte (17 %) und Kiefer (13 %) (LWF 2012) entspricht jedoch nicht der potenziellen natürlichen Vegetation (MÜLLER 1996). Die Verbreitungsdaten der wichtigsten europäischen Baumarten von CAUDULLO *et al.* (2017) liefern Informationen über die Standortanpassung der jeweiligen Arten: Während Rotbuche, Eiche (Stiel-, Trauben-) und auch Waldkiefer (Ausnahme Teile des Bereiches 8,0–8,5° O, 49,5–50,75° N) im gesamten Untersuchungsgebiet ihre

natürliche Verbreitung finden, kommt die Fichte nur im Gebiet des Thüringisch-Fränkischen Mittelgebirges (Fichtelgebirge eingeschlossen) sowie in Teilen der Frankenhöhe natürlich vor, ist jedoch heute im gesamten Gebiet *Unterfranken+* zu finden (Abbildung 7.3). Daher stellt sich die Frage, welche Ansprüche und Eigenschaften die häufigsten Baumarten Unterfrankens besitzen.

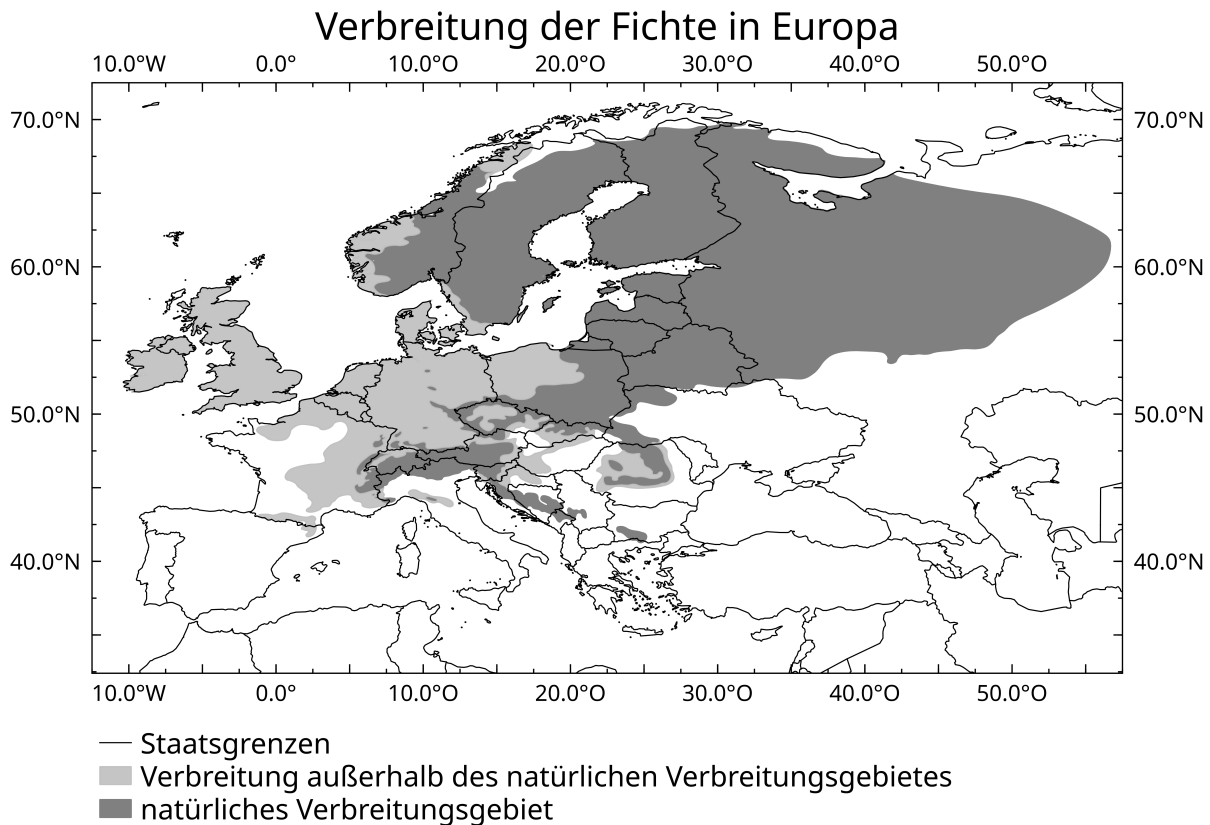


Abbildung 7.3: Verbreitung der Fichte im Untersuchungsgebiet. Eigene Darstellung, Daten

CAUDULLO et al. (2017), Staatsgrenzen EUROSTAT (2020).

Buche Bezüglich der potenziellen natürlichen Vegetation stellt die Buche die Hauptbaumart Unterfrankens dar (MÜLLER 1996). Sie besitzt eine mäßige Sommertemperaturtoleranz (17–19 °C Mitteltemperaturen Juni–August) (STMELF 2020) und bevorzugt Jahresniederschlagssummen von mindestens 600 mm (KAISER 1994). Damit ist sie allgemein, und besonders im Bezug auf weite Teile des Untersuchungsgebietes, trockenheitsgefährdet (BMU et al. 2008; GESSLER et al. 2007; METTE et al. 2013; REISSENWEBER & POHL 2019, 2021; ZIMMERMANN et al. 2015), besitzt jedoch auch eine hohe Empfindlichkeit gegenüber Staunässe (GESSLER et al. 2007; METTE et al. 2013; REISSENWEBER & POHL 2019, 2021). Je nach Region, v.a. in höheren Lagen, kann eine Erhöhung der Temperatur zuträglich sein (BMU et al. 2008),

ein Beispiel außerhalb des Untersuchungsgebietes ist die in den letzten 50 Jahren beobachtete Eignungszunahme der Buche in den Karpathen mit erhöhter Produktionsleistung und Ausbreitung in submontanen bis montanen Gebieten (KULLA *et al.* 2023). KÖLLING *et al.* (2005) relativieren die häufig genannte Abnahme der zukünftigen Konkurrenzfähigkeit durch trockenere Bedingungen. Den Beobachtungen zufolge zeigen Buchen im Vergleich zu anderen Baumarten die höchste Regenerationsfähigkeit nach extremen Trockenereignissen, die Schadsymptome sind also nur temporärer Natur. Bei Manifestierung von trockenen Bedingungen besitzen Pflanzen zudem interne Anpassungsmaßnahmen (z.B. „durch Veränderung von Gestaltmerkmalen“ (KÖLLING *et al.* 2005)). In den letzten Jahrzehnten ist eine natürliche Ausweitung des Buchenbewuchses in als eher ungeeignet erachtete Gebiete registriert worden. Die Autoren schließen daher, dass Wasserversorgungsprobleme der Buche v.a. am Rand des heutigen natürlichen Auftretens und dort relevant werden, wo sie durch schlechte Bodeneigenschaften bedingt sind. Auch GESSLER *et al.* (2007) gehen davon aus, dass die Trockenheitsproblematik v.a. Standorte mit „geringmächtigen Böden mit geringer Wasserspeicherkapazität“ betreffen wird. Nichtsdestotrotz konnte in weiten Teilen Europas in den letzten Jahren eine Verringerung der Buchenwachstumsraten beobachtet werden und zukünftige Simulationen (statistisch, realistisches Szenario, Temperatur in Zukunft limitierender Faktor) zeigen eine Fortsetzung dieser Trends mit Ausnahme höherer Lagen (MARTINEZ DEL CASTILLO *et al.* 2022). Diese Ergebnisse sind von der Konstruktion der statistischen Modelle und den für die Erstellung der Transferfunktionen genutzten Daten abhängig. Auch innerhalb verschiedener Buchenherkünfte (Ökotypen) Deutschlands existieren Unterschiede hinsichtlich der Trockenheitsanfälligkeit (PEUKE *et al.* 2002).

Eiche Eine höhere Staunässe- und auch Trockenheitstoleranz besitzt die Eiche, weshalb von einer steigenden Konkurrenzfähigkeit gegenüber der Buche und Fichte (s.u.) bei abnehmender Wasserverfügbarkeit ausgegangen wird (KAISER 1994; GESSLER *et al.* 2007; HANEWINKEL *et al.* 2012). Auch die Sommertemperaturtoleranz (Stiel- und Traubeneiche) ist mit 19–21 °C höher als die der Buche (STMELF 2020). Im Klima der mittleren Wärmezeit (ca. 6000 BP), das thermisch mit den Erwartungen zum Ende des 21. Jahrhunderts vergleichbar ist, waren Eichenmischwälder vorherrschend (KAISER 1994).

Fichte Die Fichte wird mit klimatischen Verbreitungsgrenzen von 7 °C Jahresmitteltemperatur (obere Grenze) und 800 mm Jahresniederschlagssumme (untere Grenze) (KAISER 1994)

schon heute deutlich außerhalb ihrer natürlichen Standortbedingungen angebaut (vgl. Abbildung 7.3), die sommerliche Temperaturtoleranz liegt bei unter 17 °C durchschnittlicher Juni–August-Temperaturen (STMELF 2020). Ihre schlechte klimatische Anpassung wird sich im Zuge des Klimawandels noch weiter verstärken, weshalb der heute großflächig betriebene Fichtenanbau keine Zukunftsfähigkeit besitzt (BMU *et al.* 2008; DIETRICH *et al.* 2018; MÖGES 2007; UMBW 2016). Dies wird auch durch Simulationen auf Basis verschiedener Modelle und Szenarien bestätigt (HANEWINKEL *et al.* 2012). Die für die Fichte besonders schädigenden Borkenkäferausbrüche sind bei trockenheitsbedingt geschwächten Bäumen besonders ausgeprägt, weswegen auch hier in Zukunft mit Häufigkeitszunahmen gerechnet wird (DIETRICH *et al.* 2018).

Kiefer Trotz der natürlichen Dominanz der Laubbäume im Untersuchungsgebiet, befindet sich hier ebenfalls das natürliche Verbreitungsgebiet der Kiefer. Sie „besitzt die größte ökologische Amplitude unter heimischen Wirtschaftsbaumarten“ (KAISER 1994), gedeiht also in einem weiten Bereich an Standortbedingungen (Klima, Boden etc.). Dennoch ist ihre sommerliche Temperaturtoleranz nur mäßig (17–19 °C) und geringer als die der Buche (STMELF 2020). Insbesondere in Monokulturen besteht bei Trockenheit – wie auch bei der Fichte – ein hohes Waldbrandrisiko (BMU *et al.* 2008; KAISER 1994).

Vergleich der häufigsten Baumarten sowie Zukunftsprojektionen Hinsichtlich der Trockenheitsempfindlichkeit der vier häufigsten Baumarten in Unterfranken lässt sich eine Abnahme in folgender Reihenfolge festhalten: Fichte, Buche, Eiche, Kiefer (ALBERT *et al.* 2018; DIETRICH *et al.* 2018; HANEWINKEL *et al.* 2012; METTE *et al.* 2013; ZIMMERMANN *et al.* 2015). Demgegenüber ist die Kiefer anfällig gegenüber Veränderungen der Wintertemperaturen (STOLZ *et al.* 2021).

Für die Zukunft wird von einer verstärkten Verbreitung von Eichen(misch)wäldern, einer Verlagerung von Buchen in höhere Lagen sowie einem generellen Rückgang der Fichtenwälder (aber auch Kiefernwälder) ausgegangen (KAISER 1994; KÖHL *et al.* 2017). Auch die Weißtanne (natürliche Verbreitung nicht im östlichen *Unterfranken*+ -Gebiet (CAUDULLO *et al.* 2017)) benötigt kühlere und feuchtere Bedingungen als für die Zukunft erwartet und wird daher voraussichtlich nur in Hochlagen von Rhön und Thüringisch-Fränkischem Mittelgebirge weiter bestehen können (KÖLLING *et al.* 2011).

Für das Gebiet *Unterfranken+* zeigen Modellierungen hinsichtlich der heutigen klimatischen Bedingungen (32 mögliche Baumarten in Betracht gezogen) v.a. die potenzielle Verbreitung von Buchen, im zentralen Gebiet zudem von Eichen (heimische, östlicher) und Kiefern (westlicher) sowie in höheren Lagen von Fichten. Zum Ende des 21. Jahrhunderts (mittleres Szenario) sind Fichten und Kiefern nicht mehr zu finden, Buchen kommen v.a. in feuchteren, höheren Lagen vor, wohingegen Eichen (mediterrane Arten im Westen, heimische im Osten) dominieren (HANEWINKEL *et al.* 2012).

Waldwachstumsmodelle an einem unterfränkischen Trockenstandort simulieren den klimatischen Kippunkt von Buchen- hin zu Eichendominanz bei einer Jahresdurchschnittstemperatur von 11–12 °C (Juli über 18 °C) sowie Jahresniederschlägen zwischen 500 und 530 mm. Auch wenn die Buche also heute noch keine Trockenheitslimitierung erfährt, wird sie in Zukunft (mittleres Klimaszenario) von einem deutlichen Rückgang betroffen sein und an Konkurrenzfähigkeit gegenüber der Eiche verlieren (METTE *et al.* 2013).

Klimahüllen Um Anhaltspunkte für die klimatische Eignung einer Baumart zu erhalten, können so genannte Klimahüllen hilfreich sein. Diese basieren auf den klimatischen Durchschnittsbedingungen (Jahresmitteltemperatur, Jahresniederschlagssumme), unter denen eine bestimmte Baumart auftritt (KÖLLING 2007a). Die so definierte ökologische Nische kann dann mit den jeweiligen vorherrschenden oder projizierten Werten verglichen werden. Für ganz Deutschland (Waldfläche) befindet sich das gegenwärtige Klima komplett innerhalb der Klimahülle der Buche. In Zukunft (mildes Szenario) wird ein kleiner Teil der Waldflächen trockener und heißer sein als es den natürlichen Buchenbedingungen entspricht. Für die Stiel- und die Traubeneiche ist es momentan teilweise zu feucht und/oder zu kühl, in Zukunft wird das Klima fast komplett (dann in sehr geringem Anteil zu trocken/warm) innerhalb der Klimahülle dieser Baumarten liegen. Für die Waldkiefer und insbesondere die Fichte ist es schon heute häufig zu warm (z.T. auch zu feucht), was sich in Zukunft noch verstärkt (KÖLLING 2007b). Diese Aussagen dienen nur als Anhaltspunkte, da weder Extrema noch andere als klimatische Standortbedingungen miteinbezogen werden (vgl. BROSINGER & TRETTER 2007; HANEWINKEL *et al.* 2012). Zudem ist das genutzte Zukunftsszenario als zu schwach einzustufen (KÖLLING 2007b).

Andere heimische Arten Die bisherigen Erläuterungen beziehen sich auf die bislang häufigsten Baumarten und somit auf die erste Maßnahme zum klimawandelangepassten Waldum-

bau der Bayerischen Forstverwaltung („Verschiebung des Vorkommens heimischer Baumarten“ (STMELF 2020)). Hinsichtlich der seltenen heimischen Baumarten (zweite Maßnahme) besitzen etwa Flaumeiche, Feldulme, Schwarz- und Silberpappel sowie Speierling eine sehr hohe (>21 °C), Edelkastanie (laut dieser Quelle (STMELF 2020) seltene heimische Art, natürliches Verbreitungsgebiet aber in Südeuropa (CAUDULLO *et al.* 2017)), Elsbeere, Feldahorn, Flatterulme, Hainbuche, Sommer- und Winterlinde sowie (Wild-)Obst- und Nussbaumarten eine hohe (19–21 °C) Sommertemperaturtoleranz (STMELF 2020).

Die Suche nach klimatisch besser geeigneten nicht-heimischen Arten oder Herkünften heimischer Arten (Maßnahmen drei und vier der Bayerischen Forstverwaltung (STMELF 2020)) wird durch die Geschwindigkeit des Klimawandels erschwert, die langfristige Anbauexperimente verhindert (FALK *et al.* 2019).

Analogklimate Daher ist das Konzept der Klimaanalogregionen (Analogklimate) hilfreich. Hierfür werden solche Regionen gesucht, in denen das heutige Klima den Zukunftsprojektionen des Klimas im Gebiet, für das die Baumarten gesucht werden, entspricht. Eine Masterarbeit (REISSENWEBER & POHL 2019, 2021; ZIEGLER *et al.* 2021), die in derselben Arbeitsgruppe wie diese Dissertation entstand, beschäftigte sich beispielsweise mit Analoggebieten des Steigerwaldes am Ende des 21. Jahrhunderts, um die Suche nach alternativen Baumarten für die dort gelegenen Bestände der Fürstlich Castell'schen Forstverwaltung (KMU-Partner im Projekt *BigData@Geo*) zu unterstützen. Hierbei resultierten Colmar im Elsass sowie das Rhônetal als mögliche klimatische Herkünfte. Hierbei ist zu beachten, dass die Analyse (wie der Großteil der Ausführungen in diesem Kapitel) ausschließlich auf klimatischen Bedingungen beruht, sonstige Standortfaktoren wie etwa der Boden jedoch außer Acht gelassen werden (REISSENWEBER & POHL 2019, 2021), was die Standortvoraussetzungen der jeweiligen Baumarten nicht ausreichend abgrenzt (KAISER 1994), aber dennoch als Orientierung dienen kann.

Nicht-heimische Arten und Herkünfte Bei heimischen wie auch nicht-heimischen Baumarten sollte stets die Herkunft hinsichtlich ihrer klimatischen (und nicht-klimatischen) Begebenheiten beachtet werden (BROSINGER & TRETTER 2007; KONNERT 2007; PASSEL *et al.* 2017). Denn wie schon hinsichtlich der Buche genannt, ist die klimatische Anpassung eines Baumes nicht nur von der Art, sondern auch von seiner Herkunft abhängig. Unterschiede sind hierbei natürlicherweise nicht von Staatsgrenzen abhängig, sodass auch innerhalb Deutschlands

verschiedene klimatische Nischen von einer Baumart besetzt werden (vgl. PEUKE *et al.* 2002). Allerdings beschränken sich Herkunftsunterschiede nicht nur auf die Angepasstheit im Bezug auf Mitteltemperaturen und -niederschlag, sodass andere Aspekte wie z.B. Lichtbedarf (sowohl hinsichtlich Beschattung als auch bzgl. der Tageslänge) nicht außer Acht gelassen werden sollten (KONNERT 2007).

Wurden durch Analysen anhand von Analogklimaten, Klimahüllen o.ä. potenziell geeignete Baumarten gefunden, sollten stets weitere Faktoren Beachtung finden. Dies sind zum Einen andere klimatische Eigenschaften wie etwa die Variabilität, zum Anderen die Boden- und sonstigen Bedingungen vor Ort, aber auch mögliche ökologische Konsequenzen des Einbringens neuer Baumarten (HANEWINKEL *et al.* 2012; KÖLLING *et al.* 2005; SCHULDT *et al.* 2020). Daher ist es sinnvoll, sich auf Baumarten und -herkünfte zu stützen, zu denen aufgrund genügender Erprobung Anbauempfehlungen vorliegen. Die Bayerische Forstverwaltung spricht hierbei etwa für Schwarzkiefer, Douglasie, Robinie und Roteiche uneingeschränkte Anbauempfehlungen aus (STMELF 2020). Allgemein wird u.a. aus ökologischen Gründen ein Fokus auf „nahe Verwandte zu heimischen Arten und Baumarten aus dem europäisch-asiatischen Kontaktbereich“ nahegelegt (STMELF 2020).

Die in den vergangenen Jahren erfolgreich angepflanzte Douglasie wird in Zukunft außer an heute kühlen Standorten voraussichtlich eine Abnahme ihrer Anbaueignung erfahren, wohingegen das Anbaurisiko von Robinie, Schwarzkiefer, Rot-, Flaum- und insbesondere Zerreiche sowie Edelkastanie sinken wird (FALK *et al.* 2019). Auch die Modellierungen von THURM *et al.* (2018) zeigen ein großes Potential für Rot-, Zerreiche und Robinie, am stärksten aber von Flatterulmen. Bei der statistischen Simulation der Trockenheitsresistenz verschiedener Nadelbäume zeigt sich eine Abnahme von Douglasie über Waldkiefer und Europäischer Lärche zu Weißtanne und der empfindlichsten Baumart Fichte (THURM *et al.* 2020).

Die Klimahüllenbetrachtung für 2071–2100 (kein Szenario für Projektion angegeben) zeigt eine 100 %-ige Übereinstimmung mit den bayerischen Waldflächen für Douglasien (Küstenherkunft), Bergahorn und Rotbuche. Auch für Esskastanie, Traubeneiche, Sommerlinde, Esche, Flaum-, Stieleiche und Spitzahorn liegt sie bei über 90 %. Während sich der geeignete Flächenanteil für die Douglasie (Küstenherkunft) im Vergleich zu 1950–2000 nicht ändert, bedeuten diese Werte für die anderen genannten Arten Eignungszuwächse, am stärksten für die Flaumeiche (54 % auf 93 %). Die Bedingungen entfernen sich von den Klimahüllen von Weißtanne

(100 % auf 82 %), Waldkiefer, Europäischer Lärche (von 63 bzw. 76 % auf 25 %) und Fichte (83 % auf 17 %) (KÖLLING 2007a).

Bei allen vorangegangenen Aussagen ist Folgendes zu beachten. Zum Einen sollten nichtheimische Arten und Herkünfte stets nur als Beimischung zu heimischen Bäumen angebaut werden (KÖLLING *et al.* 2005). Zum Anderen bedeutet eine bessere klimatische Anpassung nicht unbedingt höhere Erträge. Die zukünftig voraussichtlich stärker verbreiteten Arten zeigen in den Simulationen von THURM *et al.* (2018) geringere Wuchsleistungen. Zudem impliziert die Verbreitung der mediterranen Eichenwälder in den Modellierungen von HANEWINKEL *et al.* (2012) deutliche finanzielle Einbußen, da diese einen geringeren ökonomischen Wert als die heute angesiedelten Bäume besitzen. Resilienz und Wachstum sind mitunter Gegenspieler, so dass Bäume mit höheren Erträgen oftmals anfälliger gegenüber beispielsweise Trockenheit oder Schädlingen sind (FALK *et al.* 2019; KÖLLING *et al.* 2005). Dies wird heute bereits an der Fichte mit hoher Wuchsleistung, aber auch hoher Vulnerabilität sichtbar.

Diversität Zusätzlich zur Standorteignung der individuellen Baumarten und -herkünfte wird eine höhere Resilienz durch Diversität erreicht. Dies bezieht sich einerseits auf eine Vielfalt der Baumarten und Herkünfte (genetische Vielfalt) und andererseits auf die Altersstruktur des Forstes (BMELV 2008; BRANG *et al.* 2008; BROSINGER & TRETTER 2007; GESSLER *et al.* 2007; SCHULDT *et al.* 2020; SCHULZ & KÖLLING 2007; STMELF 2020).

Weitere Anpassungsmaßnahmen Auch die Bewirtschaftung kann zur Anpassung an den Klimawandel beitragen, etwa durch Boden- und Wassermanagement oder die Anpassung der Nutzungsintensität und Umtriebsdauer (BMELV 2008; BRANG *et al.* 2008; SCHULZ & KÖLLING 2007; SPATHELF *et al.* 2014). Hinzu kommen Maßnahmen zum Schutz vor Wild, Schädlingen und Feuer sowie forstliches Monitoring (BMELV 2008; BRANG *et al.* 2008; IPCC 2022b; SCHULZ & KÖLLING 2007).

7.2 Zusammenfassender Ergebnisüberblick

7.2.1 Modellvalidierung REMO

Zunächst wird die Güte der REMO-Werte im Hinblick auf Beobachtungsdaten untersucht. Ganz allgemein sind die Bedingungen hinsichtlich der betrachteten Extremindizes zu feucht (R1mmn, MCD, DMI, R95n). Es werden zu wenig Spätfrost-, Frost- und Hitzetage, jedoch zu viele Eistage simuliert. Im Vergleich zu tieferen Lagen bzw. Raumdurchschnitt treten in höheren Lagen oft gegensätzliche Fehler auf, wobei die Raumunterschiede für DMI und R95n am stärksten sind. Die Schwankungen von R1mmn, MCD und Spätfrost sowie R95n und DMI in höheren Lagen werden zu niedrig, diejenigen der Eistagehäufigkeit sowie R95n und DMI in niedrigeren Lagen zu hoch modelliert. Die Hitzehäufigkeit zeigt raum-zeitliche Unterschiede der prozentualen Standardabweichungsfehler, für die Frosthäufigkeit sind sie in den Übergangsmontaten negativ, sonst positiv. Hinsichtlich der Verteilungsübereinstimmung von REMO mit den Beobachtungsdaten finden sich für R1mmn gefolgt von MCD und DMI die besten Ergebnisse. Für die Frosthäufigkeit (außer November–April) und die übrigen betrachteten monatlichen Kennwerte liegt der pQRMSE im Gesamtjahr und allen Einzelmonaten nahe oder über 100 %, für beide Spätfrostindizes bei 82 %. Allgemein ergibt sich häufig eine schlechtere Modellgüte in niedrigeren als in höheren Höhenlagen.

7.2.2 Biaskorrektur

Die eben vorgestellten Modellvalidierungsergebnisse zeigen deutliche Defizite bei der Simulation des vergangenen Klimas hinsichtlich der betrachteten Zielgrößen auf. Daher ist eine Korrektur der Daten sinnvoll und notwendig, um eine realistischere Einschätzung der zukünftigen Entwicklungen zu ermöglichen. Hierfür werden eine einfache Mittelwertkorrektur (LS, in multiplikativer Form LSM) sowie zwei Verteilungskorrekturen (empirisches Quantilmapping mit 11 Quantilen QM11, parametrische Verteilungsanpassung PMPE) angewandt.

Die Korrektur durch alle Methoden bewirkt generell eine deutliche Verbesserung des Mittelwertfehlers, die geringste Korrekturwirkung zeigt LSM, die größten Fehler verbleiben für die Anzahl der Hitzetage. Im regionalen Mittel treten Verschlechterung sehr selten auf und dann i.d.R. nur bei sehr geringem Ursprungsfehler und nur mit Vorzeichenbeachtung vor der Mittel-

wertbildung. Für die mittlere Anzahl der Spätfrosttage sind alle Korrekturverfahren erfolgreich, LSM zeigt die geringste Wirkung.

Die verbleibenden Restfehler der Standardabweichungen sind für alle Indizes für die beiden Verteilungskorrekturen am geringsten, wobei wie schon beim Mittelwertfehler für die Hitzetage auch nach der Korrektur starke Abweichungen bestehen bleiben. Per Definitionem ergibt sich durch die einfache Linearskalierung keine Veränderung der Standardabweichung⁶³. Den geringsten Erfolg (oft Verschlechterung) bringt die multiplikative Linearskalierung mit sich. Bei geringem Ausgangsbias und mit Beachtung der Vorzeichen ergeben sich bei regionaler Mittelung teilweise Varianzverschlechterungen (R95n alle Monate). Ohne Beachtung der Vorzeichen (Mittelung der Fehlerbeträge) liegt nur für die Eistagehäufigkeit im Oktober nach PMPE-Korrektur eine Varianzverschlechterung vor. Alle Korrekturen (außer p.d. LS) verbessern die Standardabweichungen der Spätfrosthäufigkeit. Für VPT ist LSM, für VPM PMPE am erfolgreichsten.

Im Mittel über alle Monate bewirken alle Methoden eine realitätsnähere Verteilung der Zielgrößen. Auch hier verbleiben für das Hitzetageauftreten die größten Restfehler (hier die einzige Verschlechterung der Raumdurchschnittswerte aller Einzelmonate im Oktober für PMPE). Die Ergebnisse von QM11 und PMPE sind ähnlich und übertreffen die von LS und LSM im Allgemeinen (nur für Hitze- und Eistage in einzelnen Übergangsmonaten LS oder LSM am besten). Die Verteilung der Spätfrosthäufigkeit wird durch alle Methoden verbessert, für VPT ergibt QM11 die besten Resultate, für VPM sind QM11 und PMPE sehr ähnlich. Die Betrachtung der Quantil-Quantil-Plots zeigt, dass für alle Monate die QM11- und PMPE-korrigierten Werte insgesamt näher an der Winkelhalbierenden liegen – ihre Verteilungen ähneln mehr denen der Beobachtungsdaten – als die der LS- und LSM-Anpassung, wobei in allen Fällen Restabweichungen bestehen. Die beobachtete Verteilung der Spätfrosthäufigkeit wird für die QM11-korrigierten Daten am besten angenähert, auch die PMPE-Ergebnisse liegen nahe an der Winkelhalbierenden, die der übrigen Verfahren zeigen deutlichere Fehler.

⁶³ Ausnahme: Wertezuschnitt außerhalb Definitionsbereich oder Raummittelveränderung durch ungültige Gitterzellen

7.2.3 Model Output Statistics

Zusätzlich zu den beschriebenen Biaskorrekturen wird ein exploratives Verfahren zur statistischen Simulierung der Indizes anhand großräumiger und lokaler Prädiktoren entwickelt und angewandt. Für diese Model Output Statistics (MOS) wird die Beziehung der beobachteten Zielgrößen zu den (zeitlich übereinstimmenden, Reanalyse-basierten) Modell-Prädiktorwerten durch eine Transferfunktion (Multiple Lineare Regression MLR und Generalisierte Lineare Modelle GLM) beschrieben. Diese wird anschließend genutzt, um die Zielgrößen aus (nicht zeitlich mit der Realität übereinstimmenden, aber durch QM11-Korrektur angepassten, Globalmodell-basierten) Modell-Prädiktordaten zu simulieren.

7.2.3.1 MOS REMO-Eval

Für die Erstellung der Transferfunktion auf Basis der Reanalyse-getriebenen, also zeitlich mit der Realität korrespondierenden, Modelldaten werden verschiedene Varianten berechnet und jeweils diejenige mit den besten Ergebnissen weiterverwendet.

Die Wahl der Prädiktoren – alle zur Verfügung stehenden Variablen werden für mindestens 2,5 % der Gitterzellen-Index-Monat-Kombinationen ($720 \times 7 \times 12 = 60480$) genutzt – zeigt die Komplexität der Entstehung der durch die Zielgrößen beschriebenen Phänomene. Die Kollinearität der Prädiktoren wird im Vorfeld bereinigt, Prädiktoren mit hohem statistischen Zusammenhang also entfernt (jeweils der mit der Zielgröße weniger im Zusammenhang stehende). Am häufigsten werden dabei für die MLR Temperatur in 500 sowie 850 hPa-Niveau gewählt, Luftdruck auf Meereshöhe und Bewölkung sind die meistgewählten GLM-Variablen. Großräumige Prädiktoren (Hauptkomponentenzeitreihen) sind deutlich häufiger vertreten als lokale (3×3 -Fenster), wobei letztere v.a. für den Niederschlag (hierbei v.a. für MLR, weiterhin seltener als PCs) selektiert werden. Für die Simulation der Spätfrosthäufigkeit (zwei Kennwerte, nicht monatlich aufgelöst) in den 720 Gitterzellen werden ebenfalls alle Prädiktorvariablen in mindestens 2,5 % der Fälle selektiert, der Fokus auf PC-Prädiktoren ist noch stärker. Die häufigsten MLR-Variablen sind u-Wind (500 hPa), spezifische Luftfeuchtigkeit (850 hPa und bodennah) und v-Wind, für die GLM-Modellierung Bewölkung und sensible Wärmeflüsse von der Erdoberfläche.

Werden zur Bewertung der Simulationsgüte (gemittelt über alle Monate und Gitterzellen) die häufig verwendeten Determinationskoeffizienten genutzt, so liegen diese bei der MLR stets

über 0,5, bei den GLMs nahe darunter oder ebenfalls darüber. Somit läge die Interpretation nahe, dass nahezu oder mehr als die Hälfte der Varianz der Referenzdaten durch die Simulationen beschrieben wird. Wird jedoch der Mean Squared Skill Score genutzt, welcher die Abweichungen der Simulationen relativ zu den internen Schwankungen der Beobachtungsdaten betrachtet, ergibt sich ein anderes Bild. Mit im Mittel (außer für die MLR-Eistagemodellierung) negativen Werten zeigt sich, dass die Abweichungen zwischen Simulationen und Referenzdaten die Variabilität innerhalb der Referenzdaten (mit Werten von < -1 oft deutlich) übersteigen. Die Ergebnisse der Spätfrostsimulation sind ähnlich.

7.2.3.2 MOS REMO-ESM

Nach der Übertragung auf GCM-angetriebene REMO-Daten überwiegen über alle Monate gemittelt für die Hitzetage- (stärker) und Starkregenhäufigkeit zu hohe Werte. Die Fehler von Frost- und Eistageauftreten zeigen räumliche Gegensätze, ebenso wie DMI, MCD und R1mmn, die jedoch weniger stark ausfallen. Die VPT-Spätfrosthäufigkeit wird über-, die VPM-Spätfrosthäufigkeit unterschätzt. Die Ergebnisse von MLR und GLM sind im Groben ähnlich. Die Standardabweichung (im Mittel über alle Monate) wird durch die MLR-Simulationen mit wenigen Ausnahmen flächendeckend für alle Kennwerte unterschätzt. Auf GLM-Basis ist sie für R95n und die Hitzetagehäufigkeit fast überall zu hoch, für Frost- und Eistage zeigt sich räumliche Heterogenität, für R1mmn, MCD und DMI überwiegen zu niedrige Schwankungen (geringere Beträge). Die mittleren Fehler der Spätfroststandardabweichung deuten jeweils in die gleiche Richtung wie die der Mittelwerte, jedoch sind die MLR-Fehler für VPT kleiner, für VPM größer als die auf GLM-Basis. Die prozentualen Quantil-RMSE-Werte steigen im Mittel über alle Monate für GLM und MLR von R1mmn über DMI und MCD zu der Frosttagehäufigkeit an. Für MLR folgen R95n, Eis- und Hitzetage. Für die Hitzetage treten verbreitet, für die Eistage im SW des Untersuchungsgebietes pQRMSE-Werte über 100 % auf. Die GLM-Simulationen zeigen auch für die Frosttage und insbesondere für R95n viele Gitterzellen mit Fehlern von über 100 %. Die hohen Abweichungen der Extremtemperaturkentage stammen aus den jeweiligen Übergangsmontaten mit geringer Auftretenswahrscheinlichkeit. Für den Spätfrost beträgt der pQRMSE im Mittel zwischen 50 und 60 % (VPT) bzw. 35 und 45 % (VPM), für beide Varianten sind die MLR-Ergebnisse besser.

7.2.4 Biaskorrektur, MOS und Zukunftsprojektionen

Der Vergleich von Biaskorrektur- und MOS-Ergebnissen lässt je nach Situation eine der beiden Verteilungskorrekturen (QM11, PMPE) als die beste Methode zur Datenaufbereitung erkennen⁶⁴. Diese wird auf die Zukunftsprojektionen des REMO-RCMs sowie weiterer RCMs angewandt. Im Mittel über das Untersuchungsgebiet (sowie meist auch bezüglich der regionalen Minima und Maxima) ergeben sich für das 21. Jahrhundert für Frost- und Eistagehäufigkeiten negative, für Hitzetagehäufigkeiten signifikante positive Trends (alle Modelle, Abnahme der Trendstärke Richtung Übergangsmonate). Die stärksten Werte sind auf Basis des ALADIN-Modells zu verzeichnen (ca. 10 bis 15 Tage pro 100 Jahre). Ansonsten zeigt sich eine Tendenz zur sommerlichen Trockenheitszunahme (Zunahme R1mmn und MCD, Abnahme DMI Mai–August/September). Für den Winter werden z.T. weniger Trockentage und mehr Starkniederschlagsereignisse projiziert, die DMI-Trends sind weiterhin meist negativ. Die größten Modellgegensätze zeigen sich im April (ALADIN bzgl. R1mmn, MCD und DMI trockener, REMO inkl. R95n feuchter, RACMO Zwischenstellung). Die Zukunftssimulationen für das Spätfrostauftreten auf Basis der monatlichen Vegetationsperiode weisen eindeutig in Richtung Abnahme (REMO-Maximum nahe null, sonst alle regionalen Minima, Mittelwerte und Maxima negativ). Bezüglich der thermisch definierten Vegetationsperiode hingegen werden Widersprüche sichtbar: Während RACMO und ALADIN (hier auch regionales Minimum positiv) im regionalen Mittel eine Zunahme projizieren, ist der REMO-Trend⁶⁵ im Durchschnitt negativ.

7.2.5 Erträge aus Landwirtschaft und Weinbau

Die explorative MOS-Methode wird ebenfalls zur Simulation von Feldfrucht- und Weinerträgen genutzt. Aufgrund mangelhafter Referenzdatenlänge ist eine unabhängige Validierung der MOS-Ergebnisse für die Ertragssimulation nicht möglich. Die Güte der MOS-Eval-Simulationen (Kontrollzeitraum) ist jedoch deutlich besser als die der Kennwertmodellierungen. Mit wenigen Ausnahmen sind für die Feldfruchterträge sowohl MSSS als auch R^2 größer als 0,5,

⁶⁴Die einzige Ausnahme hierzu bildet MOS-MLR als beste Variante für die Frosttage im September. Da der pQRMSE hierfür jedoch bei 171 % liegt, wird diese – wie alle anderen Index-Monat-Kombination mit pQRMSE > 100 % (Eistage April, Oktober, Hitzetage Mai, September) – verworfen.

⁶⁵REMO2015, für REMO2009-Daten sowie MOS-Simulationen auf Basis von REMO2015 ist er ebenfalls positiv.

meist noch höher, für die Frankenweinerträge in allen Fällen über 0,85. Es wird eine Vielzahl an Varianten getestet und jeweils die beste Methode weiterverwendet. Auch hier sind die großräumigen PC-Prädiktoren häufiger vertreten als die lokalen 3×3 -Fensterwerte. Für alle Feldfrüchte zusammen genommen werden spezifische Luftfeuchte, Niederschlag, Luftdruck auf Meereshöhe und sensible Wärmeflüsse am häufigsten gewählt, wobei je nach Landkreis für jede Feldfrucht alle zur Wahl stehenden Prädiktorvariablen zur Anwendung kommen. Für den Frankenwein (ohne räumliche Auflösung) werden nur einzelne Variablen genutzt, hierbei dient die Bodenfeuchte zur Simulation von Rot-, Weiß- und Gesamtweinerträgen, die Minimumtemperatur wird für Rot- und Gesamtwein, der Niederschlag für Gesamt- (hier lokaler Prädiktor) und Weißweinsimulation verwendet, jeweils durch weitere ergänzt.

Die REMO-Zukunftsprojektionen ergeben für die Sommerfeldfrüchte im regionalen Mittel negative Trends (8–14 %), für die Winterfrüchte positive Trends (6–14 % pro 100 Jahre im Vergleich zum Mittelwert 1971–2000). Für die Sommergetreide treten hierbei in den Einzellandkreisen weniger Vorzeichenabweichungen vom Raumdurchschnitt auf. Im Multimodellensemble (Hinzunahme drei weiterer RCMs) bestätigen sich die mittleren Trendvorzeichen je Ackerfrucht, wobei in den einzelnen Landkreisen z.T. Abweichungen auftreten. Hinsichtlich der Frankenweinerträge ist das Bild weniger klar und beinhaltet Widersprüche. Auf Basis des REMO-Daten werden für Rot- und Weißwein Abnahmen, für den Gesamtwein hingegen Zunahmen (jeweils ca. 10 %) projiziert. Gleiche Vorzeichen besitzen die HIRHAM-Trends, ALADIN und RACMO hingegen führen zu positiven Weiß- und Gesamtwein- sowie negativen Rotweintrends.

7.3 Diskussion der Ergebnisse

7.3.1 Biaskorrekturmethode und deren Erfolg

Die bessere Korrekturgüte des Quantilmapping gegenüber der Linearskalierung und weiteren Methoden – wie sie in dieser Arbeit erkennbar wird – wurde von vielen Studien bestätigt (z.B. IVANOV & KOTLARSKI 2017; TEUTSCHBEIN & SEIBERT 2012; TENG *et al.* 2015; CHEN *et al.* 2013). Dies ist begründet durch die Erfassung der gesamten Verteilung durch diese Methoden im Vergleich zur reinen Mittelwertkorrektur bei der Linearskalierung. Die Ergebnisse der empirischen (QM) sind hierbei (wie auch in der vorliegenden Arbeit) oftmals besser als die der parametrischen Verteilungskorrekturen (PM) (z.B. IVANOV & KOTLARSKI 2017; GUDMUNDSSON

et al. 2012; GUTJAHR & HEINEMANN 2013; LAFON *et al.* 2013; SARVINA *et al.* 2018), wobei die Definition der Transferfunktionen (sowohl empirisch als auch parametrisch) dieser Studien von der hier verwendeten abweicht. In ihrer Untersuchung verschiedener Temperatur- und Niederschlags-basierter Indizes für die Weinbauregion Douro in Portugal mittels eines Multimodellensembles aus vier CORDEX-EUR11-RCMs betonen auch MARTINS *et al.* (2021) die hohe Relevanz einer adäquaten Biaskorrektur der Daten, wobei gerade im Bezug auf Extremereignisse Quantilmapping einer Linearskalierung vorzuziehen ist, da letztere keine Korrektur der Verteilung mit sich bringt.

7.3.2 MOS

7.3.2.1 Güte

Die Güte mindestens einer der Verteilungskorrekturen (QM11, PMPE) ist für alle betrachteten Kennwert-Monat-Kombinationen sowie beide Spätfrostindizes (je im regionalen Mittel) besser als die der beiden MOS-Simulationen. Dies ist im Einklang mit den Ergebnissen von THEMESSEL *et al.* (2011) zur Korrektur von Reanalyse-getriebenen RCM-Niederschlagsdaten im Alpengebiet: Auch hier ist das Quantilmapping erfolgreicher als die Model Output Statistics (MLR und andere Varianten) und alle anderen verwendeten Methoden.

Eine Einordnung der Ergebnisse dieser Studie ist aufgrund des neuartigen Charakters der Methodik schwierig. Die Anwendung von Model Output Statistics im Sinne der hier benutzten Terminologie (vom Prädiktanden abweichende Prädiktorvariable(n) im Gegensatz zu Biaskorrektur) auf Klimamodelldaten ist wenig verbreitet (MARAUN *et al.* 2010). Sie beschränkt sich zudem in der Regel auf Hindcastsimulationen bzw. Reanalyse-getriebene RCMs (z.B. PAETH 2011; SCHMIDT *et al.* 2014; STEININGER *et al.* 2023; THEMESSEL *et al.* 2011, vgl. MARAUN *et al.* 2010). Eine Ausnahme bildet etwa die Studie PAETH *et al.* (2008), in der die REMO-Eval-basierte Transferfunktion – wie in der vorliegenden Arbeit, jedoch ohne Datenanpassung – anschließend auf REMO mit GCM-Antrieb (inkl. Landmodell) übertragen wird. TURCO *et al.* (2017) nutzen Reanalyse-angetriebene RCM-Daten zum Training ihres MOS-Modells, welches sie dann anschließend auf die GCM-RCM-Daten (historisches und zukünftiges Szenario) anwenden. Jedoch basiert der verwendete Ansatz auf der sogenannten MOS-Analog-Technik. Hierbei dient der an einem Gitterpunkt beobachtete Niederschlag als Prädiktand, während das simulierte Niederschlagsmuster (pattern) über einem bestimmten Gebiet den Prädiktor darstellt.

Zu jedem täglichen Niederschlagsmuster der GCM-RCM-Daten wird dann der ähnlichste (Euklidische Distanz, vgl. Gleichung 4.90) Reanalyse-RCM-Pattern gesucht und die entsprechende beobachtete Niederschlagssumme zugeschrieben. Dieses Verfahren ist somit nicht direkt mit der hier genutzten Methodik vergleichbar, da weder Regressionen noch mehrere Prädiktoren zum Einsatz kommen.

Hinsichtlich der isolierten Betrachtung der Model Output Statistics fällt zunächst die deutlich schlechtere Performance der Index- im Vergleich zu den Ertragssimulationen auf (REMO-Eval). Ein Aspekt hierbei ist die höhere räumliche Auflösung der klimatischen Kennwerte, die naturgemäß mit einer höheren Variabilität einhergeht, da eine Mittelwertbildung über größere Regionen gegensätzliche Tendenzen an verschiedenen Raumpunkten ausgleicht. Tatsächlich erweist sich beispielsweise die MLR-Spätfrost-Simulation als deutlich erfolgreicher, wenn der regionale Mittelwert modelliert wird⁶⁶. Es verbleiben jedoch deutliche Defizite und zudem erlaubt eine ausschließliche Untersuchung der räumlichen Durchschnittswerte keine regionalen Differenzierungen der Ergebnisse. Hinzu kommt die hohe Komplexität der betrachteten klimatischen Extremsituationen. So werden auch bei der dynamischen Simulation durch Klimamodelle mittlere Zustände besser abgebildet als Extreme (vgl. z.B. FLATO *et al.* 2013; HERRERA *et al.* 2010; KJELLSTRÖM *et al.* 2007).

Andererseits sind die REMO-Eval-Ergebnisse der Ertragssimulation als überraschend hoch einzuschätzen. Basierend auf einer ähnlichen Methodik (jedoch mit nur drei Prädiktorvariablen) erreichen die Ertragsmodellierungen von PAETH *et al.* (2008) für Benin je nach betrachteter Feldfrucht maximal 41–63 % Varianzabdeckung, wobei sich die auf die Pflanzen einwirkenden klimatischen, pedologischen sowie anthropogenen Faktoren in Benin von denen im Untersuchungsgebiet unterscheiden.

In diesem Hinblick interessant ist die ähnliche Performance von MLR und GLM. Diese besteht auch für die Ertragssimulationen (nicht gezeigt, Ackererträge einige Differenzen Silomais und Sommergerste). Die kompliziertere Methode der GLM schneidet für MOS-REMO-Eval der Indizes immer schlechter ab als die MLR. Nach Anwendung auf die REMO-ESM-Daten sind die GLM-Ergebnisse für die selteneren Hitze- und Starkregenereignisse (Maximum regionaler Mittelwert Beobachtungsdaten 1951–2005 Hitzetage 2,5 bzw. R95n 1,6 Tage) für alle Monate

⁶⁶VPM MSSS = 0,35 $R^2 = 0,96$; VPT MSSS = -0,92 $R^2 = 0,86$, somit also bezüglich MSSS weiterhin nicht zufriedenstellend, vgl. Abschnitt 5.3.1.4

schlechter. Bezüglich der Eis- und Frosttage führt GLM in Monaten mit höheren beobachteten Häufigkeiten zu besseren (Eistage oder sehr ähnlichen) Ergebnissen wie MLR, für R1mmn und MCD mit generell höheren Werten ist dies außer im Mai stets der Fall. Dieser allgemein geringe Zusatznutzen der GLM über die MLR – insbesondere für Monate oder Kennwerte mit niedrigeren Werten – widerspricht der Theorie der beiden Verfahren. Im Falle der Erträge sowie des DMI mit positiv-kontinuierlichen Realisierungen mag dies noch nachvollziehbar sein: Die MLR schließt negative Werte zwar nicht explizit aus, diese werden jedoch bei ausreichend positivem Verteilungsschwerpunkt sehr unwahrscheinlich (im Falle des DMI treten sie dennoch auf und werden durch manuelle Begrenzung angepasst, für die Erträge (beste Varianten) resultieren keine negativen Werte). Bei den auf Schwellwertüber- bzw. -unterschreitung basierenden Kennwerten ist jedoch definitionsgemäß von einer anderen unterliegenden Verteilung sowohl der Daten als auch der Residuen auszugehen. Die z.T. besseren Ergebnisse sind somit nicht auf eine bessere Repräsentation der theoretischen Eigenschaften zurückzuführen, sondern haben andere Gründe. Aufgrund der allgemein schlechteren MOS-Ergebnisse für die Indizes im Vergleich zur Biaskorrektur wird hierauf nicht näher eingegangen.

Im Hinblick auf die Modellgüte stellt sich auch die Frage, ob die Auswahl des einen besten Modells aller Bootstrapping-Iterationen nachteilig ist. Daher ist es sinnvoll, alternative Verfahren – wie etwa die Verwendung des gewichteten Durchschnitts der besten Modelle – in Betracht zu ziehen. Folgender Exkurs zeigt dies beispielhaft für die Modellierung der Frankenweinerträge.

7.3.2.2 Exkurs: Frankenweinsimulation mit gewichtetem Modellmittel

Wie in Kapitel 4.4.4.3 beschrieben, wird das MOS-Modell gemäß der einen besten Bootstrapping-Iteration verwendet. Eine alternative Möglichkeit ist, anstatt dessen den – nach Modellqualität gewichteten – Mittelwert aller oder einer bestimmten Anzahl bester Iterationen zu verwenden (WMA Weighted Model Averaging). Eine WMA-Variante wird hier für MLR getestet und mit den Ergebnissen der besten Einzelmodelle verglichen. Hierfür werden die 5 % Ergebnisse der besten Modelle (der 1000 Bootstrapping-Iterationen) verwendet und gemäß ihrem Skill (vgl. Gleichung 4.91, $w1_i = skill_i / \sum_i(skill)$) sowie der Anzahl der verwendeten Prädiktoren ($w2_i = w1_i / \sqrt{npred_i + \min(npred)^2} \rightarrow w3_i = w2_i / \sum_i(w2)$) gewichtet gemittelt.

Die Modellerstellung mit gewichtetem Modellmittel statt bestem Modell wird für alle Optionen wiederholt. Tabelle 7.1 zeigt den Vergleich der jeweils besten Modelle ohne und mit WMA.

Tabelle 7.1: Ergebnisse MLR-MOS Frankenwein mit gewichteten Modelldurchschnitt. Je Weinkategorie oben bestes Ergebnis ohne WMA sowie unten mit WMA.

| Wein- klasse | Optionenkombination | Qualität beste Iteration | | Qualität WMA | |
|-----------------|--------------------------|--------------------------|----------------|--------------|----------------|
| | | MSSS | R ² | MSSS | R ² |
| weiß | bs11-uv-preco-ztrans2 | 0,82 | 1,00 | 0,77 | 0,99 |
| | bs12-uv-preco-ztrans2 | 0,77 | 1,00 | 0,77 | 1,00 |
| rot | bs12-pcafw-preco-ztrans2 | 0,76 | 0,99 | 0,84 | 0,95 |
| | bs12-pcafw-preco | 0,74 | 0,98 | 0,84 | 0,95 |
| gesamt | bs12-uv-preco | 0,97 | 0,98 | 0,76 | 0,85 |
| | bs12-pcafw-preco07 | 0,27 | 0,96 | 0,92 | 0,96 |

Für die Weiß- und Gesamtweinerträge ergeben sich die maximalen Mittelwerte aus MSSS und R² für eine Variante ohne WMA. Hinsichtlich der Rotweinerträge sind diese für die WMA-Variante von bs12-pcafw-preco am höchsten (0,89). Sehr ähnlich hierzu sind die WMA-Ergebnisse ohne Standardisierung (ztrans2, dritte Nachkommastelle etwas niedriger), also für die Optionenkombination, für die sich ohne WMA die besten Resultate ergeben (0,87). Insgesamt sind die Ergebnisse mit gewichtetem Modellmittel also besser oder ähnlich hoch wie mit der Verwendung des einen besten Modells. Erstere ist jedoch komplizierter und speicherintensiver⁶⁷, weshalb im Rahmen dieser Arbeit für alle untersuchten Prädiktanden stets die Modelle aus der besten Iteration genutzt werden.

7.3.2.3 Prädiktoren

Dass sowohl für die Index- als auch die Feldfruchtertragssimulation alle zur Verfügung gestellten Prädiktorvariablen Anwendung finden, lässt sich in mehrfacher Hinsicht interpretieren: Zum Einen handelt es sich – v.a. bei den klimatischen Kennwerten – um eine große Anzahl an möglichen Situationen (60480 für die monatlichen Kennwerte, 1440 für den Spätfrost, 36 für die Ackererträge). Zum Anderen deutet die Vielzahl an gewählten Prädiktoren auf eine hohe Komplexität der zu beschreibenden Phänomene hin. Die Variablen wurden im Voraus so gewählt, dass eine physikalische Relevanz im Bezug auf die Prädiktanden besteht, da sie verschiedene

⁶⁷Daher werden die Testläufe auch nur für die MLR der Frankenweinerträge durchgeführt.

Aspekte des atmosphärischen Zustandes in Bodennähe bzw. verschiedenen Höhenniveaus charakterisieren. Die Kollinearität der Prädiktoren wurde geprüft und bereinigt, jedoch nur paarweise sowie für MLR nur linear. Es wurden also weder multiple Korrelationen beachtet, noch (für MLR) nicht-lineare Zusammenhänge, weshalb immer eine Restredundanz verbleibt. Zudem kann z.B. die Bodenfeuchte in einem Fall als direkter Prädiktor verwendet werden, während sie in anderen Fällen implizit – etwa durch Niederschlag, latente Wärmeflüsse, Verdunstung und/oder andere Variablen – Eingang in die Simulationen findet. Hierbei ist zu beachten, dass die Hauptkomponenten-Prädiktoren nicht die jeweilige Variable an sich, sondern dominante Varianzmuster derselben repräsentieren. Gerade diese besitzen häufig einen hohen Zusammenhang zu anderen atmosphärischen Größen (Stichwort Klimamoden, vgl. KEUPP *et al.* 2017; POLLINGER 2013).

7.3.2.4 Exkurs: Spätfrostsimulation auf GCM-Basis

Da die Anzahl der selektierten lokalen Prädiktoren gering ist und von einer hohen Repräsentanz der großskaligen Prozesse auch in globalen Modellen ausgegangen wird, soll die Simulation der Spätfrosthäufigkeiten mithilfe von GCM-Daten untersucht werden.

Hierfür werden die besten Gitterzellen der MLR-Spätfrostsimulation – definiert durch MSSS und R^2 der REMO-Eval-Simulation $> 0,90$ –, welche ausschließlich auf PC-Prädiktoren⁶⁸ basieren, selektiert und anschließend mithilfe des Globalmodell MPI-ESM-LR statt des damit angetriebenen REMO2015-MPI-ESM-LR simuliert. Diese zwei Kriterien werden für den VPT-Spätfrost auf Basis von pre-co-ztrans2 nicht erfüllt. Die Verwendung der pre-co-Simulationen ergibt eine Gitterzelle für den VPT- und sieben Gitterzellen für den VPM-Spätfrost. Die MPI-ESM-LR-Daten werden mithilfe einer Nearest Neighbor-Interpolation⁶⁹ auf das RCM-Gitter gebracht und anschließend wie auch die REMO-MPI-Daten auf die REMO-Eval-EOFs projiziert (vgl. Abschnitt 4.4.5, Seite 84).

⁶⁸Lokale Prädiktoren sind mit der groben GCM-Auflösung nicht zielführend. Außerdem ist die Variable huss (spezifische Luftfeuchtigkeit in Bodennähe) für MPI-ESM-LR nicht verfügbar. Gitterpunkte mit dieser Prädiktorvariable werden daher ebenso ausgeschlossen.

⁶⁹Hierdurch werden keine künstlichen Daten generiert, sondern ausschließlich für jede neue höher aufgelöste Gitterzelle die Daten der nächsten größeren Gitterzelle verwendet.

Die Ergebnisse sind in Abbildung 7.4 für den (quasi-)unabhängigen Zeitraum 1951–1980 dargestellt. Die prozentualen Fehler von Mittelwert, Standardabweichung sowie QRMSE besitzen die gleiche Größenordnung. Für VPM sind die GCM-basierten Ergebnisse aller drei Metriken schlechter, für VPT wird der Mittelwert etwas besser simuliert. Insgesamt sind die Ergebnisse auf RCM-Grundlage somit etwas besser. Trotz der hohen Güte der REMO-Eval-Simulationen im Kontrollzeitraum weichen die Resultate der REMO-ESM- und ESM-Simulationen beide jedoch so stark von den Beobachtungen ab, dass die MOS-Nutzung hier als nicht sinnvoll erachtet wird. Da keine unabhängigen Vergleichsdaten vorliegen, kann diese Analyse nicht für die hinsichtlich (REMO-Eval) besser performenden Ertragssimulationen durchgeführt werden.

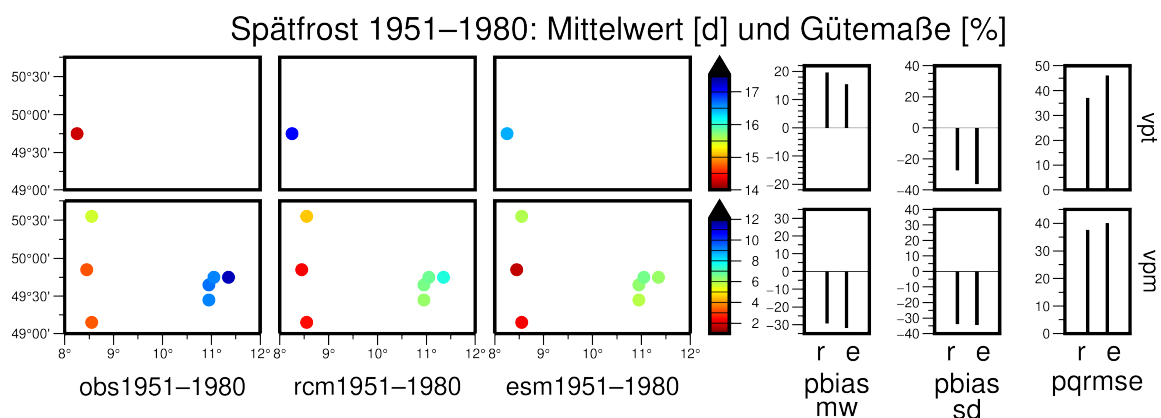


Abbildung 7.4: Ergebnisse Spätfrost basierend auf REMO- und MPI-ESM-Daten 1951–1980. Kartendarstellungen der beobachteten (links), auf RCM-Basis (REMO-MPI, Mitte) sowie ESM-Basis (MPI-ESM, rechts) simulierten Werte. Balkendarstellungen der prozentualen Mittelwert- (links), Standardabweichungs- (Mitte) sowie QRMSE-Fehler (rechts). Oben VPT, unten VPM.

7.3.3 Zukunftsprojektionen klimatischer Kennwerte

Als Vergleichsbasis für die Diskussion der simulierten zukünftigen Erträge bietet sich die Betrachtung der Trends der Beobachtungsdaten in den letzten Jahrzehnten der Vergangenheit an. Abbildung 7.5 zeigt eine Übersicht der Trends der regionalen Mittelwerte aller betrachteten Kenngrößen sowohl hinsichtlich der Beobachtungen in der Vergangenheit als auch bezüglich der Zukunftssimulationen aller genutzten Modelle. Auch die Ertragstrends sind mitaufgetragen. Gleichbleibende Trendrichtungen mit Einigkeit aller Modelle finden sich für R1mmn im Mai und August, MCD im Juni und August, R95n von Oktober bis Januar sowie im März und

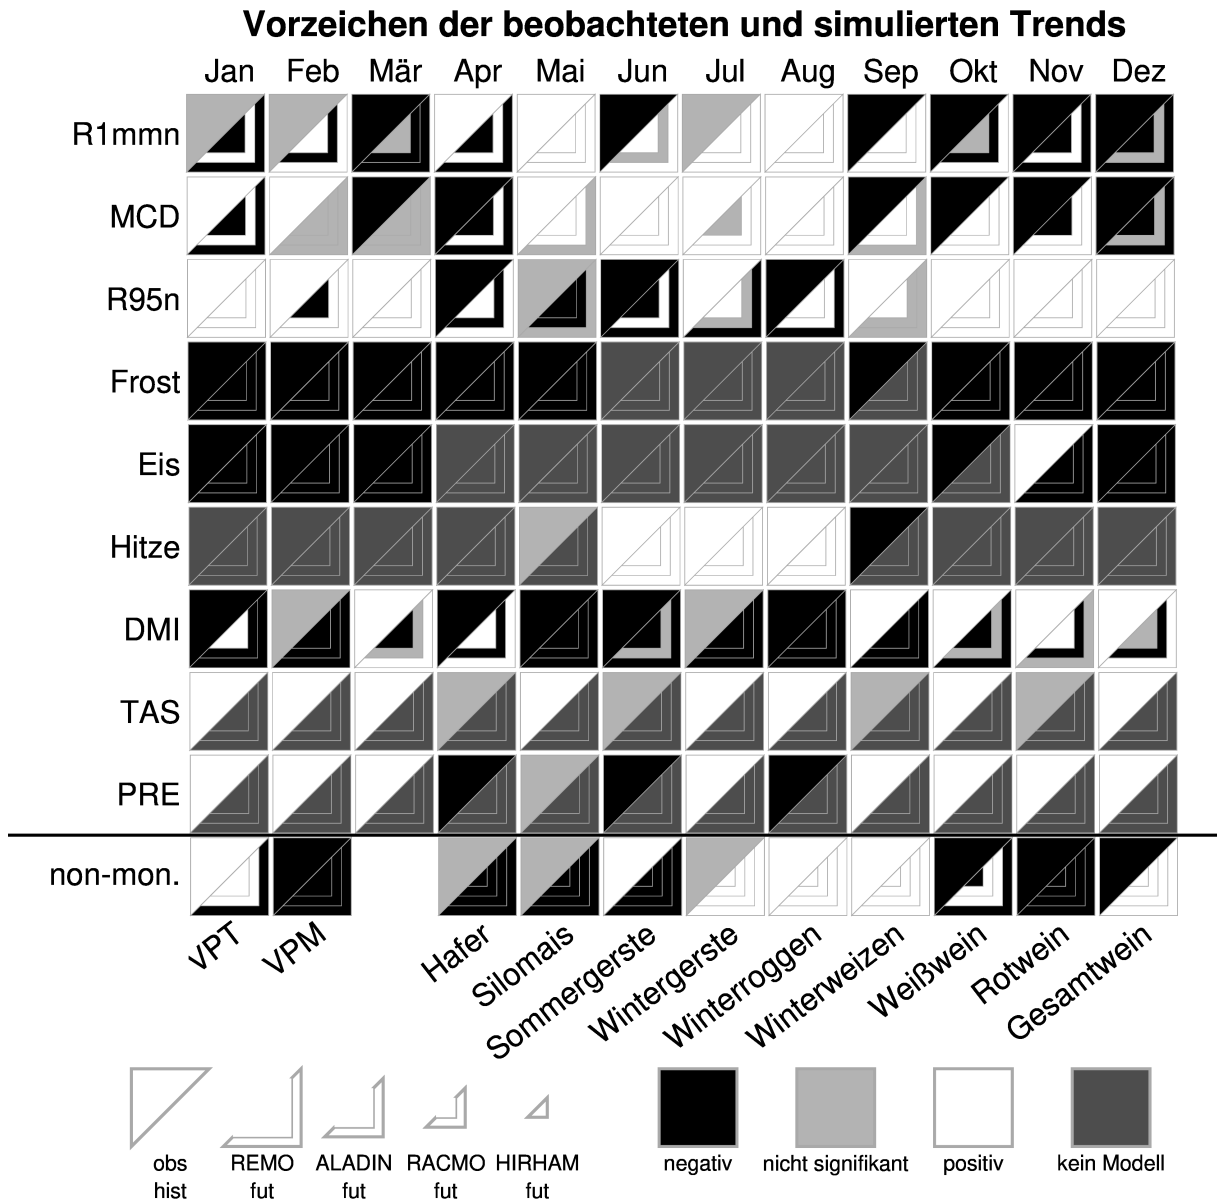


Abbildung 7.5: Vorzeichen der beobachteten vergangenen (*obs hist*) und simulierten zukünftigen (*REMO, ALADIN, RACMO, HIRHAM fut, HIRHAM nur für Feldfrucht- und Frankenweinerträge*) Trends der regionalen Mittelwerte. Zum Vergleich sind auch die beobachteten Trends von bodennaher Temperatur (*TAS*) sowie Niederschlag (*PRE*) dargestellt. Trends der Beobachtungsdaten: *DMI, TAS und PRE 1950–2019, restliche klimatische Kennwerte 1950–2018, Feldfruchterträge 1983–2015, Frankenweinerträge 1994–2020. Zukunft RCP8.5 2006–2100, Datenbasis außer beobachtete Ertragsdaten jeweils auf Basis der 30-jährigen gleitenden Mittel.*

Hitzetagehäufigkeit Juni–August jeweils mit positivem Vorzeichen. Negative Trends in der Vergangenheit und projiziert für die Zukunft (alle Modelle) liegen im Bezug auf die Anzahl der Frost- (Oktober–Mai), Eistage (Dezember–März), den DMI (Mai, August) sowie die Spätfrosthäufigkeit auf Basis der monatsdefinierten Vegetationsperiode vor. Aus Abbildung 7.5 lässt sich nur die Richtung, nicht aber die Stärke der Trends ablesen. Interessant ist dennoch beispielsweise das Verhältnis von R1mmn, MCD, R95n und PRE in den beobachteten Trends: Im Mai ist ein Anstieg der Trockentage und der maximalen Trockenperiodenlänge zu verzeichnen, gleichzeitig aber mehr Niederschlag (R95n leicht positiv, aber nicht signifikant), im Juni hingegen nehmen Trockentageanzahl, Starkniederschlagshäufigkeit und Gesamtniederschlag ab und im Juli koinzidieren längere Trockenperioden mit mehr Starkregen und mehr Niederschlag. Je nach Monat ist also eine Tendenz zu mehr oder weniger Extremen erkennbar. Werden die Trendstärken mitbetrachtet, so treten die markantesten Ergebnisse der Beobachtungsdaten im August auf und zeigen eine deutliche Tendenz zu trockeneren und heißeren Bedingungen (jeweils bezogen auf 100 Jahre): R1mmn +10,5 d, MCD +10,0 d, R95n -2,2 d, Hitzetage +4,9 d, DMI -44,4 mm/°C, TAS +5,2 °C sowie PRE -85,9 mm. In diesem Monat treten mit Ausnahme der Frost- und Eisindizes für alle klimatischen Kenngrößen die größten Trendstärken auf. Auf die Ertragstrends wird in Abschnitt 7.3.4 eingegangen.

Die Beobachtungsdaten spiegeln aufgrund ihrer zeitlichen Begrenzung und Glättung das in den letzten 250 Jahren beispiellose Hitze- und Trockenereignis der Jahre 2018–2020 nur bedingt wider. Hiervon waren im Mittel fast 36 % Europas für 12,2 Monate betroffen. Die europäische Temperaturanomale lag bei 2,8 °C. Infolgedessen kam es in Deutschland zu deutlichen Getreideertragseinbußen (RAKOVEC *et al.* 2022).

Die eindeutigsten Ergebnisse hinsichtlich der für die Zukunft projizierten Trends⁷⁰ finden sich für die betrachteten Temperatur(extrem)kenntage. Eine Abnahme der Eis- und Frost- ebenso wie eine Zunahme der Hitzetage entsprechen den Erwartungen in Verbindung mit einer grundsätzlichen Temperaturerhöhung (z.B. TÖLLE *et al.* 2018; WAGNER *et al.* 2013; HUNDHAUSEN *et al.* 2022). Viele Veröffentlichungen bestätigen diese Entwicklungstendenzen hinsichtlich der Zunahme hoher Temperaturextreme (z.B. ALMAZROUI *et al.* 2021; BENISTON *et al.* 2007;

⁷⁰Im Einklang mit den Beobachtungen in der Vergangenheit mit Ausnahme der Eistagetrends im November von +0,84 d/100a sowie der Hitzetagetrends im September von -0,32 d/100a, welche deutlich schwächer ausfallen als die Trends in den jeweiligen Kernjahreszeiten

CARDELL *et al.* 2020; COPPOLA *et al.* 2021; DEUTSCHLÄNDER & MÄCHEL 2017; HUNDBAUSEN *et al.* 2022; TÖLLE *et al.* 2018) für (Mittel-)Europa bzw. Deutschland. Auch die Abnahme der Frosttagehäufigkeit im Untersuchungsgebiet sowie den umgebenden Regionen findet sich in zahlreichen Studien (z.B. GUTIÉRREZ *et al.* 2021; ITURBIDE *et al.* 2021; JYLHÄ *et al.* 2008; ZHAO *et al.* 2021), hinzu kommt eine deutliche Zunahme der minimalen jährlichen Tagestemperatur (GUTIÉRREZ *et al.* 2021; ITURBIDE *et al.* 2021; LI *et al.* 2021).

Weniger eindeutig sind die Projektionen hinsichtlich der Niederschlagsverhältnisse. Die von allen Modellen projizierte Zunahme der Starkniederschläge im Winter sowie z.T. auch im Herbst und Frühjahr findet sich auch in anderen Studien (z.B. BENISTON *et al.* 2007; CARDELL *et al.* 2019; RAJCZAK & SCHÄR 2017; TÖLLE *et al.* 2018). Die Tendenz der sommerlichen Starkniederschläge ist wie in den hier vorgestellten Ergebnissen auch in anderen Arbeiten nicht eindeutig (z.B. CARDELL *et al.* 2020; RAJCZAK & SCHÄR 2017). RYBKA *et al.* (2022) beispielsweise erfassen im Sommer mehr Starkregen. Durch den hier betrachteten R95n-Index wird nur die Häufigkeit der Niederschlagsereignisse erfasst, die über dem 95. Perzentil der Referenzdaten liegen. Die Entwicklung der Intensität der Niederschläge – hier wird etwa von CARDELL *et al.* (2020), RAJCZAK & SCHÄR (2017) und TÖLLE *et al.* (2018) eine Zunahme simuliert – jedoch wird nicht betrachtet.

Die von den meisten Modellen des Ensembles simulierte Zunahme der Trockentageanzahl und -periodenlänge im Sommer ebenso wie das schwächere und weniger eindeutige Signal im Winter und Frühjahr finden Bestätigung in anderen Auswertungen (z.B. CARDELL *et al.* 2020; RAJCZAK & SCHÄR 2017; WAGNER *et al.* 2013, i.d.R. jahreszeitliche Betrachtung).

Hinsichtlich der allgemeinen Niederschlagsverhältnisse bis zur Mitte des 21. Jahrhunderts ist basierend auf der Literatur keine klare Tendenz auszumachen, jedoch zeigen die Verteilungen eine Veränderung zu niedrigeren geringen und höheren starken Niederschlägen (WAGNER *et al.* 2013). Generell lassen Aussagen über die durchschnittlichen Niederschläge bzw. deren Veränderungen keine Schlussfolgerungen hinsichtlich Niederschlagsextremen zu, da sich Mittelwert und Extreme oft nicht auf die gleiche Weise, teilweise sogar gegensätzlich, entwickeln (RAJCZAK & SCHÄR 2017). Stärkere, größere und teilweise auch häufigere konvektive Zellen können eine Zunahme von Starkniederschlägen bei gleichzeitiger Abnahme der Durchschnittsniederschläge hervorrufen (PURR *et al.* 2021). Die konvektionsauflösende Modellierung von PURR *et al.* (2021) weist hierbei in Richtung stärkster Zunahmen für die höchsten Perzentile, wo-

bei im Gebiet *Unterfranken+* die Anzahl und Stärke konvektiver Zellen und Niederschläge im Osten steigt, im Westen hingegen sinkt.

Die weiter oben bereits angesprochene Abnahme der Frost- und Eistage in allen Monaten geht einher mit einer Abnahme der Spätfrostgefahr im Bezug auf die monatlich definierte Vegetationsperiode (ab April). Die allgemein steigenden Temperaturen führen jedoch zu einem früheren Vegetationsbeginn, wodurch das tatsächliche Spätfrostisiko mitunter steigt (vgl. Abschnitt 7.1.1). So wird aufgrund des früheren Knospenaustriebs von einer erhöhten Spätfrostbetroffenheit des Weins ausgegangen (z.B. TRAPP *et al.* 2013b für Rheinland-Pfalz, LEOLINI *et al.* 2018 für Deutschland Modellierung mit UniChill-Modell und RCM ALADIN). Dies stimmt mit den in dieser Arbeit vorgestellten Ergebnissen der VPT-Spätfrosttrends im regionalen Mittel gemäß ALADIN, RACMO und REMO2009 überein, nicht jedoch mit denen gemäß REMO2015 (vgl. Abschnitt 5.4.3.2). Hierbei ist zu beachten, dass dieser Kennwert komplizierter definiert ist als die übrigen betrachteten Indizes: Tage mit Minimumtemperaturen von unter 0 °C innerhalb eines Zeitraumes, der vom ersten Auftreten von fünf aufeinanderfolgenden Tagen mit mindestens 5 °C Tagesmitteltemperatur bis zum 30. Juni des entsprechenden Jahres dauert. Ein Nicht-Auftreten kann also entweder bedeuten, dass kein Frost vorhanden ist, oder, dass die Schwelle zur Vegetationsperiode noch nicht überschritten wurde. Gleichzeitig bedeutet eine höhere Häufigkeit nicht mehr Frost an sich, sondern nur mehr Frost nachdem die thermische Wachstumsanregung bereits stattgefunden hat. Da die Frosthäufigkeit für alle verwendeten Modelle ausschließlich negative Trends zeigt (monatliche Auflösung, Einzeltage könnten dabei abweichen), ist davon auszugehen, dass die positiven VPT-Spätfrosttrends primär durch den erwärmungsbedingt früheren Vegetationsbeginn zu begründen sind. Dort, wo abnehmende Trends simuliert werden, liegt demnach eine Verringerung der Koinzidenz von Frost und temperaturdefinierter Vegetationsperiode vor.

7.3.3.1 Exkurs: Auswirkungen des Spätfrostereignisses im Mai 2020

Eine informelle Umfrage unter den am Projekt *BigData@Geo* beteiligten KMU zeigt eine hohe Betroffenheit hinsichtlich des Spätfrostereignisses am 12. Mai 2020 (fortgeschrittene phänologische Entwicklung). Im Weinbau waren je nach Lage Verluste von bis zu 100 % zu verzeichnen, im Obstbau je nach Fruchtart ebenfalls bis zu 90 %. Im Forst wurden Schäden teilweise durch späteres Nachwachsen neuer Blätter verhindert, es kam jedoch auch zum Absterben von Jungpflanzen. Im Ackerbau gab es zum Teil keine Schäden, ein Unternehmen beklagt jedoch

Ertragsverluste von 20–40 % bei der Wintergerste. Topographisch betroffen waren Senken- und Talbereiche, aber auch Plateau- und Hanglagen, wobei freie Flächen im Vergleich zu geschützteren Bereichen im Nachteil waren. Als wichtiger Faktor für die große Schadwirkung wurde von Seiten der Weinbetriebe der Regen im Vorfeld der Frostnacht genannt, sodass die starke Feuchtigkeit der Pflanzen die Frostwirkung verstärkte. Im Bereich Obstbau wurden hohe Windgeschwindigkeit sowie eine Schwächung der Bäume aufgrund der Trockenheit des Vorjahres als zusätzliche negative Faktoren genannt.

7.3.3.2 Implikationen der projizierten klimatischen Veränderungen

Da die Wasserbilanz in einem Großteil des Untersuchungsgebietes schon heute nur schwach positiv ist (MÜLLER 1996; DWD 2021c,b; vgl. Kapitel 2.1), implizieren die Projektionen eine Verstärkung der Wassermangelproblematik, insbesondere im Sommer. Die bereits genannten Anpassungsmaßnahmen (Abschnitt 7.1.5, z.B. Bewirtschaftungstechniken, Terminierung, Fruchtfolge, Art- und Sortenwahl) können hierbei helfen, den landwirtschaftlichen Bewässerungsbedarf so gering wie möglich zu halten. Ist dieser dennoch vorhanden, so müssen möglichst effiziente Bewässerungstechniken genutzt werden, um Wassernutzungskonflikte zu verringern. Landwirtschaftliche Bewässerung von max. 1 ha oder $50 \frac{m^3}{d}$ bedarf zwar keiner Genehmigung, bei zu niedrigen Wasserständen und/oder zu hohen Entnahmen kann die Entnahme jedoch behördlich reguliert werden (LFU 2016). Das Maindreieck sowie das Mittelfränkische Becken gehören bereits heute zu den bayerischen Gebieten mit der größten landwirtschaftlichen Bewässerung (LFU 2023, 2016). Auch in der Forstwirtschaft sind in Vorbereitung auf trockenere Verhältnisse umfassende Anpassungen notwendig, allem voran die Abkehr von intensiven Fichtenmonokulturen hin zu extensiv bewirtschafteten, artenreichen und klimatisch angepassten Mischwäldern (vgl. Abschnitt 7.1.7.4). Bei der Wahl von Sorten bzw. Arten sowie Bewirtschaftungsmaßnahmen sollte die unsichere Erkenntnislage hinsichtlich des Spätfrostrisikos miteinbezogen werden.

7.3.4 Zukünftige Ertragsprojektionen

Sowohl die Beobachtungsdaten der Vergangenheit als auch die Simulationen aller betrachteten Modelle zeigen hinsichtlich des regionalen Durchschnittswertes in Richtung zunehmender Winterroggen und -weizenerträge (siehe Abbildung 7.5). Die zukünftigen Trends der Sommer-

gerstenerträge (negativ) widersprechen den in der Vergangenheit beobachteten. Für die übrigen betrachteten Feldfrüchte liegen die Trends der dokumentierten Erträge außerhalb des Signifikanzbereichs (Hafer-, Silomais+, Wintergerste+). Die Erträge aller Frankenweinklassen sind in den letzten Jahrzehnten gesunken, gleiches wird nur für den Rotwein von allen Modellen des verwendeten Ensembles auch für die Zukunft projiziert.

7.3.4.1 Landwirtschaft

Die positivere Entwicklung der Winterfeldfrüchtererträge stimmt damit überein, dass deren Trockenheitsanfälligkeit aufgrund der vorwinterlichen Aussaat und früheren Ernte geringer ist als die von Sommerkulturen (WEBBER *et al.* 2018; TRAPP *et al.* 2013a; DIEPENBROCK *et al.* 2012; SCHALLER & WEIGEL 2007). Die Stärke der Trends (im regionalen Mittel) der Sommergetreidesorten entspricht jedoch nicht den Aussagen von CHMIELEWSKI & KÖHN (1999) hinsichtlich der klimatischen Beeinflussbarkeit (Mais > Hafer > Sommergerste, Trendstärke umgekehrte Reihenfolge). Allerdings lassen sich die Erkenntnisse kontrollierter Feldexperimente in Berlin nicht uneingeschränkt auf die unterfränkischen Anbaubedingungen übertragen. Die Maisertragsabnahme kann auf seinen sommerlichen Wasserbedarf zurückzuführen sein, Hafer bevorzugt generell kühleres und feuchteres Klima (DIEPENBROCK *et al.* 2012; SCHALLER & WEIGEL 2007). Die geringere Trockenheitsanfälligkeit von Wintergerste im Vergleich zu -weizen (DIEPENBROCK *et al.* 2012) kann, unter Annahme generell trockenerer Bedingungen, ein Grund für die stärker positiven Trends in den REMO- und HIRHAM-Projektionen sein.

Im Vergleich mit anderen (prozessbasierten wie auch statistischen) Modellstudien (vgl. Abschnitt 7.1.4.3) zeigen sich Übereinstimmungen der Entwicklungstendenz im Bezug auf Silomais (Deutschland PEICHL *et al.* 2019; Körnermais Europa auch WEBBER *et al.* 2018). Für Winterweizen (hier positiv) ist die Studienlage nicht eindeutig, die Ergebnisse zeigen teilweise in die gleiche (KERSEBAUM & NENDEL 2014; WEBBER *et al.* 2018), teilweise in entgegengesetzte (DONATELLI *et al.* 2015; MOORE & LOBELL 2014) Richtung. In allen Fällen beziehen sich die genannten Ergebnisse der Literatur aber auf größere räumliche Einheiten.

Die in der Literatur zum Teil genannten negativen Entwicklungstendenzen für Winterweizen könnten auf mangelnde Abhärtung und Vernalisation durch zu warme Wintertemperaturen (vgl. GÖMANN *et al.* 2017; SCHALLER & WEIGEL 2007) zurückzuführen sein. Da dies in der Vergangenheit kaum oder nicht vorkam, können die entsprechenden Beziehungen in den Transferfunktionen dieser Arbeit nicht wiedergespiegelt werden. Die Transferfunktionen basieren auf

vergangenen Bedingungen. Ihre Gültigkeit (Stationarität) wurde zwar durch Kreuzvalidierung überprüft und bestätigt, aber dennoch können in der Vergangenheit nicht aufgetretene Bedingungen in den Modellen nicht abgebildet werden. Gleiches gilt etwa für den Schädlingsbefallsdruck.

Zusätzlich sind mögliche anthropogene Einflussfaktoren nicht außer Acht zu lassen (vgl. Abschnitt 7.1.2). Eine Reaktion auf diese Projektionen könnte, neben der oben angesprochenen Bewässerung, im verstärkten Anbau von Winterfeldfrüchten sowie der Wahl trocken- und hitzeresistenter Sorten und Ökotypen liegen (vgl. Abschnitt 7.1.5).

7.3.4.2 Frankenwein

Wie aus den Ausführungen in Abschnitt 7.1.6 ersichtlich wird, ist von einem Verlust der Anbaueignung der traditionellen Frankenweinsorten auszugehen.

Für Franken, wie für das gesamte Europa nördlich der Alpen, wird von FRAGA *et al.* (2016a) eine Zunahme der Weinerträge unter Annahme der Rebsorte Spätburgunder simuliert (vgl. Abschnitt 7.1.6.1). Auch wenn diese Rebsorte hinsichtlich der Anteils an den Rotweinanbauflächen in den letzten Jahren von der Rebsorte Domina übertroffen wurde, hat sich die Anbaufläche in den letzten Jahrzehnten deutlich gesteigert (103 ha 1989/90 zu 273 ha 2021 (DESTATIS 1996, 2022)). Nichtsdestotrotz liegt ihr Anteil an der gesamten Frankenweinanbaufläche weiterhin bei unter 5 % (2021 4,4 % (DESTATIS 2022)), weshalb die Untersuchungen auf Basis des Spätburgunders nicht auf den gesamten Frankenwein verallgemeinert werden können.

Was bedeutet dies für die – zum Teil widersprüchlichen – Ergebnisse der MOS-Weinertragssimulationen (positive Trends der Gesamterträge und negative Trends der Rotweinerträge durch jeweils alle vier verwendeten Modelle sowie gegensätzliche Tendenzen von je zwei Modellen für die Weißweinerträge)?

Zum Einen beziehen sich die Transferfunktionen auf die Erträge – und somit die angebauten Rebsorten – des Zeitraums der Referenzdaten. Inwiefern die Beziehungen auf andere Rebsorten übertragbar sind, lässt sich somit nicht sagen, ist jedoch aufgrund der erwarteten Eignungsentwicklung von hoher Relevanz. Negative Trends können auch bedeuten, dass die bisher angebauten Sorten an Eignung verlieren, schließen jedoch Ertragssteigerungen im Bezug auf andere Sorten nicht aus. Hinzu kommt die geringe Anzahl der Referenzjahre für die Aufstellung der Transferfunktion (11 bzw. 12 Jahre Kalibrierung + 4 Jahre Validierung für das Modelltrai-

ning), was eine robuste Beziehungscharakterisierung erschwert (trotz der guten Ergebnisse im Kontrollzeitraum). Ebenfalls nicht außer Acht zu lassen ist der potenziell große Einfluss von Bewirtschaftungsmaßnahmen auf die Höhe der Weinernte (vgl. z.B. BOCK *et al.* 2013; HOPPMANN *et al.* 2010; JONES & DAVIS 2000; JONES *et al.* 2005; VAN LEEUWEN & DARRIET 2016; SCHULTZ 2016), welche mit dem Ziel höherer Qualität auch eine gezielte Verringerung der Ertragshöhe implizieren können (vgl. z.B. SCHWAB *et al.* 2004).

Die gegensätzlichen Ergebnisse im MME hinsichtlich der Weißweinerträge könnten darauf zurückzuführen sein, dass Temperatur (-mittel, -minimum, -maximum) nicht explizit in die Modellierung eingeht. Die Kombination aus jeweils bestimmten Aspekten der großräumigen Variabilität von Bodenfeuchte, Niederschlag, Luftdruck und Windkomponenten fällt also beim gleichen Szenario in den vier verwendeten Modellen unterschiedlich aus. Die Vorzeichen der Rot- und Gesamtweintrends, deren Simulationen Temperaturaspekte⁷¹ berücksichtigen, hingegen sind bei allen betrachteten Modellen gleich.

Unabhängig von der projizierten Richtung der Ertragsentwicklungen, sagen diese nichts über die Güte der Weine aus. Gerade hinsichtlich des auf Qualität ausgerichteten Frankenweins (vgl. SCHENK 2007) ist diese jedoch von hoher Relevanz. Auf mögliche Anpassungsmaßnahmen wird in den Abschnitten 7.1.5 sowie 7.1.6.1 eingegangen.

7.3.5 Limitationen

Zunächst kann die Wahl der verwendeten Kennwerte Einfluss auf die Aussagen über die Veränderung der verschiedenen klimatischen Extremereignisse haben. Ein alternativer Ansatz hierzu ist die Nutzung von Extremwertverteilungen, wie etwa in den Arbeiten von PAETH *et al.* (2015), CONTZEN *et al.* (2023) oder FURRER *et al.* (2010). Zur besseren Anschaulichkeit für die Praxispartner aus Land-, Forstwirtschaft und Weinbau werden in dieser Arbeit jedoch allgemein verständliche Indizes genutzt, deren Daseinsberechtigung durch eine breite Nutzung in der Klimaforschung belegt wird (vgl. Abschnitt 2.3).

⁷¹Rotwein jeweils zwei Hauptkomponenten der Minimum- und Maximumtemperatur, Gesamtwein eine Hauptkomponente der Minimumtemperatur und zudem Prädiktoren der Variablen Verdunstung, latente sowie sensible Wärmeflüsse, die ebenfalls großen thermischen Bezug besitzen. Alle drei Transferfunktionen enthalten je einen Bodenfeuchte-PC-Prädiktor.

Aufgrund mangelnder Länge der Beobachtungsdaten ist keine unabhängige Validierung der REMO-ESM-Model Output Statistics für die Erträge aus Landwirtschaft und Weinbau möglich. Die Verwendung zur Untersuchung der projizierten Zukunftsentwicklung basiert also auf der Annahme, dass die hohe Modellgüte im Bezug auf die REMO-Eval-Daten in Kombination mit der Datenanpassung der REMO-ESM-Daten vor Anwendung der Transferfunktion, verlässliche Zukunftsaussagen ermöglicht. Dies ist gerade im Bezug auf die Frankenweinerträge mit einem sehr kurzen Beobachtungsdatensatz nicht unproblematisch.

Durch die Verwendung monatlicher Prädiktoren verschiedener atmosphärischer und boden-naher Variablen werden nur die mittleren Zustände je Monat repräsentiert⁷². Extremzustände auf täglicher oder noch detaillierterer Zeitaufösung gehen somit nicht in die Simulationen ein. Ebenso ist die Wirkung meteorologischer Begebenheiten auf bestimmte, mitunter kurze, pflanzliche Entwicklungsstadien nicht abgebildet (vgl. LISCHIED *et al.* 2022). Andere Studien verwenden Extremindizes als Prädiktoren für die Ertragssimulation (z.B. VOGEL *et al.* 2019, 2021). Da Extrema aufgrund ihrer hohen Komplexität von den Klimamodellen oft unzureichend gut simuliert werden (s.o., vgl. z.B. FLATO *et al.* 2013; HERRERA *et al.* 2010; KJELLSTRÖM *et al.* 2007) und sich dies auf die Konstanz ihrer Beziehungen zu anderen Größen auswirken kann, wird hiervon Abstand genommen.

Die Anwendung von Transferfunktionen auf Zukunftsprojektionen setzt immer die Annahme stationärer Prädiktor-Prädiktand-Beziehungen voraus (TEUTSCHBEIN & SEIBERT 2012; IVANOV *et al.* 2018; KEUPP *et al.* 2019; PAETH 2011; MARAUN & WIDMANN 2018). Um dies zu rechtfertigen, wird in dieser Arbeit eine zufallsbasierte Kreuzvalidierung durchgeführt. Nichtsdestotrotz können zukünftige Entwicklungen zu unvorhersehbaren Veränderungen im Prädiktor-Prädiktand-Gefüge führen. Dies gilt nicht nur für die MOS-Modelle zur Simulation von klimatischen Kennwerten und Erträgen, sondern auch für die Biaskorrekturfunktionen zur Anpassung der Werte an die Beobachtungsdaten der Vergangenheit. Da jedoch keine gesicherten Kenntnisse der Zukunft möglich sind, ist der Bezug auf Gegebenheiten der Vergangenheit die einzige Möglichkeit, Korrekturen und Simulationen durchzuführen.

Ein weiterer limitierender Aspekt ist die Abhängigkeit der Evaluierungs-, Korrektur- und Simulationsergebnisse von den Referenzdaten (DOBLAS-REYES *et al.* 2021; MARAUN & WIDMANN 2018). Die flächendeckende Aufbereitung punktueller Beobachtungsdaten beinhaltet

⁷²Minimum- und Maximumtemperatur entsprechen jeweils dem monatlichen Durchschnitt der täglichen Extreme.

immer eine Interpolation und ist so von Unsicherheiten begleitet, wobei die Ergebnisse von der jeweiligen verwendeten Methode abhängen (ALEXANDER 2016; MARAUN & WIDMANN 2018). Die Interpolationsmethoden der hier verwendeten Daten sind in Abschnitt 3.1.1 beschrieben. Beim Vergleich verschiedener globaler gegrideter Beobachtungsdatensätze finden DONAT *et al.* (2014) eine höhere Einigkeit im Bezug auf Temperatur als auf Niederschlag, wobei auch für letzteren die Ergebnisse im annehmbaren Rahmen bleiben. Die Extreme ähneln sich für die Temperatur sehr, für den Niederschlag weniger. Zu den Interpolationsmethoden kommen noch die Unsicherheiten der unterliegenden Stationsdaten sowie die interne Variabilität (Beobachtungen und Modelle), welche die Evaluierung, Korrektur und Simulation erschweren (DOBLAS-REYES *et al.* 2021). Laut GÓMEZ-NAVARRO *et al.* (2012) belaufen sich die Unsicherheiten beispielsweise für Spanien mit einer guten Klimastationsabdeckung innerhalb der Größenordnung derer von Reanalyse-getriebenen RCMs. Hieraus lässt sich die Problematik der Korrektur auf Basis eben dieser Beobachtungsdaten erkennen.

Exkurs: Daten DWD vs. E-OBS Wie in Abschnitt 3.1.1 genannt, werden für den DMI Beobachtungsdaten des Deutschen Wetterdienstes, für die anderen Indizes (aufgrund mangelnder Verfügbarkeit täglicher Daten) E-OBS-Daten genutzt. Es ist daher sinnvoll, einen Vergleich der beiden Datensätze vorzunehmen⁷³. Der prozentuale Mittelwertbias (Standardabweichungsbias) von E-OBS im Vergleich zu DWD liegt im regionalen Mittel aller Monate zwischen -1,3 und -3,5 % (-2,0–2,5 %), wobei die Werte im Raum zwischen -33,5 und 34,4 % (-31,9–44,9 %) abweichen. Der prozentuale QRMSE beträgt im monatlichen Raumdurchschnitt 6,4–8,4 % (räumlich aufgelöst 1,6–39,2 %). Der Produkt-Moment-Korrelationskoeffizient der regionalen Mittelwerte beläuft sich in allen Monaten auf mindestens 0,99. Für die regionalen Minima und Maxima gilt mit einer Ausnahme (regionales Maximum Januar $r_p = 0,84$) $r_p \geq 0,93$. Obwohl die Daten des DWD als nationale Stationsdaten Eingang in die Basis des E-OBS-Datensatzes finden, existieren also vor allem bei räumlicher Betrachtung durchaus Unterschiede. Wie bereits erwähnt, können diese auf die verschiedenen Interpolationsmethoden zurückzuführen sein. Im regionalen Durchschnitt sind die Abweichungen deutlich geringer.

⁷³Zeitraum 1951–2012 als Kombination der Zeiträume der Biaskorrektur und von MOS-REMO-Eval

8 Schlussfolgerungen und Ausblick

Der Titel und das übergeordnete Ziel der vorliegenden Arbeit ist die **hochaufgelöste Erfassung zukünftiger Klimarisiken für Land- und Forstwirtschaft in Unterfranken**. Sie soll nun anhand der eingangs formulierten Teilziele (vgl. Abschnitt 1.3) zusammengefasst und bewertet werden.

Ein erster wichtiger Schritt ist die **Herausarbeitung relevanter klimatischer Kenngrößen für Land-, Forstwirtschaft sowie Weinbau in Unterfranken**. Da die Ergebnisse möglichst praxisrelevant für die jeweiligen Betriebe in der Region sein sollen, basiert die Auswahl der zu untersuchenden klimatischen Zielgrößen auf einer Umfrage unter den im Projekt *BigData@Geo* beteiligten kleinen und mittelständigen Partnerunternehmen. Die am häufigsten genannten klimatischen Ereignisse werden in monatlicher Auflösung durch folgende Kennwerte repräsentiert: Drei Trockenheitsindizes (Anzahl der Trockentage R1mmn, maximale Anzahl konsekutiver Trockentage MCD, De Martonne-Index DMI), je ein Starkniederschlags- (Anzahl der Tage mit Niederschlag über dem 95. Perzentil der Referenzperiode R95n) und Hitzekennwert (Anzahl der heißen Tage) sowie zwei Frostindizes (Anzahl der Frost- und der Eistage). Hinzu kommen jährlich aufgelöste Spätfrostkennwerte gemäß der monatsdefinierten sowie temperaturdefinierten Vegetationsperiode.

Hieran schließt sich die **Güteabschätzung von regionalen Klimamodelldaten hinsichtlich dieser Größen** an. Genutzt wird das im Projekt *BigData@Geo* weiterentwickelte regionale Klimamodell (RCM) REMO mit Antrieb durch das globale Klimamodell (GCM) MPI-ESM-LR. Die Modellvalidierung erfolgt für die Vergangenheit hinsichtlich Mittelwert, Standardabweichung sowie Verteilung im Vergleich zu Beobachtungsdaten. Hierbei werden Defizite hinsichtlich der Trockenheits- und Starkniederschlagsrepräsentation sichtbar (zu feucht). Zudem wird die Häufigkeit von (Spät-)Frost- und Hitze- unter-, die von Eistagen jedoch überschätzt. Höhere Lagen, insbesondere für DMI und R95n, weisen häufig gegensätzliche Fehlerrichtungen auf. Auch hinsichtlich der Standardabweichung zeigen sich Schwachstellen des Modells, die je nach Index und Höhenlage unterschiedlich ausfallen können. Die Verteilung der Beobachtungsdaten wird für R1mmn, MCD und DMI am besten simuliert, für die Temperaturkenntage

sind die Abweichungen deutlich höher. Verallgemeinert ergibt sich eine Tendenz zu besserer Modellqualität in höheren Höhenlagen.

Daher ist eine Anpassung der Daten vor ihrer weiteren Verwendung sinnvoll. Hierzu dient **die Korrektur vorhandener systematischer Fehler und die statistische Simulation durch unterschiedliche Methoden**. Diese beiden Ansätze werden jeweils kreuzvalidiert durchgeführt. Sie unterscheiden sich insofern, als dass bei der Biaskorrektur die Zielgrößen gemäß ihrer Definition aus Modelldaten berechnet und anschließend hinsichtlich bestimmter statistischer Aspekte an die Beobachtungsdaten angepasst werden. Zwei Korrekturvarianten beziehen sich hierbei ausschließlich auf den Mittelwert (additive und multiplikative Linearskalierung), zwei weitere hingegen bewirken eine Verteilungskorrektur anhand empirischer Quantile (QM11) bzw. unter Annahme einer parametrischen Verteilung (PMPE). Im Gegensatz hierzu werden bei der Simulation im Rahmen der Model Output Statistics (MOS) die Kennwerte nicht aus den Modelldaten berechnet, sondern lokale und großräumige atmosphärische Variablen des Modells dienen als Prädiktoren für eine statistische Transferfunktion. Diese wird jeweils in mehreren Varianten aufgestellt, basierend auf Multipler Linearer Regression (MLR) sowie auf Generalisierten Linearen Modellen (GLM) in verschiedenen Ausführungen. Im Gegensatz zur Biaskorrektur erfordern die MOS-Verfahren eine zeitliche Übereinstimmung der Beobachtungs- und Modelldaten, da der beobachtete Prädiktand (klimatischer Kennwert) an einem bestimmten Zeitpunkt durch die Modellprädiktoren simuliert wird. Dies wird durch die Verwendung Reanalyse-angetriebener Daten (REMO-Eval) für die Aufstellung der Transferfunktion erreicht. Im Anschluss werden GCM-angetriebene REMO-Daten hinsichtlich ihrer statistischen Eigenschaften an die REMO-Eval Daten angepasst (QM11) und hierauf die Transferfunktion angewandt. Diese MOS-Anwendung auf GCM-angetriebene RCM-Daten stellt eine Neuerung dar und besitzt explorativen Charakter.

Ein **Vergleich der Methoden hinsichtlich des Korrektur- bzw. Simulationserfolges** offenbart die besten Ergebnisse für die beiden verteilungsbasierten Biaskorrekturen. Für keinen Monat oder Index sind Mittelwertkorrekturen oder eine der MOS-Simulationen besser geeignet. Die schlechtere Performance von LS und LSM ist gemäß ihrer Definition (Mittelwert- statt Verteilungsanpassung) naheliegend und wurde durch viele Studien bestätigt. Gründe für das schlechte Abschneiden der MOS-Verfahren könnten u.a. die Komplexität der betrachteten klimatischen Kennwerte sowie die Analyse in hoher räumlicher Auflösung sein.

Im regionalen Durchschnitt zeigt die **Analyse der projizierten Zukunftsentwicklung der Zielgrößen mithilfe der jeweils besten Methode** für das 21. Jahrhundert signifikante Abnahmen von Frost- und Eistagehäufigkeit sowie signifikante Zunahmen der Hitzetageanzahl. Ebenso wird auf Basis von R1mmn, MCD und DMI eine Verstärkung der sommerlichen Trockenheit projiziert. Die Häufigkeit der Starkniederschlagsereignisse steigt im Winter(halbjahr). Für den Spätfrost ergibt sich bei monatlich definierter Vegetationsperiode (VPM) ein deutlicher Rückgang (alle Gitterzellen). Bei thermischer Abgrenzung (VPT) ist die Gesamttendenz leicht negativ, jedoch durch räumliche Gegensätze geprägt. Bei Hinzunahme zwei weiterer RCMs werden die Ergebnisse grundsätzlich bestätigt, nur für den VPT-Spätfrost weisen die regionalen Mittelwerte der beiden anderen Modelle in Richtung steigender Häufigkeit, eines resultiert an allen Gitterzellen in positiven Trends.

Die Verringerung der Eis-, Frost- sowie Erhöhung der Hitzetagehäufigkeit entspricht der erwarteten Entwicklungen im Rahmen eines allgemeinen Temperaturanstieges. Letztgenannte ist insbesondere dann für die Land- und Forstwirtschaft problematisch, wenn – wie die Projektionen hier ergeben – gleichzeitig eine Zunahme der Trockentagehäufigkeit und -periodenlänge auftritt. Das Zusammenspiel aus Temperatur- und Niederschlagsdurchschnittswerten wird im DMI widerspiegelt, für den weite Teile Unterfrankens am Ende des 21. Jahrhunderts von Juni bis September außerhalb der humiden Klassen liegen.

Bei der MOS-basierten **Simulation von Ertragszahlen aus Acker- und Weinbau** werden unter Verwendung der REMO-Eval Daten deutlich bessere Ergebnisse erzielt als bei der Simulation der klimatischen Kennwerte. Eine unabhängige Validierung der GCM-angetriebenen REMO-Daten ist aufgrund zu kurzer Referenzzeitreihen nicht möglich, die Modelle basieren je nach Frucht und Landkreis auf MLR oder GLM mit verschiedenen Optionen. Die Zukunftsprojektionen der untersuchten Ackerfruchterträge weisen trotz Gegensätzen in den unterfränkischen Landkreisen im Mittel in Richtung Zunahmen der Winter- und Abnahmen der Sommerfeldfrüchte (REMO und drei weitere RCMs). Dies steht im Einklang mit den Erwartungen im Bezug auf die bereits beschriebene Trockenheitsverstärkung, da Winterfeldfrüchte von winterlicher Feuchtigkeit profitieren können und durch die frühere Ernte im Jahr weniger von sommerlicher Trockenheit und Hitze betroffen sind. Nichtsdestotrotz sind in der Vergangenheit nicht aufgetretene Extreme (sehr starke Hitze, mangelnder Kältereiz im Winter) mitunter nicht durch die MOS-Modelle abgebildet und auch anthropogene Eingriffe gehen nicht in die Simulationen ein.

Die für die Vergangenheit auf REMO-Eval-Basis sehr hohe Simulationsqualität aufweisenden Modelle für Weiß-, Rot- und Gesamtweinerträge des Frankenweingebietes ergeben für Rot- und Weißwein negative, für den Gesamtwein jedoch positive Trends im 21. Jahrhundert. Dies gilt für REMO sowie ein weiteres untersuchtes RCM, zwei andere jedoch zeigen für den Weißwein in positive Richtung. Die unabhängige Modellierung der drei Weinklassen resultiert somit für die Hälfte der RCMs in Ergebnissen, die nicht miteinander vereinbar sind. Problematisch bei der Analyse der Frankenweinerträge sind die hohen Unterschiede der verschiedenen Rebsorten hinsichtlich ihrer klimatischen Ansprüche. Es ist generell von einem Verlust der Anbaueignung traditioneller Rebsorten wie z.B. dem Silvaner auszugehen. Die genutzten Transferfunktionen basieren jedoch auf den Rebsorten der Vergangenheit. Hinzu kommt der starke anthropogene Einfluss auf die Erntemengen, welche zur Qualitätssteigerung bewusst reguliert werden.

Auch wenn Erträge der Forstwirtschaft in dieser Arbeit nicht direkt untersucht werden, sind die vorgestellten Ergebnisse dennoch von hoher Relevanz für diesen Sektor sowie die gesamte Landwirtschaft. Die Projektionen zeigen, dass sich die ohnehin in großen Teilen Unterfrankens vorhandene Trockenheit in Zukunft weiter verstärken wird. Hinzu kommt eine höhere Hitzetagehäufigkeit sowie eine trotz selteneren Frostauftretens unsichere Tendenz im Bezug auf die Spätfrosthäufigkeit (bzgl. thermisch definierter Vegetationsperiode). Hieraus ist eine Notwendigkeit von Anpassungsmaßnahmen in Land- und Forstwirtschaft abzuleiten. Diese reichen von veränderten Bewirtschaftungsmaßnahmen über Bodenbedeckung bis hin zum Anbau trockenheits- und hitzeangepasster Arten, Sorten und Herkünfte. Gerade für die Forstwirtschaft ist der umfassende Waldumbau weg von Fichtenmonokulturen hin zu artenreichen klimaresilienten Mischwäldern von entscheidender Relevanz. Doch gerade bei erwarteter Wasserknappheit muss auch in der Landwirtschaft durch angepasste Bewirtschaftung und Pflanzenwahl der Bewässerungsbedarf so gering wie möglich gehalten werden.

Die Defizite hinsichtlich der MOS-Simulationsqualität der klimatischen Kennwerte sowie die Widersprüche zwischen einigen Zukunftsprojektionen (Spätfrost VPT, Frankenwein) weisen auf die hohe Komplexität der hier betrachteten Thematiken hin. Der Einbezug zusätzlicher oder anderer Prädiktoren sowie die Verwendung alternativer Regressionsverfahren könnten hierbei zur Problemlösung oder -analyse beitragen. Allgemein ist die hier vorgestellte Verwendung von Model Output Statistics als neuer, explorativer Ansatz zu sehen, dessen Potenzial es weiter zu ergründen gilt.

Die Land- und Forstwirtschaft in Unterfranken sieht einer herausfordernden Zukunft entgegen. Diese Arbeit soll eine Hilfestellung für die Vorbereitung darauf sein. Hierbei besteht die Hoffnung, dass getätigte Anpassungsmaßnahmen nicht nur ökonomische Verluste vermeiden, sondern auch positive Nebeneffekte für Biodiversität, Boden und den Wasserhaushalt erzielen können.

Literatur

- ABEL, D., F. POLLINGER, K. ZIEGLER & H. PAETH (2020): Extension of the regional climate model REMO by a 5-layer soil scheme. EGU General Assembly 2020, Online, 4–8 May 2020, EGU2020-2964. DOI: 10.5194/EGUSPHERE-EGU2020-2964.
- ABEL, D., K. ZIEGLER, F. POLLINGER & H. PAETH (2021): Comparison of different infiltration schemes in the regional climate model REMO. EGU General Assembly 2021, online, 19–30 Apr 2021, EGU21-9874. DOI: 10.5194/EGUSPHERE-EGU21-9874.
- ABEL, D. K.-J. (2023): Weiterentwicklung der Bodenhydrologie des regionalen Klimamodells REMO. Dissertation. Würzburg: Julius-Maximilians-Universität. DOI: 10.25972/OPUS-31146.
- AKAIKE, H. (1974): A New Look at the Statistical Model Identification. – IEEE Transactions on Automatic Control AC-19, 6, 716–723.
- AKHTAR, N., J. BRAUCH & B. AHRENS (2018): Climate modeling over the Mediterranean Sea: impact of resolution and ocean coupling. – Climate Dynamics 51, 3, 933–948. DOI: 10.1007/S00382-017-3570-8.
- ALBERT, M., R. V. NAGEL, J. SUTMÖLLER & M. SCHMIDT (2018): Quantifying the effect of persistent dryer climates on forest productivity and implications for forest planning: A case study in northern Germany. – Forest Ecosystems 5, 1, 1–21. DOI: 10.1186/S40663-018-0152-0.
- ALEXANDER, L. V. (2016): Global observed long-term changes in temperature and precipitation extremes: A review of progress and limitations in IPCC assessments and beyond. – Weather and Climate Extremes DOI: 10.1016/j.wace.2015.10.007.
- ALMAZROUI, M., F. SAEED, S. SAEED, M. ISMAIL, M. A. EHSAN, M. N. ISLAM, M. A. ABID, E. O'BRIEN, S. KAMIL, I. U. RASHID & I. NADEEM (2021): Projected Changes in Climate Extremes Using CMIP6 Simulations Over SREX Regions. – Earth Systems and Environment 5, 3, 481–497. DOI: 10.1007/S41748-021-00250-5.

- ASSENG, S., P. MARTRE, A. MAIORANO, R. P. RÖTTER, G. J. O'LEARY, G. J. FITZGERALD, C. GIROUSSE, R. MOTZO, F. GIUNTA, M. A. BABAR, M. P. REYNOLDS, A. M. KHEIR, P. J. THORBURN, K. WAHA, A. C. RUANE, P. K. AGGARWAL, M. AHMED, J. BALKOVIČ, B. BASSO, C. BIERNATH, M. BINDI, D. CAMMARANO, A. J. CHALLINOR, G. D. SANCTIS, B. DUMONT, E. E. REZAEI, E. FERERES, R. FERRISE, M. GARCIA-VILA, S. GAYLER, Y. GAO, H. HORAN, G. HOOGENBOOM, R. C. IZAURRALDE, M. JABLON, C. D. JONES, B. T. KASSIE, K. C. KERSEBAUM, C. KLEIN, A. K. KOEHLER, B. LIU, S. MINOLI, M. M. S. MARTIN, C. MÜLLER, S. N. KUMAR, C. NENDEL, J. E. OLESEN, T. PALOSUO, J. R. PORTER, E. PRIESACK, D. RIPOCHE, M. A. SEMENOV, C. STÖCKLE, P. STRATONOVITCH, T. STRECK, I. SUPIT, F. TAO, M. V. DER VELDE, D. WALLACH, E. WANG, H. WEBBER, J. WOLF, L. XIAO, Z. ZHANG, Z. ZHAO, Y. ZHU & F. EWERT (2019): Climate change impact and adaptation for wheat protein. – *Global Change Biology* 25, 1, 155–173. DOI: 10.1111/GCB.14481.
- AWOYE, O., F. POLLINGER, E. AGBOSSOU & H. PAETH (2017): Dynamical-statistical projections of the climate change impact on agricultural production in Benin by means of a cross-validated linear model combined with Bayesian statistics. – *Agricultural and Forest Meteorology* 234-235, 80–94. DOI: 10.1016/J.AGRFORMET.2016.12.010.
- BALTAS, E. (2007): Spatial distribution of climatic indices in northern Greece. – *Meteorological Applications* 14, 1, 69–78. DOI: 10.1002/MET.7.
- BARLOW, K. M., B. P. CHRISTY, G. J. O'LEARY, P. A. RIFFKIN & J. G. NUTTALL (2015): Simulating the impact of extreme heat and frost events on wheat crop production: A review. – *Field Crops Research* 171, Supplement C, 109–119. DOI: 10.1016/j.fcr.2014.11.010.
- BARNABÁS, B., K. JÄGER & A. FEHÉR (2008): The effect of drought and heat stress on reproductive processes in cereals. – *Plant, Cell & Environment* 31, 1, 11–38. DOI: 10.1111/J.1365-3040.2007.01727.X.
- BATTAGLINI, A., G. BARBEAU, M. BINDI & F. W. BADECK (2009): European winegrowers' perceptions of climate change impact and options for adaptation. – *Regional Environmental Change* 9, 2, 61–73. DOI: 10.1007/S10113-008-0053-9.
- BAUMHAUER, R. (2007a): Die geologische und tektonische Entwicklung Deutschlands. In: GLASER, R., H. GEBHARDT & W. SCHENK (Hrsg.): *Geographie Deutschlands*. Darmstadt: Wissenschaftliche Buchgesellschaft, 99–107.

- BAUMHAUER, R. (2007b): Von der Küste zum Hochgebirge – Reliefentwicklung. In: GLASER, R., H. GEBHARDT & W. SCHENK (Hrsg.): Geographie Deutschlands. Darmstadt: Wissenschaftliche Buchgesellschaft, 107–116.
- BAYERISCHE LANDESANSTALT FÜR LAND- UND FORSTWIRTSCHAFT (LWF) (2012): Die Bundeswaldinventur 2012 für Bayern. Waldfläche (insgesamt) nach Baumartengruppen (Bayern und Regierungsbezirke). Unterfranken. <<https://www.lwf.bayern.de/bwi/101520/index.php>>. (Stand: 2012) (Zugriff: 2022-05-16).
- BAYERISCHES LANDESAMT FÜR STATISTIK (LFSTAT) (2020a): Ausgewählte Fruchtarten Getreide. Durchschnittlicher Hektarertrag. Kreise. (Stand: 14.12.2020). Fürth: Bayerisches Landesamt für Statistik.
- BAYERISCHES LANDESAMT FÜR STATISTIK (LFSTAT) (2020b): Hülsen-, Hackfrücker, Futterpflanzen, Handelsgewächse. Durchschnittlicher Hektarertrag. Kreise. (Stand: 14.12.2020). Fürth: Bayerisches Landesamt für Statistik.
- BAYERISCHES LANDESAMT FÜR STATISTIK (LFSTAT) (2022): Flächenerhebung nach Art der tatsächlichen Nutzung (ALKIS). 31.12.2020 (Stand: 17.01.2022). Fürth: Bayerisches Landesamt für Statistik.
- BAYERISCHES LANDESAMT FÜR STATISTIK (LFSTAT) (2023): Landwirtschaft: Kreise, Anbau auf dem Ackerland, Fruchtarten, Jahr. Unterfranken. Berichtsjahr 2016. (Stand: 10.01.2023). Fürth: Bayerisches Landesamt für Statistik.
- BAYERISCHES LANDESAMT FÜR UMWELT (LFU) (2016): Niedrigwasser in Bayern. Grundlagen, Veränderung und Auswirkungen. Augsburg: LfU.
- BAYERISCHES LANDESAMT FÜR UMWELT (LFU) (2023): Wasserentnahmen für die Bewässerung. <<https://www.lfu.bayern.de/wasser/bewaesserung/index.htm>>. (Stand: 2022) (Zugriff: 2023-02-23).
- BAYERISCHES LANDESAMT FÜR UMWELT (LFU) (o.J.): Karte der Naturraum-Haupteinheiten und Naturraum-Einheiten in Bayern. Augsburg: LfU.
- BAYERISCHES STAATSMINISTERIUM FÜR ERNÄHRUNG, LANDWIRTSCHAFT UND FORSTEN (STMELF) (2011): Franken. Qualitätswein, Prädikatswein, Sekt b.A. und Qualitätsperlwein, Federweißer, Classic, Selection. Produktspezifikation für eine geschützte Ursprungsbezeichnung. München: StMELF.

- BAYERISCHES STAATSMINISTERIUM FÜR ERNÄHRUNG, LANDWIRTSCHAFT UND FORSTEN (StMELF) (2020): BAUMARTEN FÜR DEN KLIMAWALD. Leitlinien der Bayerischen Forstverwaltung. München: StMELF.
- BAYERISCHES STAATSMINISTERIUM FÜR UMWELT UND VERBRAUCHERSCHUTZ (StMUV) (2015): Klima-Report Bayern 2015. Klimawandel, Auswirkungen, Anpassungs- und Forschungsaktivitäten. München: StMUV.
- BECK, H. E., N. E. ZIMMERMANN, T. R. McVICAR, N. VERGOPOLAN, A. BERG & E. F. WOOD (2018): Present and future Köppen-Geiger climate classification maps at 1-km resolution. – *Scientific Data* 5, 1, 1–12. DOI: 10.1038/sdata.2018.214.
- BEDNAR-FRIEDL, B., R. BIESBROEK, D. SCHMIDT, P. ALEXANDER, K. BØRSHEIM, J. CARNICER, E. GEORGOPOULOU, M. HAASNOOT, G. L. COZANNET, P. LIONELLO, O. LIPKA, C. MÖLLMANN, V. MUCCIONE, T. MUSTONEN, D. PIEPENBURG & L. WHITMARSH (2022): Europe. In: PÖRTNER, H.-O., D. ROBERTS, M. TIGNOR, E. POLOCZANSKA, K. MINTENBECK, A. ALEGRÍA, M. CRAIG, S. LANGSDORF, S. LÖSCHKE, V. MÖLLER, A. OKEM & B. RAMA (Hrsg.): *Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge and New York: Cambridge University Press. DOI: 10.1017/9781009325844.015.
- BENESTAD, R. E. (2010): Downscaling precipitation extremes. – *Theoretical and Applied Climatology* 100, 1, 1–21. DOI: 10.1007/s00704-009-0158-1.
- BENISTON, M., D. B. STEPHENSON, O. B. CHRISTENSEN, C. A. FERRO, C. FREI, S. GOYETTE, K. HALSNAES, T. HOLT, K. JYLHÄ, B. KOFFI, J. PALUTIKOF, R. SCHÖLL, T. SEMMLER & K. WOTH (2007): Future extreme events in European climate: An exploration of regional climate model projections. – *Climatic Change* 81, SUPPL. 1, 71–95. DOI: 10.1007/S10584-006-9226-Z.
- BENTSEN, M., I. BETHKE, J. B. DEBERNARD, T. IVERSEN, A. KIRKEVÅG, O. SELAND, H. DRANGE, C. ROELANDT, I. A. SEIERSTAD, C. HOOSE & J. E. KRISTJÁNSSON (2013): The Norwegian Earth System Model, NorESM1-M – Part 1: Description and basic evaluation of the physical climate. – *Geoscientific Model Development* 6, 3, 687–720. DOI: 10.5194/GMD-6-687-2013.

- BEZNER KERR, R., T. HASEGAWA, R. LASCO, I. BHATT, D. DERYNG, A. FARRELL, H. GURNEY-SMITH, H. JU, S. LLUCH-COTA, F. MEZA, G. NELSON, H. NEUFELDT, & P. THORNTON (2022): Food, Fibre, and Other Ecosystem Products. In: PÖRTNER, H.-O., D. ROBERTS, M. TIGNOR, E. POLOCZANSKA, K. MINTENBECK, A. ALEGRÍA, M. CRAIG, S. LANGSDORF, S. LÖSCHKE, V. MÖLLER, A. OKEM & B. RAMA (Hrsg.): Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge and New York: Cambridge University Press. DOI: 10.1017/9781009325844.007.
- BOCK, A., T. SPARKS, N. ESTRELLA & A. MENZEL (2011): Changes in the phenology and composition of wine from Franconia, Germany. – *Climate Research* 50, 1, 69–81. 10.3354/cr01048.
- BOCK, A., T. H. SPARKS, N. ESTRELLA & A. MENZEL (2013): Climate-Induced Changes in Grapevine Yield and Must Sugar Content in Franconia (Germany) between 1805 and 2010. – *PLoS ONE* 8, 7. DOI: 10.1371/journal.pone.0069015.
- BOLTE, A. & B. DEGEN (2010): Anpassung der Wälder an den Klimawandel: Optionen und Grenzen. – *Landbauforschung - vTI Agriculture and Forestry Research* 3, 60, 111–118.
- BORTZ, J. & C. SCHUSTER (2010): *Statistik für Human- und Sozialwissenschaftler*. 7. Auflage. Berlin: Springer.
- BOÉ, J., L. TERRAY, F. HABETS & E. MARTIN (2007): Statistical and dynamical downscaling of the Seine basin climate for hydro-meteorological studies. – *International Journal of Climatology* 27, 12, 1643–1655. DOI: 10.1002/JOC.1602.
- BRANG, P., H. BUGMANN, A. BÜRGI, U. MÜHLEHALER, A. RIGLING & R. SCHWITTER (2008): Klimawandel als waldbauliche Herausforderung. – *Schweizerische Zeitschrift für Forstwesen* 159, 10, 362–373. DOI: 10.3188/szf.2008.0362.
- BRISSON, N., P. GATE, D. GOUACHE, G. CHARMET, F. X. OURY & F. HUARD (2010): Why are wheat yields stagnating in Europe? A comprehensive data analysis for France. – *Field Crops Research* 119, 1, 201–212. DOI: 10.1016/J.FCR.2010.07.012.
- BROSINGER, F. & S. TRETTER (2007): *Waldbau im Zeichen des Klimawandels. Anpassung durch Waldumbau und naturnahe Forstwirtschaft*. – *LWF Waldforschung aktuell* 60, 21–23.

- BRUN, P., A. PSOMAS, C. GINZLER, W. THUILLER, M. ZAPPA & N. E. ZIMMERMANN (2020): Large-scale early-wilting response of Central European forests to the 2018 extreme drought. – *Global Change Biology* 26, 12, 7021–7035. DOI: 10.1111/GCB.15360.
- BUNDESAMT FÜR NATURSCHUTZ (BfN) (2011): Naturräume und Großlandschaften Deutschlands. Karte und Zusatzinformationen. Bonn: BfN.
- BUNDESANSTALT FÜR GEOWISSENSCHAFTEN UND ROHSTOFFE (BGR) (2011): Geowissenschaftliche Karte der Bundesrepublik Deutschland 1:2000000. Geologie. Hannover: BGR.
- BUNDESANSTALT FÜR LANDWIRTSCHAFT UND ERNÄHRUNG (BLE) (2021): Bericht zur Markt- und Versorgungslage Zucker. Bonn: BLE.
- BUNDESGESETZBLATT (2019): Verordnung über die Durchführung einer vierten Bundeswaldinventur (Vierte Bundeswaldinventur-Verordnung – 4. BWI-VO). – *Bundesgesetzblatt Jahrgang 2019 I*, 24.
- BUNDESMINISTERIUM FÜR ERNÄHRUNG, LANDWIRTSCHAFT UND VERBRAUCHERSCHUTZ (BMELV) (2008): Bericht des BMELV für einen aktiven Klimaschutz der Agrar-, Forst- und Ernährungswirtschaft und zur Anpassung der Agrar- und Forstwirtschaft an den Klimawandel. Berlin: BMELV.
- BUNDESMINISTERIUM FÜR ERNÄHRUNG UND LANDWIRTSCHAFT (BMEL) & BUNDESANSTALT FÜR LANDWIRTSCHAFT (BLE) (2020): Versorgungsbilanz für Hafer. 202. Deutschland. Tabellennummer: 4020600. Bonn: BMEL und BLE.
- BUNDESMINISTERIUM FÜR UMWELT, NATURSCHUTZ UND REAKTORSICHERHEIT (BMU), UMWELTBUNDESAMT (UBA) & KOMPASS (2008): Deutsche Anpassungsstrategie an den Klimawandel - Erwartungen, Ziele und Handlungsoptionen. Berlin: BMU.
- BURAS, A., A. RAMMIG & C. S. ZANG (2020): Quantifying impacts of the 2018 drought on European ecosystems in comparison to 2003. – *Biogeosciences* 17, 6, 1655–1672. DOI: 10.5194/BG-17-1655-2020.
- BURGER, W. & M. J. BURGE (2016): *Digital Image Processing*. London: Springer.
- BUTH, M., W. KAHLENBORN, J. SAVELSBERG, N. BECKER, S. GREIVING, M. FLEISCHHAUER, C. LINDNER, M. ZEBISCH, S. SCHNEIDERBAUER & C. KOFLER (2015): *Vulnerabilität Deutschlands gegenüber dem Klimawandel*. Dessau-Roßlau: Umweltbundesamt.

- CAFFARRA, A., M. RINALDI, E. ECCEL, V. ROSSI & I. PERTOT (2012): Modelling the impact of climate change on the interaction between grapevine and its pests and pathogens: European grapevine moth and powdery mildew. – *Agriculture, Ecosystems & Environment* 148, Supplement C, 89–101. DOI: 10.1016/j.agee.2011.11.017.
- CALZADILLA, A., K. REHDANZ, R. BETTS, P. FALLOON, A. WILTSHIRE & R. S. J. TOL (2013): Climate change impacts on global agriculture. – *Climatic Change* 120, 1-2, 357–374. DOI: 10.1007/s10584-013-0822-4.
- CARDELL, M., R. ROMERO, A. AMENGUAL, V. HOMAR & C. RAMIS (2019): A quantile–quantile adjustment of the EURO-CORDEX projections for temperatures and precipitation. – *International Journal of Climatology* 39, 6. DOI: 10.1002/joc.5991.
- CARDELL, M. F., A. AMENGUAL, R. ROMERO & C. RAMIS (2020): Future extremes of temperature and precipitation in Europe derived from a combination of dynamical and statistical approaches. – *International Journal of Climatology* 40, 11, 4800–4827. DOI: 10.1002/JOC.6490.
- CAUDULLO, G., E. WELK & J. SAN-MIGUEL-AYANZ (2017): Chorological maps for the main European woody species. – *Data in Brief* 12, 662–666. DOI: 10.1016/J.DIB.2017.05.007.
- CAVAZOS, T. & B. C. HEWITSON (2005): Performance of NCEP – NCAR reanalysis variables in statistical downscaling of daily precipitation. – *Climate Research* 28, 2, 95–107. DOI: 10.3354/cr028095.
- CHEN, J., F. P. BRISSETTE, D. CHAUMONT & M. BRAUN (2013): Finding appropriate bias correction methods in downscaling precipitation for hydrologic impact studies over North America. – *Water Resources Research* 49, 7, 4187–4205. DOI: 10.1002/WRCR.20331.
- CHMIELEWSKI, F.-M. (2007): Folgen des Klimawandels für Land- und Forstwirtschaft. In: ENDLICHER, W. & F.-W. GERSTENGARBE (Hrsg.): *Der Klimawandel. Einblicke, Rückblicke und Ausblicke*. Potsdam: PIK, 75–85.
- CHMIELEWSKI, F. M. & W. KÖHN (1999): The long-term agrometeorological field experiment at Berlin-Dahlem, Germany. – *Agricultural and Forest Meteorology* 96, 1-3, 39–48. DOI: 10.1016/S0168-1923(99)00045-3.

- CHRISTENSEN, J. H., F. BOBERG, O. B. CHRISTENSEN & P. LUCAS-PICHER (2008): On the need for bias correction of regional climate change projections of temperature and precipitation. – *Geophysical Research Letters* 35, 20, L20709. DOI: 10.1029/2008GL035694.
- CHRISTENSEN, O. B., M. DREWS, J. H. CHRISTENSEN, K. DETHLOFF, K. KETELSEN, I. HEBESTADT & A. RINKE (2007): The HIRHAM Regional Climate Model Version 5 (beta). DMI Technical Report 06-17. Copenhagen: Danish Meteorological Institute (DMI).
- COLLINS, M., R. KNUTTI, J. ARBLASTER, J.-L. DUFRESNE, T. FICHEFET, P. FRIEDLINGSTEIN, X. GAO, W. GUTOWSKI, T. JOHNS, G. KRINNER, M. SHONGWE, C. TEBALDI, A. WEAVER & M. WEHNER (2013): *Long-term Climate Change: Projections, Commitments and Irreversibility*. Cambridge: Cambridge University Press, 1029–1136.
- CONTZEN, J., T. DICKHAUS & G. LOHMANN (2023): Long-term temporal evolution of extreme temperature in a warming Earth. – *PLOS ONE* 18, 2, e0280503. DOI: 10.1371/JOURNAL.PONE.0280503.
- COPERNICUS CLIMATE CHANGE SERVICE (C3S) (2023a): 2022 was a year of climate extremes, with record high temperatures and rising concentrations of greenhouse gases. 2022 was the 5th warmest year globally and 2nd warmest year for Europe. Press release. <<https://climate.copernicus.eu/copernicus-2022-was-year-climate-extremes-record-high-temperatures-and-rising-concentrations>>. (Stand: 2023-01-09) (Zugriff: 2023-04-21).
- COPERNICUS CLIMATE CHANGE SERVICE (C3S) (2023b): Climate Indicators. Greenhouse gas concentrations. <<https://climate.copernicus.eu/climate-indicators/greenhouse-gas-concentrations>>. (Stand: 2023-04-20) (Zugriff: 2023-04-21).
- COPPOLA, E., F. RAFFAELE, F. GIORGI, G. GIULIANI, G. XUEJIE, J. M. CIARLO, T. R. SINES, J. A. TORRES-ALAVEZ, S. DAS, F. DI SANTE, E. PICHELLI, R. GLAZER, S. K. MÜLLER, S. A. OMAR, M. ASHFAQ, M. BUKOVSKY, E. S. IM, D. JACOB, C. TEICHMANN, A. REMEDIO, T. REMKE, A. KRIEGSMANN, K. BÜLOW, T. WEBER, L. BUNTEMeyer, K. SIECK & D. RECHID (2021): Climate hazard indices projections based on CORDEX-CORE, CMIP5 and CMIP6 ensemble. – *Climate Dynamics* 57, 1293–1383. DOI: 10.1007/S00382-021-05640-Z.

- CORNES, R. C., G. VAN DER SCHRIER, E. J. VAN DEN BESSELAAR & P. D. JONES (2018): An Ensemble Version of the E-OBS Temperature and Precipitation Data Sets. – *Journal of Geophysical Research: Atmospheres* 123, 17, 9391–9409. DOI: 10.1029/2017JD028200.
- CORTEKAR, J. (2017): Glossar. In: BRASSEUR, G. P., D. JACOB & S. SCHUCK-ZÖLLER (Hrsg.): *Klimawandel in Deutschland*. Berlin, Heidelberg: Springer Spektrum, 346–348. DOI: 10.1007/978-3-662-50397-3_4.
- CRAWLEY, M. J. (2013): *The R book*. Southern Gate: Wiley.
- DAMATTA, F. M., A. GRANDIS, B. C. ARENQUE & M. S. BUCKERIDGE (2010): Impacts of climate changes on crop physiology and food quality. – *Food Research International* 43, 1814–1823. DOI: 10.1016/j.foodres.2009.11.001.
- DANIEL, M., A. LEMONSU, M. DÉQUÉ, S. SOMOT, A. ALIAS & V. MASSON (2019): Benefits of explicit urban parameterization in regional climate modeling to study climate and city interactions. – *Climate Dynamics* 52, 5-6, 2745–2764. DOI: 10.1007/S00382-018-4289-X.
- DE MARTONNE, E. (1926a): Aerisme, et indices d'aridité. – *Comptes rendus de L'Academie des Sciences* 182, 1395–1398.
- DE MARTONNE, E. (1926b): L'indice d'aridité. – *Bulletin de l'Association de géographes français* 9, 3–5.
- DE MARTONNE, E. (1942): Nouvelle carte mondial de l'indice d'aridité. – *Annales de Géographie* 51, 288, 241–250.
- DEE, D. P., S. M. UPPALA, A. J. SIMMONS, P. BERRISFORD, P. POLI, S. KOBAYASHI, U. ANDRAE, M. A. BALMASEDA, G. BALSAMO, P. BAUER, P. BECHTOLD, A. C. BELJAARS, L. VAN DE BERG, J. BIDLOT, N. BORMANN, C. DELSOL, R. DRAGANI, M. FUENTES, A. J. GEER, L. HAIMBERGER, S. B. HEALY, H. HERSBACH, E. V. HÓLM, L. ISAKSEN, P. KÅLLBERG, M. KÖHLER, M. MATRICARDI, A. P. MCNALLY, B. M. MONGE-SANZ, J. J. MORCRETTE, B. K. PARK, C. PEUBEY, P. DE ROSNAY, C. TAVOLATO, J. N. THÉPAUT & F. VITART (2011): The ERA-Interim reanalysis: configuration and performance of the data assimilation system. – *Quarterly Journal of the Royal Meteorological Society* 137, 656, 553–597. DOI: 10.1002/QJ.828.
- DENIZ, A., H. TOROS & S. INCECIK (2011): Spatial variations of climate indices in Turkey. – *International Journal of Climatology* 31, 3, 394–403. DOI: 10.1002/JOC.2081.

- DEUTSCHER WETTERDIENST (DWD) (2019): Jahrbuch 2019 des Deutschen Wetterdienstes. Offenbach: DWD.
- DEUTSCHER WETTERDIENST (DWD) (2020): Nationaler Klimareport. Klima – Gestern, heute und in der Zukunft. Offenbach: DWD.
- DEUTSCHER WETTERDIENST (DWD) (2021a): Grids of monthly averaged daily air temperature (2m) over Germany. Data set. <https://opendata.dwd.de/climate_environment/CDC/grids_germany/monthly/air_temperature_mean/>. (Stand: 2021-01-04) (Zugriff:2022-03-16).
- DEUTSCHER WETTERDIENST (DWD) (2021b): Grids of monthly total precipitation over Germany. Data set. <https://opendata.dwd.de/climate_environment/CDC/grids_germany/monthly/precipitation/>. (Stand: 2021-01-04) (Zugriff:2022-04-25).
- DEUTSCHER WETTERDIENST (DWD) (2021c): Monthly grids of the accumulated potential evapotranspiration over grass. Data set. <https://opendata.dwd.de/climate_environment/CDC/grids_germany/monthly/evapo_p/>. (Stand: 2021-02-01) (Zugriff:2022-04-25).
- DEUTSCHER WETTERDIENST (DWD) (2021d): Stationsdaten jährliche Wetterphänomene. Station 05705 Würzburg. <https://opendata.dwd.de/climate_environment/CDC/observations_germany/climate/annual/weather_phenomena/historical/wetter_jahreswerte_05705_19490101_20141231_hist.zip>. (Stand: 2021) (Zugriff: 2022-03-31).
- DEUTSCHER WETTERDIENST (DWD) (2022): Wetterlexikon. Klimatologische Kenntnisse. <<https://www.dwd.de/DE/service/lexikon/Functions/glossar.html?lv2=101334&lv3=101452>>. (Stand: 2022) (Zugriff: 2022-03-31).
- DEUTSCHLÄNDER, T. & H. MÄCHEL (2017): Temperatur inklusive Hitzewellen. In: BRASSEUR, G. P., D. JACOB & S. SCHUCK-ZÖLLER (Hrsg.): Klimawandel in Deutschland. Berlin, Heidelberg: Springer, 47–56. DOI: 10.1007/978-3-662-50397-3_6.
- DIEPENBROCK, W., F. ELLMER & J. LEON (2012): Ackerbau, Pflanzenbau, Pflanzenzüchtung. 3. Auflage. Stuttgart: Ulmer.
- DIER, M., L. HÜTHER, W. X. SCHULZE, M. ERBS, P. KÖHLER, H. J. WEIGEL, R. MANDERSCHIED & C. ZÖRB (2020): Elevated Atmospheric CO₂ Concentration Has Limited Effect on Wheat Grain Quality Regardless of Nitrogen Supply. – Journal of agricultural and food chemistry 68, 12, 3711–3721. DOI: 10.1021/ACS.JAFC.9B07817.

- DIETRICH, H.-P., S. RASPE, L. ZIMMERMANN, A. WAUER, D. KÖHLER, A. SCHUBERT, J. STIEGLER, U. BLUM & T. K. UND HANS-JOACHIM KLEMMT (2018): Umwelt und Standortsbedingungen in raschem Wandel. Forstliches Monitoring der LWF zieht nüchterne Zwischenbilanz. – LWF aktuell 2, 6–11.
- DISTANTE, A. & C. DISTANTE (2020): Handbook of image processing and computer vision: Volume 2: From image to pattern. Cham: Springer International Publishing.
- DOBLAS-REYES, F. J., A. A. SÖRENSSON, M. ALMAZROUI, A. DOSIO, W. J. GUTOWSKI, R. HAARSMA, R. HAMDY, B. HEWITSON, W.-T. KWON, B. L. LAMPTEY, D. MARAUN, T. S. STEPHENSON, I. TAKAYABU, L. TERRAY, A. TURNER & Z. ZUO (2021): Linking Global to Regional Climate Change. In: MASSON-DELMOTTE, V., P. ZHAI, A. PIRANI, S. CONNORS, C. PÉAN, S. BERGER, N. CAUD, Y. CHEN, L. GOLDFARB, M. GOMIS, M. HUANG, K. LEITZELL, E. LONNOY, J. MATTHEWS, T. MAYCOCK, T. WATERFIELD, O. YELEKÇI, R. YU & B. ZHOU (Hrsg.): Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press.
- DOBLER, A., H. FELDMANN, U. ULBRICH, D. JACOB & C. KOTTMEIER (2017): Grenzen und Herausforderungen der regionalen Klimamodellierung. In: BRASSEUR, G. P., D. JACOB & S. SCHUCK-ZÖLLER (Hrsg.): Klimawandel in Deutschland. Berlin, Heidelberg: Springer, 37–44. DOI: 10.1007/978-3-662-50397-3_5.
- DONAT, M. G., J. SILLMANN, S. WILD, L. V. ALEXANDER, T. LIPPMANN & F. W. ZWIERS (2014): Consistency of Temperature and Precipitation Extremes across Various Global Gridded In Situ and Reanalysis Datasets. – Journal of Climate 27, 13, 5019–5035. DOI: 10.1175/JCLI-D-13-00405.1.
- DONATELLI, M., A. K. SRIVASTAVA, G. DUVEILLER, S. NIEMEYER & D. FUMAGALLI (2015): Climate change impact and potential adaptation strategies under alternate realizations of climate scenarios for three major crops in Europe. – Environmental Research Letters 10, 7, 075005. DOI: 10.1088/1748-9326/10/7/075005.
- DOPPLER, G., M. FIEBIG, W. FREUDENBERGER, S. GLASER, R. MEYER, T. PÜRNER, J. ROHRMÜLLER & K. SCHWERD (2004): GeoBavaria. 600 Millionen Jahre Bayern. München: Bayerisches Geologisches Landesamt.

- DORMANN, C. F. (2017): *Parametrische Statistik*. Berlin, Heidelberg: Springer Spektrum.
- DROULIA, F. & I. CHARALAMPOPOULOS (2021): Future Climate Change Impacts on European Viticulture: A Review on Recent Scientific Advances. – *Atmosphere* 12, 4, 495. DOI: 10.3390/ATMOS12040495.
- DUNN, P. K. & G. K. SMYTH (2018): *Generalized Linear Models. With Examples in R*. New York: Springer.
- EDEN, J. M., M. WIDMANN, D. GRAWE & S. RAST (2012): Skill, Correction, and Downscaling of GCM-Simulated Precipitation. – *Journal of Climate* 25, 11, 3970–3984. DOI: 10.1175/JCLI-D-11-00254.1.
- EDEN, J. M., M. WIDMANN, D. MARAUN & M. VRAC (2014a): Comparison of GCM- and RCM-simulated precipitation following stochastic postprocessing. – *Journal of Geophysical Research: Atmospheres* 119, 19, 11,040–11,053. DOI: 10.1002/2014JD021732.
- EDEN, J. M., M. WIDMANN, D. MARAUN & M. VRAC (2014b): Comparison of GCM- and RCM-simulated precipitation following stochastic postprocessing. – *Journal of Geophysical Research: Atmospheres* 119, 19, 11,040–11,053. DOI: 10.1002/2014JD021732.
- EUROPEAN ENVIRONMENT AGENCY (EEA) (2019): *Climate change adaptation in the agriculture sector in Europe*. EEA Report 04/2019. Kopenhagen: EEA.
- EUROSTAT (2020): *GISCO - the Geographic Information System of the COMmission*. Geodatatata. Reference Data. Administrative Units / Statistical Units. Countries. Countries 2020. 1:10 Million. Shapefile. Luxemburg: Eurostat.
- EXPERT TEAM ON CLIMATE CHANGE DETECTION AND INDICES (ETCCDI) (2022): *Climate Change Indices. Definitions of the 27 core indices*. <http://etccdi.pacificclimate.org/list_27_indices.shtml>. (Stand: 2022) (Zugriff: 2022-03-31).
- FACHAGENTUR NACHWACHSENDE ROHSTOFFE E.V. (FNR) (2022a): *Anbau und Verwendung nachwachsender Rohstoffe in Deutschland*. Gülzow-Prüzen: FNR.
- FACHAGENTUR NACHWACHSENDE ROHSTOFFE E.V. (FNR) (2022b): *Basisdaten Bioenergie Deutschland 2022*. Gülzow-Prüzen: FNR.
- FAHRMEIR, L., T. KNEIB & S. LANG (2009): *Regression: Modelle, Methoden und Anwendungen*. Berlin, Heidelberg: Springer.

- FALK, W., E. A. THURM, T. METTE, O. SCHUSTER & H.-J. KLEMMT (2019): Anbaurisiko-Karten für nichtheimische Baumarten Modelle zur Unterstützung der Baumartenwahl im Klimawandel. – LWF aktuell 4, 23–27.
- FALLOON, P. & R. BETTS (2010): Climate impacts on European agriculture and water management in the context of adaptation and mitigation—The importance of an integrated approach. – *Science of The Total Environment* 408, 23, 5667–5687. DOI: 10.1016/J.SCITOTENV.2009.05.002.
- FELBERMEIR, T. (2011): Auswirkungen der Klimaänderung auf Naturerträge. In: LfL (BAYERISCHE LANDESANSTALT FÜR LANDWIRTSCHAFT) (Hrsg.): Klimaänderung in Bayern. Antworten des Pflanzenbaus. Lfl - Jahrestagung. 9. Kulturlandschaftstag. Freising: LfL, 7–16.
- FESER, F., B. RROCKEL, H. STORCH, J. WINTERFELDT & M. ZAHN (2011): Regional Climate Models Add Value to Global Model Data: A Review and Selected Examples. – *Bulletin of the American Meteorological Society* 92, 9, 1181–1192. DOI: 10.1175/2011BAMS3061.1.
- FINGER, R. (2010): Evidence of slowing yield growth – The example of Swiss cereal yields. – *Food Policy* 35, 2, 175–182. DOI: 10.1016/J.FOODPOL.2009.11.004.
- FISCHER, G., M. SHAH & H. V. VELTHUIZEN (2002): *Climate Change and Agricultural Vulnerability*. Laxenburg: International Institute for Applied Systems Analysis.
- FLATO, G., J. MAROTZKE, B. ABIODUN, P. BRACONNOT, S. CHOU, W. COLLINS, P. COX, F. DRIOUECH, S. EMORI, V. EYRING, C. FOREST, P. GLECKLER, E. GUILYARDI, C. JAKOB, V. KATSOV, C. REASON & M. RUMMUKAINEN (2013): *Evaluation of Climate Models*. Cambridge: Cambridge University Press, 741–866.
- FRAGA, H., I. GARCÍA DE CORTÁZAR ATAURI, A. C. MALHEIRO & J. A. SANTOS (2016a): Modelling climate change impacts on viticultural yield, phenology and stress conditions in Europe. – *Global Change Biology* 22, 11. DOI: 10.1111/gcb.13382.
- FRAGA, H., J. A. SANTOS, J. MOUTINHO-PEREIRA, C. CARLOS, J. SILVESTRE, J. EIRAS-DIAS, T. MOTA & A. C. MALHEIRO (2016b): Statistical modelling of grapevine phenology in Portuguese wine regions: Observed trends and climate change projections. – *Journal of Agricultural Science* 154, 5. DOI: 10.1017/S0021859615000933.

- FRICH, P., L. V. ALEXANDER, P. DELLA-MARTA, B. GLEASON, M. HAYLOCK, A. M. G. K. TANK & T. PETERSON (2002): Observed coherent changes in climatic extremes during the second half of the twentieth century. – *Climate Research* 19, 3, 193–212. DOI: 10.2307/24866781.
- FURRER, E. M., R. W. KATZ, M. D. WALTER & R. FURRER (2010): Statistical modeling of hot spells and heat waves. – *Climate Research* 43, 3, 191–205. DOI: 10.3354/CR00924.
- GEBHARDT, H. (2007): Postindustrielle Entwicklung. In: GLASER, R., H. GEBHARDT & W. SCHENK (Hrsg.): *Geographie Deutschlands*. Darmstadt: Wissenschaftliche Buchgesellschaft, 159–169.
- GEOBASIS-DE (2012): CORINE Land Cover 10 ha. CLC10. Leipzig: Bundesamt für Kartographie und Geodäsie.
- GEOBASIS-DE (2017): Verwaltungsgebiete 1:250000. VG250 und VG250-EW. SHAPE-Daten. Leipzig: Bundesamt für Kartographie und Geodäsie.
- GESCH, D. B., K. L. VERDIN & S. K. GREENLEE (1999): New land surface digital elevation model covers the Earth. – *Eos* 80, 6, 69–70. DOI: 10.1029/99EO00050.
- GESSLER, A., C. KEITEL, J. KREUZWIESER, R. MATYSSEK, W. SEILER & H. RENNENBERG (2007): Potential risks for European beech (*Fagus sylvatica* L.) in a changing climate. – *Trees - Structure and Function* 21, 1, 1–11. DOI: 10.1007/S00468-006-0107-X.
- GIORGETTA, M. A., J. JUNGCLAUS, C. H. REICK, S. LEGUTKE, J. BADER, M. BÖTTINGER, V. BROVKIN, T. CRUEGER, M. ESCH, K. FIEG, K. GLUSHAK, V. GAYLER, H. HAAK, H.-D. HOLLWEG, T. ILYINA, S. KINNE, L. KORNBLUEH, D. MATEI, T. MAURITSEN, U. MIKOLAJEWICZ, W. MUELLER, D. NOTZ, F. PITHAN, T. RADDATZ, S. RAST, R. REDLER, E. ROECKNER, H. SCHMIDT, R. SCHNUR, J. SEGSCHEIDER, K. D. SIX, M. STOCKHAUSE, C. TIMMRECK, J. WEGNER, H. WIDMANN, K.-H. WIENERS, M. CLAUSSEN, J. MAROTZKE & B. STEVENS (2013): Climate and carbon cycle changes from 1850 to 2100 in MPI-ESM simulations for the Coupled Model Intercomparison Project phase 5. – *Journal of Advances in Modeling Earth Systems* 5, 3, 572–597. DOI: 10.1002/JAME.20038.
- GIORGI, F. (2006): Climate change hot-spots. – *Geophysical Research Letters* 33, 8, 8707. DOI: 10.1029/2006GL025734.

- GIORGI, F. (2019): Thirty Years of Regional Climate Modeling: Where Are We and Where Are We Going next?. – *Journal of Geophysical Research: Atmospheres* 124, 11, 5696–5723. DOI: 10.1029/2018JD030094.
- GIORGI, F. & W. J. GUTOWSKI (2015): Regional Dynamical Downscaling and the CORDEX Initiative. – <http://dx.doi.org/10.1146/annurev-environ-102014-021217> 40, 467–490. DOI: 10.1146/ANNUREV-ENVIRON-102014-021217.
- GIORGI, F., C. JONES & G. R. ASRAR (2009): Addressing climate information needs at the regional level: the CORDEX framework. – *WMO Bulletin* 58, 3, 175–183.
- GLAHN, H. R., D. A. LOWRY, H. R. GLAHN & D. A. LOWRY (1972): The Use of Model Output Statistics (MOS) in Objective Weather Forecasting. – *Journal of Applied Meteorology* 11, 8, 1203–1211. DOI: 10.1175/1520-0450(1972)011<1203:TUOMOS>2.0.CO;2.
- GLASER, R. (2007): Ordnung muss sein – naturräumliche und landschaftsökologische Gliederungen. In: GLASER, R., H. GEBHARDT & W. SCHENK (Hrsg.): *Geographie Deutschlands*. Darmstadt: Wissenschaftliche Buchgesellschaft, 20–29.
- GLASER, R. (2008): *Klimageschichte Mitteleuropas. 1200 Jahre Wetter, Klima, Katastrophen*. 2. Auflage. Darmstadt: Wissenschaftliche Buchgesellschaft.
- GLASER, R. & J. SCHÖNBEIN (2007): Klima und Wetterkontraste. In: GLASER, R., H. GEBHARDT & W. SCHENK (Hrsg.): *Geographie Deutschlands*. Darmstadt: Wissenschaftliche Buchgesellschaft, 29–44.
- GÖMANN, H., C. FRÜHAUF, A. LÜTTGER & H.-J. WEIGEL (2017): Landwirtschaft. In: BRASSEUR, G. P., D. JACOB & S. SCHUCK-ZÖLLER (Hrsg.): *Klimawandel in Deutschland*. Berlin, Heidelberg: Springer, 183–191. DOI: 10.1007/978-3-662-50397-3_18.
- GORNOTT, C. & F. WECHSUNG (2016): Statistical regression models for assessing climate impacts on crop yields: A validation study for winter wheat and silage maize in Germany. – *Agricultural and Forest Meteorology* 217, 89–100. DOI: 10.1016/J.AGRFORMET.2015.10.005.
- GRASSL, H. (2007): Der Klimawandel – zu schnell für jeden Baum. Rasante Klimaänderung überfordert Anpassungsfähigkeit der Bäume. – *LWF Waldforschung aktuell* 60, 3–4.

- GRIESER, J., R. GOMMES, S. COFIELD & M. BERNARDI (2006): FAO Climpag Climate Impact on Agriculture. Data sources for FAO worldmaps of Koeppen climatologies and climatic net primary production. Genf: FAO of the UN.
- GRILLAKIS, M. G., A. G. KOUTROULIS, I. N. DALIAKOPOULOS & I. K. TSANIS (2017): A method to preserve trends in quantile mapping bias correction of climate modeled temperature. – *Earth System Dynamics* 8, 3, 889–900. DOI: 10.5194/esd-8-889-2017.
- GUDMUNDSSON, L., J. B. BREMNES, J. E. HAUGEN & T. ENGEN-SKAUGEN (2012): Technical Note: Downscaling RCM precipitation to the station scale using statistical transformations - A comparison of methods. – *Hydrology and Earth System Sciences* 16, 9, 3383–3390. DOI: 10.5194/HESS-16-3383-2012.
- GUTIÉRREZ, J., R. JONES, G. NARISMA, L. ALVES, M. AMJAD, I. GORODETSKAYA, M. GROSE, N. KLUTSE, S. KRAKOVSKA, J. LI, D. MARTÍNEZ-CASTRO, L. MEARNES, S. MERNILD, T. NGO-DUC, B. VAN DEN HURK & J.-H. YOON (2021): Atlas. Interactive Atlas available from <http://interactive-atlas.ipcc.ch/>. In: MASSON-DELMOTTE, V., P. ZHAI, A. PIRANI, S. CONNORS, C. PÉAN, S. BERGER, N. CAUD, Y. CHEN, L. GOLDFARB, M. GOMIS, M. HUANG, K. LEITZELL, E. LONNOY, J. MATTHEWS, T. MAYCOCK, T. WATERFIELD, O. YELEKÇI, R. YU & B. ZHOU (Hrsg.): *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press.
- GUTJAHR, O. & G. HEINEMANN (2013): Comparing precipitation bias correction methods for high-resolution regional climate simulations using COSMO-CLM: Effects on extreme values and climate change signal. – *Theoretical and Applied Climatology* 114, 3-4, 511–529. DOI: 10.1007/S00704-013-0834-Z.
- GUTSCH, M., P. LASCH-BORN, C. KOLLAS, F. SUCKOW & C. P. REYER (2018): Balancing trade-offs between ecosystem services in Germany's forests under climate change. – *Environmental Research Letters* 13, 4, 045012. DOI: 10.1088/1748-9326/AAB4E5.
- GÓMEZ-NAVARRO, J. J., J. P. MONTÁVEZ, S. JEREZ, P. JIMÉNEZ-GUERRERO & E. ZORITA (2012): What is the role of the observational dataset in the evaluation and scoring of climate models?. – *Geophysical Research Letters* 39, 24, L24701. DOI: 10.1029/2012GL054206.

- HANEWINKEL, M., D. A. CULLMANN, M.-J. SCHELHAAS, G.-J. NABUURS & N. E. ZIMMERMANN (2012): Climate change may cause severe loss in the economic value of European forest land. – *Nature Climate Change* 3, 3, 203–207. DOI: 10.1038/nclimate1687.
- HASTIE, T. J. & R. J. TIBSHIRANI (1990): *Generalized additive models*. 2. New York: Chapman & Hall/CRC.
- HAYLOCK, M. R., N. HOFSTRA, A. M. G. K. TANK, E. J. KLOK, P. D. JONES & M. NEW (2008): A European daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006. – *Journal of Geophysical Research* 113, D20, D20119. DOI: 10.1029/2008JD010201.
- HAZELEGER, W., X. WANG, C. SEVERIJNS, S. ȘTEFĂNESCU, R. BINTANJA, A. STERL, K. WYSER, T. SEMMLER, S. YANG, B. VAN DEN HURK, T. VAN NOIJE, E. VAN DER LINDEN & K. VAN DER WIEL (2012): EC-Earth V2.2: Description and validation of a new seamless earth system prediction model. – *Climate Dynamics* 39, 11, 2611–2629. DOI: 10.1007/S00382-011-1228-5.
- HEDDERICH, J. & L. SACHS (2016): *Angewandte Statistik*. Berlin, Heidelberg: Springer.
- HEMPEL, S., K. FRIELER, L. WARSZAWSKI, J. SCHEWE & F. PIONTEK (2013): A trend-preserving bias correction – the ISI-MIP approach. – *Earth System Dynamics* 4, 2, 219–236. DOI: 10.5194/esd-4-219-2013.
- HERRERA, S., L. FITA, J. FERNÁNDEZ & J. M. GUTIÉRREZ (2010): Evaluation of the mean and extreme precipitation regimes from the ENSEMBLES regional climate multimodel simulations over Spain. – *Journal of Geophysical Research: Atmospheres* 115, D21117. DOI: <https://doi.org/10.1029/2010JD013936>.
- HERTIG, E. & J. JACOBET (2015): Considering observed and future nonstationarities in statistical downscaling of Mediterranean precipitation. – *Theoretical and Applied Climatology* 122, 3-4, 667–683. DOI: 10.1007/s00704-014-1314-9.
- HERTIG, E., S. SEUBERT, A. PAXIAN, G. VOGT, H. PAETH & J. JACOBET (2014): Statistical modelling of extreme precipitation indices for the Mediterranean area under future climate change. – *International Journal of Climatology* 34, 4, 1132–1156. DOI: 10.1002/joc.3751.
- HEWITT, C. D. & D. J. GRIGGS (2004): Ensembles-based predictions of climate changes and their impacts. – *Eos* 85, 52, 566–566. DOI: 10.1029/2004EO520005.

- HO-HAGEMANN, H. T. M., M. GRÖGER, B. ROCKEL, M. ZAHN, B. GEYER & H. E. MEIER (2017): Effects of air-sea coupling over the North Sea and the Baltic Sea on simulated summer precipitation over Central Europe. – *Climate Dynamics* 49, 11-12, 3851–3876. DOI: 10.1007/S00382-017-3546-8.
- HÖGY, P. & A. FANGMEIER (2008): Effects of elevated atmospheric CO₂ on grain quality of wheat. – *Journal of Cereal Science* 48, 3, 580–591. DOI: 10.1016/J.JCS.2008.01.006.
- HOPPMANN, D., K. SCHALLER & M. STOLL (2010): *Terroir. Wetter, Klima und Boden im Weinbau*. Stuttgart: Ulmer.
- HORANYI, A. (2021): Copernicus Climate Change Service - C3S. Climate Projections. Documentation for regional climate projections in the CDS. Extension 1 - CORDEX: Regional climate projections. <<https://confluence.ecmwf.int/display/COPSRV/Extension+1++CORDEX%3A+Regional+climate+projections>>. (Stand: 2021) (Zugriff: 2023-01-17). Los Alamos: Theoretical Division Los Alamos National Laboratory.
- HOSKING, J. R. M. (1990): L-Moments: Analysis and Estimation of Distributions Using Linear Combinations of Order Statistics. – *Journal of the Royal Statistical Society: Series B (Methodological)* 52, 1, 105–124. DOI: 10.1111/j.2517-6161.1990.tb01775.x.
- HOSKING, J. R. M. (1996): Fortran routines for use with the method of L-moments Version 3.04. RC 20525. Yorktown Heights: IBM Research Division.
- HOSKING, J. R. M. & J. R. WALLIS (1997): *Regional Frequency Analysis: An Approach Based on L-Moments*. Cambridge: Cambridge University Press.
- HUGLIN, M. (1976): Nouveau mode d'évaluation des possibilités héliothermiques d'un milieu viticole. – *Comptes Rendus de l'Académie d'Agriculture de France* 64, 1117–1126.
- HUNDHAUSEN, M., H. FELDMANN, N. LAUBE & J. PINOT (2022): Future heat extremes and impacts in a convection permitting climate ensemble over Germany. – *Natural Hazards and Earth System Sciences Discussion* (under review). DOI: 10.5194/nhess-2022-283.
- HURRELL, J. W. & H. V. LOON (1997): Decadal variations in climate associated with the North Atlantic oscillation. – *Climatic Change* 36, 301–326. DOI: 10.1023/A:1005314315270.
- ILES, C. & G. HEGERL (2017): Role of the North Atlantic Oscillation in decadal temperature trends. – *Environmental Research Letters* 12, 114010. DOI: 10.1088/1748-9326/AA9152.

- IMMLER, T. & M. BLASCKE (2007): Forstschädlinge profitieren vom Klimawandel. Klimaerwärmung stellt die Waldschützer vor neue Herausforderungen. – LWF Waldforschung aktuell 60, 24–26.
- INSTITUT FÜR LANDESKUNDE (IFL) (1968): Geographische Landesaufnahme 1:200000. Naturräumliche Gliederung. Blatt 151 Darmstadt. Bad Godesberg: Bundesforschungsanstalt für Landeskunde und Raumordnung.
- INSTITUT FÜR REBENZÜCHTUNG (ZR) (2022): Vitis International Variety Catalogue VIVC. Passport Data Search. Suchbegriffe Prime name: Bacchus weiss, Domina, Pinot noir, Dornfelder, Regent, Schwarzriesling, Pinot gris, Pinot blanc. <<https://www.vivc.de/index.php?r=passport%2Findex>>. (Stand: 2022) (Zugriff: 2022-11-02).
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC) (2021): Summary for Policymakers. In: MASSON-DELMOTTE, V., P. ZHAI, A. PIRANI, S. CONNORS, C. PÉAN, S. BERGER, N. CAUD, Y. CHEN, L. GOLDFARB, M. GOMIS, M. HUANG, K. LEITZELL, E. LONNOY, J. MATTHEWS, T. MAYCOCK, T. WATERFIELD, O. YELEKÇI, R. YU & B. ZHOU (Hrsg.): Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC) (2022a): Annex I: Global to Regional Atlas. In: PÖRTNER, H.-O., D. ROBERTS, M. TIGNOR, E. POLOCZANSKA, K. MINTENBECK, A. ALEGRÍA, M. CRAIG, S. LANGSDORF, S. LÖSCHKE, V. MÖLLER, A. OKEM & B. RAMA (Hrsg.): Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge and New York: Cambridge University Press. DOI: 10.1017/9781009325844.028.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC) (2022b): Summary for Policymakers. In: PÖRTNER, H.-O., D. ROBERTS, M. TIGNOR, E. POLOCZANSKA, K. MINTENBECK, A. ALEGRÍA, M. CRAIG, S. LANGSDORF, S. LÖSCHKE, V. MÖLLER, A. OKEM & B. RAMA (Hrsg.): Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge and New York: Cambridge University Press. DOI: 10.1017/9781009325844.001.

- ITURBIDE, M., J. FERNÁNDEZ, J. GUTIÉRREZ, J. BEDIA, E. CIMADEVILLA, J. DÍEZ-SIERRA, R. MANZANAS, A. CASANUEVA, J. BAÑO-MEDINA, J. MILOVAC, S. HERRERA, A. COFIÑO, D. S. MARTÍN, M. GARCÍA-DÍEZ, M. HAUSER, D. HUARD & Ö. YELEKÇI (2021): Repository supporting the implementation of FAIR principles in the IPCC-WG1 Atlas. Zenodo. Available from: <https://github.com/IPCC-WG1/Atlas>. DOI: 10.5281/zenodo.3691645.
- IVANOV, M. A. & S. KOTLARSKI (2017): Assessing distribution-based climate model bias correction methods over an alpine domain: added value and limitations. – *International Journal of Climatology* 37, 5, 2633–2653. DOI: 10.1002/joc.4870.
- IVANOV, M. A., J. LUTERBACHER & S. KOTLARSKI (2018): Climate model biases and modification of the climate change signal by intensity-dependent bias correction. – *Journal of Climate* 31, 16. DOI: 10.1175/JCLI-D-17-0765.1.
- JACKSON, R. S. (2000): *Wine Science*. Burlington, London, San Diego: Elsevier Academic Press.
- JACOB, D., C. KOTTMEIER, J. PETERSEN, D. RECHID & C. TEICHMANN (2017): Regionale Klimamodellierung. In: BRASSEUR, G. P., D. JACOB & S. SCHUCK-ZÖLLER (Hrsg.): *Klimawandel in Deutschland*. Berlin, Heidelberg: Springer Spektrum, 27–35. DOI: 10.1007/978-3-662-50397-3_4.
- JACOB, D., J. PETERSEN, B. EGGERT, A. ALIAS, O. B. CHRISTENSEN, L. M. BOUWER, A. BRAUN, A. COLETTE, M. DÉQUÉ, G. GEORGIEVSKI, E. GEORGOPOULOU, A. GOBIET, L. MENUT, G. NIKULIN, A. HAENSLER, N. HEMPELMANN, C. JONES, K. KEULER, S. KOVATS, N. KRÖNER, S. KOTLARSKI, A. KRIEGSMANN, E. MARTIN, E. VAN MEIJGAARD, C. MOSELEY, S. PFEIFER, S. PREUSCHMANN, C. RADERMACHER, K. RADTKE, D. RECHID, M. ROUNSEVELL, P. SAMUELSSON, S. SOMOT, J.-F. SOUSSANA, C. TEICHMANN, R. VALENTINI, R. VAUTARD, B. WEBER & P. YIOU (2014): EURO-CORDEX: new high-resolution climate change projections for European impact research. – *Regional Environmental Change* 14, 2, 563–578. DOI: 10.1007/S10113-013-0499-2.
- JACOB, D. & R. PODZUN (1997): Sensitivity studies with the regional climate model REMO. – *Meteorology and Atmospheric Physics* 63, 1-2, 119–129. DOI: 10.1007/BF01025368.
- JOLLIFFE, I. T. (2002): *Principal Component Analysis*. 2. Auflage. New York: Springer.

- JONES, G. V. & F. ALVES (2012): Impact of climate change on wine production: A global overview and regional assessment in the douro valley of Portugal. – *International Journal of Global Warming* 4, 3-4, 383–406. DOI: 10.1504/IJGW.2012.049448.
- JONES, G. V. & R. E. DAVIS (2000): Using a synoptic climatological approach to understand climate-viticulture relationships. – *International Journal of Climatology* 20, 8, 813–837. DOI: 10.1002/1097-0088(20000630)20:8<813::AID-JOC495>3.0.CO;2-W.
- JONES, G. V. & L. B. WEBB (2010): Climate change, viticulture, and wine: Challenges and opportunities. – *Journal of Wine Research* DOI: 10.1080/09571264.2010.530091.
- JONES, G. V., M. A. WHITE, O. R. COOPER & K. STORCHMANN (2005): Climate Change and Global Wine Quality. – *Climatic Change* 73, 3, 319–343. DOI: 10.1007/s10584-005-4704-2.
- JONES, P. (1998): A User's Guide for SCRIP: A Spherical Coordinate Remapping and Interpolation Package. Version 1.5. Los Alamos: Theoretical Division Los Alamos National Laboratory.
- JØRGENSEN, B. (1987): Exponential Dispersion Models. – *Journal of the Royal Statistical Society: Series B (Methodological)* 49, 2, 127–145. DOI: 10.1111/J.2517-6161.1987.TB01685.X.
- JUNGCLAUS, J. H., N. FISCHER, H. HAAK, K. LOHMANN, J. MAROTZKE, D. MATEI, U. MIKOLAJEWICZ, D. NOTZ & J. S. V. STORCH (2013): Characteristics of the ocean simulations in the Max Planck Institute Ocean Model (MPIOM) the ocean component of the MPI-Earth system model. – *Journal of Advances in Modeling Earth Systems* 5, 2, 422–446. DOI: 10.1002/JAME.20023.
- JYLHÄ, K., S. FRONZEK, H. TUOMENVIRTA, T. R. CARTER & K. RUOSTEENOJA (2008): Changes in frost, snow and Baltic sea ice by the end of the twenty-first century based on climate model projections for Europe. – *Climatic Change* 86, 441–462. DOI: 10.1007/S10584-007-9310-Z.
- KAISER, M. (1994): Mögliche Auswirkungen der globalen Klimaänderung auf Waldökosysteme der gemäßigten Breiten. In: FORSTINGENIEURE, V. W. (Hrsg.): *Waldökosysteme im globalen Klimawandel. Hintergründe und Handlungsbedarf*. Bonn: *Economica*, 49–70.

- KALLARACKAL, J. & T. J. ROBY (2012): Responses of trees to elevated carbon dioxide and climate change. – *Biodiversity and Conservation* 21, 5, 1327–1342. DOI: 10.1007/S10531-012-0254-X.
- KASPAR, F., G. MÜLLER-WESTERMEIER, E. PENDA, H. MÄCHEL, K. ZIMMERMANN, A. KAISER-WEISS & T. DEUTSCHLÄNDER (2013): Monitoring of climate change in Germany – data, products and services of Germany’s National Climate Data Centre. – *Advances in Science and Research* 10, 1, 99–106. DOI: 10.5194/ASR-10-99-2013.
- KASPAR-OTT, I., E. HERTIG, S. KASPAR, F. POLLINGER, C. RING, H. PAETH & J. JACOBET (2019): Weights for General Circulation Models from CMIP3/CMIP5 in a Statistical Downscaling Framework and the Impact on Future Mediterranean Precipitation. – *International Journal of Climatology* 39, 3639–3654. DOI: 10.1002/joc.6045.
- KELEMEN, F. D., C. PRIMO, H. FELDMANN & B. AHRENS (2019): Added Value of Atmosphere-Ocean Coupling in a Century-Long Regional Climate Simulation. – *Atmosphere* 2019, Vol. 10, Page 537 10, 9, 537. DOI: 10.3390/ATMOS10090537.
- KENDON, E. J., N. BAN, N. M. ROBERTS, H. J. FOWLER, M. J. ROBERTS, S. C. CHAN, J. P. EVANS, G. FOSSER & J. M. WILKINSON (2017): Do convection-permitting regional climate models improve projections of future precipitation change?. – *Bulletin of the American Meteorological Society* 98, 1. DOI: 10.1175/BAMS-D-15-0004.1.
- KERN, A., Z. BARCZA, H. MARJANOVIĆ, T. ÁRENDÁS, N. FODOR, P. BÓNIS, P. BOGNÁR & J. LICHTENBERGER (2018): Statistical modelling of crop yield in Central Europe using climate data and remote sensing vegetation indices. – *Agricultural and Forest Meteorology* 260-261, 300–320. DOI: 10.1016/J.AGRFORMET.2018.06.009.
- KERSEBAUM, K., J. EITZINGER, J. GLAUNINGER, K. BAUER, B. GRUMMER, M. LEXER, B. FREYER & K. FRIEDEL (2009): Auswirkungen auf die Land- und Forstwirtschaft. In: EITZINGER, J., K. C. KERSEBAUM & H. FORMAYER (Hrsg.): *Landwirtschaft im Klimawandel: Auswirkungen und Anpassungsstrategien für die Land- und Forstwirtschaft in Mitteleuropa*. Clenze: Agrimedia. ISBN 9783862630493, 83–258.
- KERSEBAUM, K. C. & C. NENDEL (2014): Site-specific impacts of climate change on wheat production across regions of Germany using different CO₂ response functions. – *European Journal of Agronomy* 52, 22–32. DOI: 10.1016/J.EJA.2013.04.005.

- KEUPP, L., E. HERTIG, I. KASPAR-OTT, F. POLLINGER, C. RING, H. PAETH & J. JACOBET (2019): Weighted multi-model ensemble projection of extreme precipitation in the Mediterranean region using statistical downscaling. – *Theoretical and Applied Climatology* 138, 3-4, 1269–1295. DOI: 10.1007/s00704-019-02851-7.
- KEUPP, L., F. POLLINGER & H. PAETH (2017): Assessment of future ENSO changes in a CMIP3/CMIP5 multi-model and multi-index framework. – *International Journal of Climatology* 37, 8, 3439–3451. DOI: 10.1002/joc.4928.
- KIRILENKO, A. P. & R. A. SEDJO (2007): Climate change impacts on forestry. DOI: 10.1073/pnas.0701424104.
- KJELLSTRÖM, E., L. BÄRRING, D. JACOB, R. JONES, G. LENDERINK & C. SCHÄR (2007): Modelling daily temperature extremes: recent climate and future changes over Europe. – *Climatic Change* 81, 249–265. DOI: 10.1007/s10584-006-9220-5.
- KLEIN TANK, A. M., J. B. WIJNGAARD, G. P. KÖNNEN, R. BÖHM, G. DEMARÉE, A. GO-CHEVA, M. MILETA, S. PASHIARDIS, L. HEJKRLIK, C. KERN-HANSEN, R. HEINO, P. BESSEMOULIN, G. MÜLLER-WESTERMEIER, M. TZANAKOU, S. SZALAI, T. PÁLSDÓTTIR, D. FITZGERALD, S. RUBIN, M. CAPALDO, M. MAUGERI, A. LEITASS, A. BUKANTIS, R. ABERFELD, A. F. V. ENGELEN, E. FORLAND, M. MIETUS, F. COELHO, C. MARES, V. RAZUVAEV, E. NIEPLOVA, T. CEGNAR, J. ANTONIO LÓPEZ, B. DAHLSTRÖM, A. MOBERG, W. KIRCHHOFER, A. CEYLAN, O. PACHALIUK, L. V. ALEXANDER & P. PETROVIC (2002): Daily dataset of 20th-century surface air temperature and precipitation series for the European Climate Assessment. – *International Journal of Climatology* 22, 12, 1441–1453. DOI: 10.1002/JOC.773.
- KLOK, E. J. & A. M. KLEIN TANK (2009): Updated and extended European dataset of daily climate observations. – *International Journal of Climatology* 29, 8, 1182–1191. DOI: 10.1002/JOC.1779.
- KNAFL, G. J. & K. DING (2016): *Adaptive Regression for Modeling Nonlinear Relationships*. Cham: Springer International Publishing.
- KNIST, S., K. GOERGEN, E. BUONOMO, O. B. CHRISTENSEN, A. COLETTE, R. M. CARDOSO, R. FEALY, J. FERNÁNDEZ, M. GARCÍA-DÍEZ, D. JACOB, S. KARTSIOS, E. KATRAGKOU, K. KEULER, S. MAYER, E. V. MEIJGAARD, G. NIKULIN, P. M. SOARES, S. SOBO-

- LOWSKI, G. SZEPSZO, C. TEICHMANN, R. VAUTARD, K. WARRACH-SAGI, V. WULFMEYER & C. SIMMER (2017): Land-atmosphere coupling in EURO-CORDEX evaluation experiments. – *Journal of Geophysical Research: Atmospheres* 122, 1, 79–103. DOI: 10.1002/2016JD025476.
- KNUTTI, R., R. FURRER, C. TEBALDI, J. CERMAK & G. A. MEEHL (2010): Challenges in combining projections from multiple climate models. – *Journal of Climate* 23, 10, 2739–2758. DOI: 10.1175/2009JCLI3361.1.
- KOCH, B., F. OEHL, B. KOCH & F. OEHL (2018): Climate Change Favors Grapevine Production in Temperate Zones. – *Agricultural Sciences* 9, 3, 247–263. DOI: 10.4236/AS.2018.93019.
- KÖHL, M., D. PLUGGE, M. GUTSCH, P. LASCH-BORN, M. MÜLLER & C. REYER (2017): Wald und Forstwirtschaft. In: BRASSEUR, G. P., D. JACOB & S. SCHUCK-ZÖLLER (Hrsg.): *Klimawandel in Deutschland*. Berlin, Heidelberg: Springer, 193–201. DOI: 10.1007/978-3-662-50397-3_19.
- KÖLLING, C. (2007a): Bäume für die Zukunft. Baumartenwahl in Zeiten des Klimawandels. – *LWF Waldforschung aktuell* 60, 35–37.
- KÖLLING, C. (2007b): Klimahüllen für 27 Waldbaumarten. – *AFZ-DerWald* 23, 1242–1245.
- KÖLLING, C., W. FALK & H. WALENTOWSKI (2011): Standörtliche Möglichkeiten für den Anbau der Tanne (*Abies alba* und *Abies grandis*) in Bayern. – *LWF Wissen* 66, 11–19.
- KÖLLING, C., H. WALENTOWSKI & H. BORCHERT (2005): Die Buche in Mitteleuropa. – *AFZ-DerWald* 13, 696–701.
- KONNERT, M. (2007): Bedeutung der Herkunft beim Klimawandel. Genetische Ausstattung der Waldbäume ist Grundlage für ihre Anpassungsfähigkeit. – *LWF Waldforschung aktuell* 60, 38–39.
- KOTLARSKI, S., K. KEULER, O. B. CHRISTENSEN, A. COLETTE, M. DÉQUÉ, A. GOBIET, K. GOERGEN, D. JACOB, D. LÜTHI, E. V. MEIJGAARD, G. NIKULIN, C. SCHÄR, C. TEICHMANN, R. VAUTARD, K. WARRACH-SAGI & V. WULFMEYER (2014): Regional climate modeling on European scales: A joint standard evaluation of the EURO-CORDEX RCM ensemble. – *Geoscientific Model Development* 7, 4, 1297–1333. DOI: 10.5194/GMD-7-1297-2014.

- KRAPP, M. & J. NEBEL (2011): *Methoden der Statistik*. Wiesbaden: Vieweg+Teubner.
- KRISTENSEN, K., K. SCHELDE & J. E. OLESEN (2011): Winter wheat yield response to climate variability in Denmark. – *The Journal of Agricultural Science* 149, 1, 33–47. DOI: 10.1017/S0021859610000675.
- KURUKULASURIYA, P. & S. ROSENTHAL (2003): *Climate Change and Agriculture. A Review of Impacts and Adaptations*. Washington: The World Bank.
- KULLA, L., J. ROESSIGER, M. BOŠEL'A, S. KUCBEL, V. MURGAŠ, J. VENCURIK, J. PITNER, P. JALOVJAR, L. ŠUMICHRASŤ & M. SANIGA (2023): Changing patterns of natural dynamics in old-growth European beech (*Fagus sylvatica* L.) forests can inspire forest management in Central Europe. – *Forest Ecology and Management* 529, 120633. DOI: 10.1016/J.FORECO.2022.120633.
- LAFON, T., S. DADSON, G. BUYS & C. PRUDHOMME (2013): Bias correction of daily precipitation simulated by a regional climate model: a comparison of methods. – *International Journal of Climatology* 33, 6, 1367–1381. DOI: 10.1002/joc.3518.
- LANDESANSTALT FÜR LANDWIRTSCHAFT, ERNÄHRUNG UND LÄNDLICHEN RAUM (LEL) & LANDESANSTALT FÜR LANDWIRTSCHAFT (LFL) (2022): *Agrarmärkte 2021*. Schwäbisch-Gmünd: LEL, Freising-Weihenstephan: LfL.
- LANGE, S. (2017): *ISIMIP2b bias-correction fact sheet*. Potsdam: Potsdam Institute for Climate Impact Research.
- LASCH-BORN, P., F. SUCKOW, M. GUTSCH, C. REYER, Y. HAUF, A. MURAWSKI & T. PILZ (2015): Forests under climate change: Potential risks and opportunities. – *Meteorologische Zeitschrift* 24, 2. DOI: 10.1127/metz/2014/0526.
- LATIF, M. (2009): *Klimawandel und Klimadynamik*. Stuttgart: UTB Ulmer.
- LEOLINI, L., M. MORIONDO, G. FILA, S. COSTAFREDA-AUMEDES, R. FERRISE & M. BINDI (2018): Late spring frost impacts on future grapevine distribution in Europe. – *Field Crops Research*, 222, 197–208. DOI: 10.1016/j.fcr.2017.11.018.
- LI, C., F. ZWIERS, X. ZHANG, G. LI, Y. SUN & M. WEHNER (2021): Changes in Annual Extremes of Daily Temperature and Precipitation in CMIP6 Models. – *Journal of Climate* 34, 3441–3460. DOI: 10.1175/JCLI-D-19-1013.1.

- LINDNER, M., J. B. FITZGERALD, N. E. ZIMMERMANN, C. REYER, S. DELZON, E. VAN DER MAATEN, M.-J. SCHELHAAS, P. LASCH, J. EGGERS, M. VAN DER MAATEN-THEUNISSEN, F. SUCKOW, A. PSOMAS, B. POULTER & M. HANEWINKEL (2014): Climate change and European forests: What do we know, what are the uncertainties, and what are the implications for forest management?. – *Journal of Environmental Management* 146, 69–83. DOI: 10.1016/J.JENVMAN.2014.07.030.
- LISCHEID, G., H. WEBBER, M. SOMMER, C. NENDEL & F. EWERT (2022): Machine learning in crop yield modelling: A powerful tool, but no surrogate for science. – *Agricultural and Forest Meteorology* 312. DOI: 10.1016/j.agrformet.2021.108698.
- LLOPART, M., M. S. REBOITA & R. P. DA ROCHA (2020): Assessment of multi-model climate projections of water resources over South America CORDEX domain. – *Climate Dynamics* 54, 1-2, 99–116. DOI: 10.1007/S00382-019-04990-Z.
- LOBELL, D. B. & M. B. BURKE (2010): On the use of statistical models to predict crop yield responses to climate change. – *Agricultural and Forest Meteorology* 150, 11, 1443–1452. DOI: 10.1016/J.AGRFORMET.2010.07.008.
- LOTH, G., G. GEYER, U. HOFFMANN, E. JOBE, U. LAGALLY, R. LOTH, T. PÜRNER, H. WEINIG & J. ROHRMÜLLER (2013): *Geotope in Unterfanken*. Augsburg: LfU.
- LÜTTGER, A. B. & T. FEIKE (2018): Development of heat and drought related extreme weather events and their effect on winter wheat yields in Germany. – *Theoretical and Applied Climatology* 132, 1-2, 15–29. DOI: 10.1007/S00704-017-2076-Y.
- MACHOLDT, J., F. ELLMER, G. BARTHELMES & M. BAUMECKER (2013): Zur Ökostabilität von Winterroggensorten unter Standortbedingungen Brandenburgs. – *Journal für Kulturpflanzen* 65, 6, 217–226. DOI: 10.5073/JFK.2013.06.01.
- MACHOLDT, J. & B. HONERMEIER (2016): Impact of Climate Change on Cultivar Choice: Adaptation Strategies of Farmers and Advisors in German Cereal Production. – *Agronomy* 2016, Vol. 6, Page 40 6, 3, 40. DOI: 10.3390/AGRONOMY6030040.
- MAHER, N., F. LEHNER & J. MAROTZKE (2020): Quantifying the role of internal variability in the temperature we expect to observe in the coming decades. – *Environmental Research Letters* 15, 054014. DOI: 10.1088/1748-9326/AB7D02.

- MAIER, U. & G. MÜLLER-WESTERMEIER (2010): Verifikation klimatologischer Rasterfelder, Berichte des Deutschen Wetterdienstes 235. Offenbach: Selbstverlag des Deutschen Wetterdienstes.
- MAJEWSKI, D. (1991): The EUROPA-modell of the Deutscher Wetterdienst. – Seminar on Numerical Methods in Atmospheric Models, 9-13 September 1991 II, 147–193.
- MÄKINEN, H., J. KASEVA, M. TRNKA, J. BALEK, K. C. KERSEBAUM, C. NENDEL, A. GOBIN, J. E. OLESEN, M. BINDI, R. FERRISE, M. MORIONDO, A. RODRÍGUEZ, M. RUIZ-RAMOS, J. TAKÁČ, P. BEZÁK, D. VENTRELLA, F. RUGET, G. CAPELLADES & H. KAHILUOTO (2018): Sensitivity of European wheat to extreme weather. – *Field Crops Research* 222, 209–217. DOI: 10.1016/J.FCR.2017.11.008.
- MARAUN, D. (2016): Bias Correcting Climate Change Simulations - a Critical Review. – *Current Climate Change Reports* 2, 4, 211–220. DOI: 10.1007/s40641-016-0050-x.
- MARAUN, D., F. WETTERHALL, A. M. IRESON, R. E. CHANDLER, E. J. KENDON, M. WIDMANN, S. BRIENEN, H. W. RUST, T. SAUTER, M. THEMEL, V. K. VENEMA, K. P. CHUN, C. M. GOODESS, R. G. JONES, C. ONOF, M. VRAC & I. THIELE-EICH (2010): Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. – *Reviews of Geophysics* 48, 3. DOI: 10.1029/2009RG000314.
- MARAUN, D. & M. WIDMANN (2018): Statistical downscaling and bias correction for climate research. Cambridge: Cambridge University Press.
- MARTINEZ DEL CASTILLO, E., C. S. ZANG, A. BURAS, A. HACKET-PAIN, J. ESPER, R. SERRANO-NOTIVOLI, C. HARTL, R. WEIGEL, S. KLESSE, V. R. DE DIOS, T. SCHARNWEBER, I. DORADO-LIÑÁN, M. VAN DER MAATEN-THEUNISSEN, E. VAN DER MAATEN, A. JUMP, S. MIKAC, B. E. BANZRAGCH, W. BECK, L. CAVIN, H. CLAESSENS, V. ČADA, K. ČUFAR, C. DULAMSUREN, J. GRIČAR, E. GIL-PELEGRÍN, P. JANDA, M. KAZIMIROVIC, J. KREYLING, N. LATTE, C. LEUSCHNER, L. A. LONGARES, A. MENZEL, M. MERELA, R. MOTTA, L. MUFFLER, P. NOLA, A. M. PETRITAN, I. C. PETRITAN, P. PRISLAN, ÁLVARO RUBIO-CUADRADO, M. RYDVAL, B. STAJIĆ, M. SVOBODA, E. TOROMANI, V. TROTSIUK, M. WILMKING, T. ZLATANOV & M. DE LUIS (2022): Climate-change-driven growth decline of European beech forests. – *Communications Biology* 2022 5:1 5, 1, 1–9. DOI: 10.1038/s42003-022-03107-3.

- MARTINS, J., H. FRAGA, A. FONSECA & J. A. SANTOS (2021): Climate Projections for Precipitation and Temperature Indicators in the Douro Wine Region: The Importance of Bias Correction. – *Agronomy* 2021, Vol. 11, Page 990 11, 5, 990. DOI: 10.3390/AGRONOMY11050990.
- MASSON-DELMOTTE, V., P. ZHAI, A. PIRANI, S. CONNORS, C. PÉAN, S. BERGER, N. CAUD, Y. CHEN, L. GOLDFARB, M. GOMIS, M. HUANG, K. LEITZELL, E. LONNOY, J. MATTHEWS, T. MAYCOCK, T. WATERFIELD, O. YELEKÇI, R. YU & B. ZHOU (Hrsg.) (2021): *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press.
- MATTHEWS, J. B. R., J. S. FUGLESTVEDT, V. MASSON-DELMOTTE, V. MÖLLER, C. MANS R. VAN DIEMEN, A. REISINGER & S. (2021): Glossary. In: MASSON-DELMOTTE, V., P. ZHAI, A. PIRANI, S. CONNORS, C. PÉAN, S. BERGER, N. CAUD, Y. CHEN, L. GOLDFARB, M. GOMIS, M. HUANG, K. LEITZELL, E. LONNOY, J. MATTHEWS, T. MAYCOCK, T. WATERFIELD, O. YELEKÇI, R. YU & B. ZHOU (Hrsg.): *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press.
- MCCULLAGH, P. J. & J. A. NELDER (1989): *Generalized Linear Models*. London: Chapman and Hall.
- MEGGIO, F., B. PRINSI, A. S. NEGRI, G. S. D. LORENZO, G. LUCCHINI, A. PITACCO, O. FAILLA, A. SCIENZA, M. COCUCCI & L. ESPEN (2014): Biochemical and physiological responses of two grapevine rootstock genotypes to drought and salt treatments. – *Australian Journal of Grape and Wine Research* 20, 2, 310–323. DOI: 10.1111/AJGW.12071.
- MEREDITH, E. P., U. ULBRICH, H. W. RUST & H. TRUHETZ (2021): Present and future diurnal hourly precipitation in 0.11° EURO-CORDEX models and at convection-permitting resolution. – *Environmental Research Communications* 3, 5, 055002. DOI: 10.1088/2515-7620/ABF15E.
- METTE, T., K. DOLOS, C. MEINARDUS, A. BRÄUNING, B. REINEKING, M. BLASCHKE, H. PRETZSCH, C. BEIERKUHNLIN, A. GOHLKE, C. WELLSTEIN, C. . METTE, K. DOLOS, C. MEINARDUS, A. BRÄUNING, B. REINEKING, M. BLASCHKE, H. PRETZSCH,

- C. BEIERKUHNLEIN, A. GOHLKE & C. WELLSTEIN (2013): Climatic turning point for beech and oak under climate change in Central Europe. – *Ecosphere* 4, 12, 1–19. DOI: 10.1890/ES13-00115.1.
- MIEDANER, T. (2018): *Genusspflanzen*. Berlin: Springer.
- MINISTERIUM FÜR UMWELT, KLIMA UND ENERGIEWIRTSCHAFT BADEN-WÜRTTEMBERG (UMBW) (2016): *Klimawandel in Baden-Württemberg*. Stuttgart: UMBW.
- MÖGES, M. (2007): Klima-Konzept für den Staatswald. – *LWF Waldforschung aktuell* 60, 42–44.
- MOORE, F. C. & D. B. LOBELL (2014): Adaptation potential of European agriculture in response to climate change. – *Nature Climate Change* 4, 7, 610–614. DOI: 10.1038/nclimate2228.
- MOORE, F. C. & D. B. LOBELL (2015): The fingerprint of climate trends on european crop yields. – *Proceedings of the National Academy of Sciences of the United States of America* 112, 9, 2970–2975. DOI: 10.1073/PNAS.1409606112.
- MORIONDO, M., G. V. JONES, B. BOIS, C. DIBARI, R. FERRISE, G. TROMBI & M. BINDI (2013): Projected shifts of wine regions in response to climate change. – *Climatic Change* 119, 3-4, 825–839. DOI: 10.1007/S10584-013-0739-Y.
- MÜLLER, J. (1996): *Grundzüge der Naturgeographie von Unterfranken. Landschaftsökologie - Landschaftsgenese - landschaftsräumlicher Vergleich*. Gotha: Perthes.
- MÜLLER-WESTERMEIER, G. (1995): *Numerische Verfahren zur Erstellung klimatologischer Karten*, Berichte des Deutschen Wetterdienstes 193. Offenbach: Selbstverlag des Deutschen Wetterdienstes.
- NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. NATIONAL CENTERS FOR ENVIRONMENTAL INFORMATION (NOAA NCEI) (2022): *Climate at a Glance: Global Time Series*. <<https://www.ncdc.noaa.gov/cag/>>. (Stand: 2022) (Zugriff: 2022-03-31).
- NELSON, G. C., H. VALIN, R. D. SANDS, P. HAVLÍK, H. AHAMMAD, D. DERYNG, J. ELLIOTT, S. FUJIMORI, T. HASEGAWA, E. HEYHOE, P. KYLE, M. V. LAMPE, H. LOTZECAMPEN, D. M. D’CROZ, H. VAN MEIJL, D. VAN DER MENSBRUGGHE, C. MÜLLER, A. POPP, R. ROBERTSON, S. ROBINSON, E. SCHMID, C. SCHMITZ, A. TABEAU &

- D. WILLENBOCKEL (2014): Climate change effects on agriculture: economic responses to biophysical shocks.. – Proceedings of the National Academy of Sciences of the United States of America 111, 9, 3274–9. DOI: 10.1073/pnas.1222465110.
- NEUMANN, P. A. & A. MATZARAKIS (2011): Viticulture in southwest Germany under climate change conditions. DOI: 10.3354/cr01000.
- NEUMANN, P. A. & A. MATZARAKIS (2014): Potential climate change impacts on winegrape must density and titratable acidity in southwest Germany. – Climate Research 59, 2. DOI: 10.3354/cr01216.
- NICHOLLS, N. & W. MURRAY (1999): Workshop on Indices and Indicators for Climate Extremes: Asheville, NC, USA, 3–6 June 1997 Breakout Group B: Precipitation. – Climatic Change 42, 1, 23–29. DOI: 10.1023/A:1005495627778.
- OLESEN, J. E., M. TRNKA, K. C. KERSEBAUM, A. O. SKJELVÅG, B. SEGUIN, P. PELTONEN-SAINIO, F. ROSSI, J. KOZYRA & F. MICALE (2011): Impacts and adaptation of European crop production systems to climate change. – European Journal of Agronomy 34, 2, 96–112. DOI: 10.1016/j.eja.2010.11.003.
- OBLADEN, N., P. DECHERING, G. SKIADARETIS, W. TEGEL, J. KESSLER, S. HÖLLERL, S. KAPS, M. HERTEL, C. DULAMSUREN, T. SEIFERT, M. HIRSCH & A. SEIM (2021): Tree mortality of European beech and Norway spruce induced by 2018-2019 hot droughts in central Germany. – Agricultural and Forest Meteorology 307, 108482. DOI: 10.1016/J.AGRFORMET.2021.108482.
- ORLOWSKY, B., F. W. GERSTENGARBE & P. C. WERNER (2008): A resampling scheme for regional climate simulations and its performance compared to a dynamical RCM. – Theoretical and Applied Climatology 92, 3-4, 209–223. DOI: 10.1007/S00704-007-0352-Y.
- OTU-LARBI, F., A. CONTE, S. FARES, O. WILD & K. ASHWORTH (2020): Current and future impacts of drought and ozone stress on Northern Hemisphere forests. – Global Change Biology 26, 11, 6218–6234. DOI: 10.1111/GCB.15339.
- PAETH, H. (2007): Klimamodellsimulationen. In: ENDLICHER, W. & F.-W. GERSTENGARBE (Hrsg.): Der Klimawandel – Einblicke, Rückblicke und Ausblicke. Potsdam: PIK, 44–55.

- PAETH, H. (2011): Postprocessing of simulated precipitation for impact research in West Africa. Part I: model output statistics for monthly data. – *Climate Dynamics* 36, 7-8, 1321–1336. DOI: 10.1007/s00382-010-0760-z.
- PAETH, H., A. CAPO-CHICHI & W. ENDLICHER (2008): Climate change and food security in tropical West Africa - A dynamic-statistical modelling approach. – *Erdkunde* 62, 2, 101–115. DOI: 10.3112/ERDKUNDE.2008.02.01.
- PAETH, H. & M. DIEDERICH (2011): Postprocessing of simulated precipitation for impact research in West Africa. Part II: A weather generator for daily data. – *Climate Dynamics* 36, 7, 1337–1348. DOI: 10.1007/s00382-010-0840-0.
- PAETH, H. & A. HENSE (2003): Seasonal forecast of sub-sahelian rainfall using cross validated model output statistics. – *Meteorologische Zeitschrift* 12, 3, 157–173. DOI: 10.1127/0941-2948/2003/0012-0157.
- PAETH, H., J. HETZEL & B. MANNIG (2015): Uncertainties in the assessment of future temperature and precipitation extremes in central Europe. – *Erdkunde* 69, 3, 247–265. DOI: 10.3112/erdkunde.2015.03.04.
- PAETH, H. & B. MANNIG (2013): On the added value of regional climate modeling in climate change assessment. – *Climate Dynamics* 41, 3-4, 1057–1066. DOI: 10.1007/s00382-012-1517-7.
- PASSEL, S. V., E. MASSETTI & R. MENDELSON (2017): A Ricardian Analysis of the Impact of Climate Change on European Agriculture. – *Environmental and Resource Economics* 67, 4, 725–760. DOI: 10.1007/S10640-016-0001-Y.
- PEEL, M. C., B. L. FINLAYSON & T. A. MCMAHON (2007): Updated world map of the Köppen-Geiger climate classification. – *Hydrology and Earth System Sciences* 11, 5, 1633–1644. DOI: 10.5194/HESS-11-1633-2007.
- PEICHL, M., S. THOBER, V. MEYER & L. SAMANIEGO (2018): The effect of soil moisture anomalies on maize yield in Germany. – *Natural Hazards and Earth System Sciences* 18, 3, 889–906. DOI: 10.5194/NHESS-18-889-2018.
- PEICHL, M., S. THOBER, L. SAMANIEGO, B. HANSJÜRGENS & A. MARX (2019): Climate impacts on long-term silage maize yield in Germany. – *Scientific Reports* 2019 9:1 9, 1, 1–12. DOI: 10.1038/s41598-019-44126-1.

- PELLICONE, G., T. CALOIERO & I. GUAGLIARDI (2019): The De Martonne aridity index in Calabria (Southern Italy). – *Journal of Maps* 15, 2, 788–796. DOI: 10.1080/17445647.2019.1673840.
- PELTONEN-SAINIO, P., L. JAUHAINEN, M. TRNKA, J. E. OLESEN, P. CALANCA, H. ECKERSTEN, J. EITZINGER, A. GOBIN, K. C. KERSEBAUM, J. KOZYRA, S. KUMAR, A. D. MARTA, F. MICALÈ, B. SCHAAP, B. SEGUIN, A. O. SKJELVÅG & S. ORLANDINI (2010): Coincidence of variation in yield and climate in Europe. – *Agriculture, Ecosystems & Environment* 139, 4, 483–489. DOI: 10.1016/j.agee.2010.09.006.
- PETERSON, T. C., C. C. FOLLAND, G. GRUZA, W. HOGG, A. MOKSSIT & N. PLUMMER (2001): Report on the activities of the Working Group on Climate Change Detection and Related Rapporteurs 1998–2001. WMO Report WCDMP-47, WMO-TD 1071. Genf: WMO.
- PEUKE, A. D., C. SCHRAML, W. HARTUNG & H. RENNENBERG (2002): Identification of drought-sensitive beech ecotypes by physiological parameters. – *New Phytologist* 154, 2, 373–387. DOI: 10.1046/J.1469-8137.2002.00400.X.
- PIANI, C., J. O. HAERTER & E. COPPOLA (2010a): Statistical bias correction for daily precipitation in regional climate models over Europe. – *Theoretical and Applied Climatology* 99, 1-2, 187–192. DOI: 10.1007/s00704-009-0134-9.
- PIANI, C., G. WEEDON, M. BEST, S. GOMES, P. VITERBO, S. HAGEMANN & J. HAERTER (2010b): Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models. – *Journal of Hydrology* 395, 3-4, 199–215. DOI: 10.1016/J.JHYDROL.2010.10.024.
- PIRTTIOJA, N., T. R. CARTER, S. FRONZEK, M. BINDI, H. HOFFMANN, T. PALOSUO, M. RUIZ-RAMOS, F. TAO, M. TRNKA, M. ACUTIS, S. ASSENG, P. BARANOWSKI, B. BASSO, P. BODIN, S. BUIS, D. CAMMARANO, P. DELIGIOS, M. F. DESTAIN, B. DUMONT, F. EWERT, R. FERRISE, L. FRANÇOIS, T. GAISER, P. HLAVINKA, I. JACQUEMIN, K. C. KERSEBAUM, C. KOLLAS, J. KRZYSZCZAK, I. J. LORITE, J. MINET, M. I. MINGUEZ, M. MONTESINO, M. MORIONDO, C. MÜLLER, C. NENDEL, I. ÖZTÜRK, A. PEREGO, A. RODRÍGUEZ, A. C. RUANE, F. RUGET, M. SANNA, M. A. SEMENOV, C. SLAWINSKI, P. STRATONOVITCH, I. SUPIT, K. WAHA, E. WANG, L. WU, Z. ZHAO & R. P. RÖTTER (2015): Temperature and precipitation effects on wheat yield across a European transect: a

- crop model ensemble analysis using impact response surfaces. – *Climate Research* 65, 87–105. DOI: 10.3354/CR01322.
- POLLINGER, F. (2013): Bewertung und Auswirkungen der Simulationsgüte führender Klimamoden in einem Multi-Modell Ensemble. Dissertation. Würzburg: Julius-Maximilians-Universität.
- POLLINGER, F., K. ZIEGLER, D. ABEL & H. PAETH (2020): Effects of a new land surface parametrization scheme on thermal extremes in a Regional Climate Model. EGU General Assembly 2020, Online, 4–8 May 2020, EGU2020-16320. DOI: 10.5194/EGUSPHERE-EGU2020-16320.
- POLLINGER, F., K. ZIEGLER & H. PAETH (2017): Comparison of the performance of three types of multiple regression for phenology in bavaria in a dynamical-statistical model approach. – *Erdkunde* 71, 271–285. DOI: 10.3112/ERDKUNDE.2017.04.01.
- PORTER, J. R. & M. A. SEMENOV (2005): Crop responses to climatic variation. – *Philosophical Transactions of the Royal Society B: Biological Sciences* 360, 1463, 2021–2035. DOI: 10.1098/RSTB.2005.1752.
- PREIN, A. F., A. GOBIET, H. TRUHETZ, K. KEULER, K. GOERGEN, C. TEICHMANN, C. F. MAULE, E. VAN MEIJGAARD, M. DÉQUÉ, G. NIKULIN, R. VAUTARD, A. COLETTE, E. KJELLSTRÖM & D. JACOB (2016): Precipitation in the EURO-CORDEX 0.11° and 0.44° simulations: high resolution, high benefits?. – *Climate Dynamics* 46, 1-2. DOI: 10.1007/s00382-015-2589-y.
- PRETZSCH, H., P. BIBER, G. SCHÜTZE, J. KEMMERER & E. UHL (2018): Wood density reduced while wood volume growth accelerated in Central European forests since 1870. – *Forest Ecology and Management* 429, 589–616. DOI: 10.1016/J.FORECO.2018.07.045.
- PRUSCHA, H. (2006): Statistisches Methodenbuch Verfahren, Fallstudien, Programmcodes. Berlin, Heidelberg: Springer.
- PURR, C., E. BRISSON & B. AHRENS (2021): Convective rain cell characteristics and scaling in climate projections for Germany. – *International Journal of Climatology* 41, 5, 3174–3185. DOI: 10.1002/JOC.7012.

- RAJCZAK, J. & C. SCHÄR (2017): Projections of Future Precipitation Extremes Over Europe: A Multimodel Assessment of Climate Simulations. – *Journal of Geophysical Research: Atmospheres* 122, 20, 10,773–10,800. DOI: 10.1002/2017JD027176.
- RAKOVEC, O., L. SAMANIEGO, V. HARI, Y. MARKONIS, V. MORAVEC, S. THOBER, M. HANEL & R. KUMAR (2022): The 2018–2020 Multi-Year Drought Sets a New Benchmark in Europe. – *Earth's Future* 10, 3, e2021EF002394. DOI: 10.1029/2021EF002394.
- RANDALL, D., R. WOOD, S. BONY, R. COLMAN, T. FICHEFET, J. FYFE, V. KATTSOV, A. PITMAN, J. SHUKLA, J. SRINIVASAN, R. STOUFFER, A. SUMI & K. TAYLOR (2007): Climate Models and Their Evaluation. In: SOLOMON, S., D. QIN, M. MANNING, Z. CHEN, M. MARQUIS, K. B. AVERYT, M. TIGNOR & H. L. MILLER (Hrsg.): *Climate Change 2007. The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press, 589–662.
- RAUH, E. (2020): Persönliche Kommunikation mit KMU-Partner Ernst Rauh (Landwirt und Saatgutspezialist) am 21.12.2020 zu üblichen Saat- und Ernteterminen.
- RAUH, J. & H. PAETH (2011): Anthropogener Klimawandel und Weinwirtschaft – Wahrnehmung und Anpassungsmaßnahmen fränkischer Winzer auf den Wandel klimatischer Bedingungen. – *Berichte zur deutschen Landeskunde* 85, 151–177.
- REISSENWEBER, U. & F. POHL (2019): Unser Wald in Not aber nicht ohne Hoffnung. – *Casteller Nachrichten* 49, 10–14.
- REISSENWEBER, U. & F. POHL (2021): Unser Wald in Not aber nicht ohne Hoffnung. – *Abhandlungen des Naturwissenschaftlichen Vereins Würzburg* 54, 40–48.
- REYER, C., P. LASCH-BORN, F. SUCKOW, M. GUTSCH, A. MURAWSKI & T. PILZ (2014): Projections of regional changes in forest net primary productivity for different tree species in Europe driven by climate change and carbon dioxide. – *Annals of Forest Science* 71, 2, 211–225. DOI: 10.1007/S13595-013-0306-8.
- REYER, C. P., S. BATHGATE, K. BLENNOW, J. G. BORGES, H. BUGMANN, S. DELZON, S. P. FAIAS, J. GARCIA-GONZALO, B. GARDINER, J. R. GONZALEZ-OLABARRIA, C. GRACIA, J. G. HERNÁNDEZ, S. KELLOMÄKI, K. KRAMER, M. J. LEXER, M. LINDNER, E. V. D.

- MAATEN, M. MAROSCHEK, B. MUYS, B. NICOLL, M. PALAHI, J. H. PALMA, J. A. PAULO, H. PELTOLA, T. PUKKALA, W. RAMMER, D. RAY, S. SABATÉ, M. J. SCHELHAAS, R. SEIDL, C. TEMPERLI, M. TOMÉ, R. YOUSEFPOUR, N. E. ZIMMERMANN & M. HANEWINKEL (2017): Are forest disturbances amplifying or canceling out climate change-induced productivity changes in European forests?. – *Environmental Research Letters* 12, 3, 034027. DOI: 10.1088/1748-9326/AA5EF1.
- REZAEI, E. E., S. SIEBERT, H. HÜGING & F. EWERT (2018): Climate change effect on wheat phenology depends on cultivar change. – *Scientific Reports* 2018 8:1 8, 1, 1–10. DOI: 10.1038/s41598-018-23101-2.
- REZAEI, E. E., H. WEBBER, T. GAISER, J. NAAB & F. EWERT (2015): Heat stress in cereals: Mechanisms and modelling. – *European Journal of Agronomy* 64, 98–113. DOI: 10.1016/J.EJA.2014.10.003.
- RIAHI, K., S. RAO, V. KREY, C. CHO, V. CHIRKOV, G. FISCHER, G. KINDERMANN, N. NAKICENOVIC & P. RAFAJ (2011): RCP 8.5—A scenario of comparatively high greenhouse gas emissions. – *Climatic Change* 2011 109:1 109, 1, 33–57. DOI: 10.1007/S10584-011-0149-Y.
- RIEDIGER, J., B. BRECKLING, R. S. NUSKE & W. SCHRÖDER (2014): Will climate change increase irrigation requirements in agriculture of Central Europe? A simulation study for Northern Germany. – *Environmental Sciences Europe* 26, 1, 18. DOI: 10.1186/s12302-014-0018-1.
- RIO, C., A. D. D. GENIO & F. HOURDIN (2019): Ongoing Breakthroughs in Convective Parameterization. – *Current Climate Change Reports* 2019 5, 2, 95–111. DOI: 10.1007/S40641-019-00127-W.
- ROSENZWEIG, C., J. ELLIOTT, D. DERYNG, A. C. RUANE, C. MÜLLER, A. ARNETH, K. J. BOOTE, C. FOLBERTH, M. GLOTTER, N. KHABAROV, K. NEUMANN, F. PIONTEK, T. A. M. PUGH, E. SCHMID, E. STEHFEST, H. YANG & J. W. JONES (2014): Assessing agricultural risks of climate change in the 21st century in a global gridded crop model intercomparison.. – *Proceedings of the National Academy of Sciences of the United States of America* 111, 9, 3268–3273. DOI: 10.1073/pnas.1222463110.
- RYBKA, H., M. HALLER, S. BRIENEN, J. BRAUCH, B. FRÜH, T. JUNGHÄNEL, K. LENGFELD, A. WALTER & T. WINTERRATH (2022): Convection-permitting climate simulations

- with COSMO-CLM for Germany: Analysis of present and future daily and sub-daily extreme precipitation. – *Meteorologische Zeitschrift Preprint*. DOI: 10.1127/METZ/2022/1147.
- SACHINDRA, D. A., F. HUANG, A. BARTON & B. J. C. PERERA (2014): Statistical downscaling of general circulation model outputs to precipitation-part 1: Calibration and validation. – *International Journal of Climatology* DOI: 10.1002/joc.3914.
- SARVINA, Y., T. PLUNTKE & C. BERNHOFER (2018): Comparing bias correction methods to improve modelled precipitation extremes. – *Jurnal Meteorologi dan Geofisika* 19, 2, 103–110. DOI: 10.31172/JMG.V19I2.449.
- SCHALLER, M. & H.-J. WEIGEL (2007): Analyse des Sachstands zu Auswirkungen von Klimaveränderungen auf die deutsche Landwirtschaft und Maßnahmen zur Anpassung. *Landbauforschung Völkenrose. Sonderheft 136*. Braunschweig: Bundesforschungsanstalt für Landwirtschaft.
- SCHAUBERGER, B., T. BEN-ARI, D. MAKOWSKI, T. KATO, H. KATO & P. CIAIS (2018): Yield trends, variability and stagnation analysis of major crops in France over more than a century. – *Scientific Reports* 8, 1, 1–12. DOI: 10.1038/s41598-018-35351-1.
- SCHENK, W. (2007): Vor- und frühindustrielle (Kultur-)Landschaft. In: GLASER, R., H. GEBHARDT & W. SCHENK (Hrsg.): *Geographie Deutschlands*. Darmstadt: Wissenschaftliche Buchgesellschaft, 159–169.
- SCHINDLER, A., A. TORETI, M. ZAMPIERI, E. SCOCCIMARRO, S. GUALDI, S. FUKUTOME, E. XOPLAKI & J. LUTERBACHER (2015): On the Internal Variability of Simulated Daily Precipitation. – *Journal of Climate* 28, 3624–3630. DOI: 10.1175/JCLI-D-14-00745.1.
- SCHMIDT, H., V. EYRING, M. LATIF, D. RECHID, R. SAUSEN, D. JACOB & C. KOTTMEIER (2017): Globale Sicht des Klimawandels. In: BRASSEUR, G. P., D. JACOB & S. SCHUCKZÖLLER (Hrsg.): *Klimawandel in Deutschland*. Berlin, Heidelberg: Springer, 7–16. DOI: 10.1007/978-3-662-50397-3_2.
- SCHMIDT, M., D. KLEIN, C. CONRAD, S. DECH & H. PAETH (2014): On the relationship between vegetation and climate in tropical and northern Africa. – *Theoretical and Applied Climatology* 115, 1-2, 341–353. DOI: 10.1007/S00704-013-0900-6.
- SCHÖNWIESE, C.-D. (2006): *Praktische Statistik für Meteorologen und Geowissenschaftler*. 4. Auflage. Stuttgart: Gebrüder Borntraeger.

- SCHOPFER, P. & A. BRENNICKE (2010): *Pflanzenphysiologie*. Berlin, Heidelberg: Springer.
- SCHULDT, B., A. BURAS, M. AREND, Y. VITASSE, C. BEIERKUHNEIN, A. DAMM, M. GHARUN, T. E. GRAMS, M. HAUCK, P. HAJEK, H. HARTMANN, E. HILTBRUNNER, G. HOCH, M. HOLLOWAY-PHILLIPS, C. KÖRNER, E. LARYSCH, T. LÜBBE, D. B. NELSON, A. RAMMIG, A. RIGLING, L. ROSE, N. K. RUEHR, K. SCHUMANN, F. WEISER, C. WERNER, T. WOHLGEMUTH, C. S. ZANG & A. KAHMEN (2020): A first assessment of the impact of the extreme 2018 summer drought on Central European forests. – *Basic and Applied Ecology* 45, 86–103. DOI: 10.1016/J.BAAE.2020.04.003.
- SCHULTZ, H. R. (2016): Global Climate Change, Sustainability, and Some Challenges for Grape and Wine Production. – *Journal of Wine Economics* 11, 1, 181–200. DOI: 10.1017/JWE.2015.31.
- SCHULTZ, H. R. & G. V. JONES (2010): Climate Induced Historic and Future Changes in Viticulture. – <https://doi.org/10.1080/09571264.2010.530098> 21, 2, 137–145. DOI: 10.1080/09571264.2010.530098.
- SCHULZ, C. & C. KÖLLING (2007): Anpassung und Milderung. Wälder entlasten als CO₂-Senke die Atmosphäre, werden aber gleichzeitig durch den Klimawandel belastet. – *LWF Waldforschung aktuell* 6, 18–20.
- SCHWAB, A., M. PETERNEL & E. GREBNER (2004): Ertragsregulierung. Einfluss auf Mostinhaltsstoffe und Weinbewertung. – *Rebe und Wein* 6.
- SCHWALM, C. R., S. GLENDON & P. B. DUFFY (2020): RCP8.5 tracks cumulative CO₂ emissions. – *Proceedings of the National Academy of Sciences* 117, 33, 19656–19657. DOI: 10.1073/PNAS.2007117117.
- SCHWINGSHACKL, C., E. L. DAVIN, M. HIRSCHI, S. L. SØRLAND, R. WARTENBURGER & S. I. SENEVIRATNE (2019): Regional climate model projections underestimate future warming due to missing plant physiological CO₂ response. – *Environmental Research Letters* 14, 11, 114019. DOI: 10.1088/1748-9326/AB4949.
- SEMENOV, M. A. & P. R. SHEWRY (2010): Modelling predicts that heat stress and not drought will limit wheat yield in Europe. – *Nature Precedings*. DOI: 10.1038/npre.2010.4335.1.

- SEMENOV, M. A., P. STRATONOVITCH, F. ALGHABARI & M. J. GOODING (2014): Adapting wheat in Europe for climate change. – *Journal of Cereal Science* 59, 3, 245–256. DOI: 10.1016/j.jcs.2014.01.006.
- SENEVIRATNE, S. I., N. NICHOLLS, D. EASTERLING, C. M. GOODESS, S. KANAE, J. KOSIN, Y. LUO, J. MARENGO, K. MCINNES, M. RAHIMI, M. REICHSTEIN, A. SORTEBERG, C. VERA, X. ZHANG, M. RUSTICUCCI, V. SEMENOV, L. V. ALEXANDER, S. ALLEN, G. BENITO, T. CAVAZOS, J. CLAGUE, D. CONWAY, P. M. DELLA-MARTA, M. GERBER, S. GONG, B. N. GOSWAMI, M. HEMER, C. HUGGEL, B. VAN DEN HURK, V. V. KHARRIN, A. KITO, A. M. K. TANK, G. LI, S. MASON, W. MCGUIRE, G. J. VAN OLDENBORGH, B. ORLOWSKY, S. SMITH, W. THIAW, A. VELEGRAKIS, P. YIOU, T. ZHANG, T. ZHOU & F. W. ZWIERS (2012): Changes in Climate Extremes and their Impacts on the Natural Physical Environment. In: FIELD, C., V. BARROS, T. STOCKER, D. QIN, D. DOKKEN, K. EBI, M. MASTRANDREA, K. MACH, G.-K. PLATTNER, S. ALLEN, M. TIGNOR & P. MIDGLEY (Hrsg.): *Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation*. Cambridge: Cambridge University Press, 109–230. DOI: 10.1017/CBO9781139177245.006.
- SORTEBERG, A. & N. G. KVAMSTØ (2006): The effect of internal variability on anthropogenic climate projections. – *Tellus* 58A, 565–574. DOI: 10.1111/J.1600-0870.2006.00202.X.
- SPATHELF, P., E. VAN DER MAATEN, M. VAN DER MAATEN-THEUNISSEN, M. CAMPIOLI & D. DOBROWOLSKA (2014): Climate change impacts in European forests: the expert views of local observers. – *Annals of Forest Science* 71, 2, 131–137. DOI: 10.1007/s13595-013-0280-1.
- SPERLICH, D., D. NADAL-SALA, C. GRACIA, J. KREUZWIESER, M. HANEWINKEL & R. YOUSEFPOUR (2020): Gains or losses in forest productivity under climate change? The uncertainty of CO₂ fertilization and climate effects. – *Climate* 8, 12. DOI: 10.3390/cli8120141.
- SSYMANK, A. (1994): Neue Anforderungen im europäischen Naturschutz: Das Schutzgebietssystem Natur 2000 und die FFH-Richtlinie der EU. – *Landschaft und Natur* 69, 9, 395–406.
- STATISTISCHES BUNDESAMT (DESTATIS) (1996): *Land- und Forstwirtschaft, Fischerei. Landwirtschaftliche Bodennutzung - Rebflächen - 1995*. Fachserie 3. Reihe 3.1.5. Wiesbaden: Statistisches Bundesamt.

- STATISTISCHES BUNDESAMT (DESTATIS) (2016): Land- und Forstwirtschaft, Fischerei. Grunderhebung der Rebflächen 2015. Fachserie 3. Reihe 3.1.5. Wiesbaden: Statistisches Bundesamt.
- STATISTISCHES BUNDESAMT (DESTATIS) (2020): Weinmostertrag je Hektar. Weinanbaugebiet Franken. (Stand: 14.12.2020). Wiesbaden: Statistisches Bundesamt.
- STATISTISCHES BUNDESAMT (DESTATIS) (2021): Land- und Forstwirtschaft, Fischerei. Grunderhebung der Rebflächen 2020. Fachserie 3. Reihe 3.1.5. Wiesbaden: Statistisches Bundesamt.
- STATISTISCHES BUNDESAMT (DESTATIS) (2022): Land- und Forstwirtschaft, Fischerei. Landwirtschaftliche Bodennutzung - Rebflächen - 2021. Fachserie 3. Reihe 3.1.5. Wiesbaden: Statistisches Bundesamt.
- STEININGER, M., D. ABEL, K. ZIEGLER, A. KRAUSE, H. PAETH & A. HOTH (2020): Deep Learning for Climate Model Output Statistics. Tackling Climate Change with Machine Learning Workshop at NeurIPS 2020.
- STEININGER, M., D. ABEL, K. ZIEGLER, A. KRAUSE, H. PAETH & A. HOTH (2023): ConvMOS: climate model output statistics with deep learning. – *Data Mining and Knowledge Discovery* 37, 1, 136–166. DOI: 10.1007/S10618-022-00877-6.
- STEPHENS, G. L., T. L'ECUYER, R. FORBES, A. GETTELMEN, J.-C. GOLAZ, A. BODAS-SALCEDO, K. SUZUKI, P. GABRIEL & J. HAYNES (2010): Dreary state of precipitation in global models. – *Journal of Geophysical Research: Atmospheres* 115, D24, D24211. DOI: 10.1029/2010JD014532.
- STEVENS, B., M. GIORGETTA, M. ESCH, T. MAURITSEN, T. CRUEGER, S. RAST, M. SALZMANN, H. SCHMIDT, J. BADER, K. BLOCK, R. BROKOPF, I. FAST, S. KINNE, L. KORNBLUEH, U. LOHMANN, R. PINCUS, T. REICHLER & E. ROECKNER (2013): Atmospheric component of the MPI-M Earth System Model: ECHAM6. – *Journal of Advances in Modeling Earth Systems* 5, 2, 146–172. DOI: 10.1002/JAME.20015.
- STOCK, M. (2005): KLARA. Klimawandel - Auswirkungen, Risiken, Anpassung. PIK Report 99. Potsdam: PIK.

- STOCK, M., F. BADECK, F.-W. GERSTENGARBE, T. KARTSCHALL, H. ÖSTERLE, P. C. WERNER, M. WODINSKI & D. HOPPMANN (2007): Perspektiven der Klimaänderung bis 2050 für den Weinbau in Deutschland (Klima 2050). Schlußbericht zum FDW-Vorhaben Klima 2050. PIK Report 106. Potsdam: PIK.
- STOCK, M., F. GERSTENGARBE, T. KARTSCHALL & P. WERNER (2005): Reliability of climate change impact assessments for viticulture. – *Acta Horticulturae* 689, 29–40. DOI: 10.17660/ActaHortic.2005.689.1.
- STOLZ, J., E. VAN DER MAATEN, H. KALANKE, J. MARTIN, M. WILMKING & M. VAN DER MAATEN-THEUNISSEN (2021): Increasing climate sensitivity of beech and pine is not mediated by adaptation and soil characteristics along a precipitation gradient in northeastern Germany. – *Dendrochronologia* 67, 125834. DOI: 10.1016/J.DENDRO.2021.125834.
- SÜDZUCKER (2022): Zuckerfabriken der Südzucker AG in Deutschland. <<https://www.suedzucker.de/de/unternehmen/standorte/zuckerfabriken-deutschland>>. (Stand: 2022) (Zugriff: 2022-05-16).
- SUN, Y., S. SOLOMON, A. DAI & R. W. PORTMANN (2006): How often does it rain?. – *Journal of Climate* 19, 6, 916–934. DOI: 10.1175/JCLI3672.1.
- SUPIT, I., C. VAN DIEPEN, A. DE WIT, P. KABAT, B. BARUTH & F. LUDWIG (2010): Recent changes in the climatic yield potential of various crops in Europe. – *Agricultural Systems* 103, 9, 683–694. DOI: 10.1016/J.AGSY.2010.08.009.
- TAPIADOR, F. J., J. L. SÁNCHEZ & E. GARCÍA-ORTEGA (2019): Empirical values and assumptions in the microphysics of numerical models. – *Atmospheric Research* 215, 214–238. DOI: 10.1016/J.ATMOSRES.2018.09.010.
- TATE, A. B. (2001): Global Warming's Impact on Wine. – *Journal of Wine Research* 12, 2, 95–109. DOI: 10.1080/09571260120095012.
- TAYLOR, K. E., V. BALAJI, S. HANKIN, M. JUCKES, B. LAWRENCE & S. PASCOE (2012a): CMIP5 Data Reference Syntax (DRS) and Controlled Vocabularies. Version 1.3.1 <https://pcmdi.llnl.gov/mips/cmip5/docs/cmip5_data_reference_syntax.pdf>. (Stand: 2012) (Zugriff: 2023-01-17).
- TAYLOR, K. E., R. J. STOUFFER & G. A. MEEHL (2009): A Summary of the CMIP5 Experiment Design. PCMDI Report. Livermore: PCMDI.

- TAYLOR, K. E., R. J. STOUFFER & G. A. MEEHL (2012b): An Overview of CMIP5 and the Experiment Design. – *Bulletin of the American Meteorological Society* 93, 4, 485–498. DOI: 10.1175/BAMS-D-11-00094.1.
- TENG, J., N. J. POTTER, F. H. CHIEW, L. ZHANG, B. WANG, J. VAZE & J. P. EVANS (2015): How does bias correction of regional climate model precipitation affect modelled runoff?. – *Hydrology and Earth System Sciences* 19, 2, 711–728. DOI: 10.5194/hess-19-711-2015.
- TEUTSCHBEIN, C. & J. SEIBERT (2012): Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. – *Journal of Hydrology* 456-457, 12–29. DOI: 10.1016/j.jhydrol.2012.05.052.
- THEMESSL, M. J., A. GOBIET & A. LEUPRECHT (2011): Empirical-statistical downscaling and error correction of daily precipitation from regional climate models. – *International Journal of Climatology* 31, 10, 1530–1544. DOI: 10.1002/JOC.2168.
- THURM, E. A., S. BRANDL, H. FISCHER, K. H. MELLERT, T. METTE, B. REGER & W. WEIS (2020): Nadelbäume im Trockenstress. Vier Modelle zur Abschätzung der Trockenheitsresistenz im Klimawandel. – *LWF aktuell* 3, 24–27.
- THURM, E. A., L. HERNANDEZ, A. BALTENSWEILER, S. AYAN, E. RASZTOVITS, K. BI-ELAK, T. M. ZLATANOV, D. HLADNIK, B. BALIC, A. FREUDENSCHUSS, R. BÜCHSENMEISTER & W. FALK (2018): Alternative tree species under climate warming in managed European forests. – *Forest Ecology and Management* 430, 485–497. DOI: 10.1016/J.FORECO.2018.08.028.
- TÖLLE, M. H., L. SCHEFCZYK & O. GUTJAHR (2018): Scale dependency of regional climate modeling of current and future climate extremes in Germany. – *Theoretical and Applied Climatology* 134, 3-4, 829–848. DOI: 10.1007/S00704-017-2303-6.
- TRAPP, M., G. TINTRUP GEN. SUNTRUP & C. KOTREMPA (2013a): Klima- und Landschaftswandel in Rheinland-Pfalz (KlimLandRP) – Themenblatt zu den Methoden und Ergebnissen des Moduls Landwirtschaft. Trippstadt: Rheinland-Pfalz Kompetenzzentrum für Klimawandelfolgen.
- TRAPP, M., G. TINTRUP GEN. SUNTRUP & C. KOTREMPA (2013b): Klima- und Landschaftswandel in Rheinland-Pfalz (KlimLandRP) – Themenblatt zu den Methoden und Ergebnissen

des Moduls Landwirtschaft – Sektor Weinbau. Trippstadt: Rheinland-Pfalz Kompetenzzentrum für Klimawandelfolgen.

TURCO, M., M. C. LLASAT, S. HERRERA & J. M. GUTIÉRREZ (2017): Bias correction and downscaling of future RCM precipitation projections using a MOS-analog technique. – *Journal of Geophysical Research* 122, 5. DOI: 10.1002/2016JD025724.

UL REHMAN KHAN, M. S., Z. HUSSAIN & I. AHMAD (2021): Effects of L-Moments, Maximum Likelihood and Maximum Product of Spacing Estimation Methods in Using Pearson Type-3 Distribution for Modeling Extreme Values. – *Water Resources Management* 35, 5, 1415–1431. DOI: 10.1007/S11269-021-02767-W.

VAN DER LINDEN, P. & J. MITCHELL (2009): ENSEMBLES: Climate Change and its Impacts: Summary of research and results from the ENSEMBLES project. Exeter: Met Office Hadley Centre.

VAN DUREN, I., A. VOINOV, O. ARODUDU & M. T. FIRRISA (2015): Where to produce rapeseed biodiesel and why? Mapping European rapeseed energy efficiency. – *Renewable Energy* 74, 49–59. DOI: 10.1016/J.RENENE.2014.07.016.

VAN LEEUWEN, C. & P. DARRIET (2016): The Impact of Climate Change on Viticulture and Wine Quality. – *Journal of Wine Economics* 11, 01, 150–167. DOI: 10.1017/jwe.2015.21.

VAN MEIJGAARD, E., L. VAN ULFT, W. VAN DE BERG, F. BOSVELT, B. VAN DEN HURK, G. LENDERINK & A. SIEBESMA (2008): The KNMI regional atmospheric model RACMO version 2.1. KNMI Technical Report 302. De Bilt: Royal Netherlands Meteorological Institute (KNMI).

VAN VUUREN, D., J. EDMONDS, M. KAINUMA, K. RIAHI, A. THOMSON, K. HIBBARD, G. HURTT, T. KRAM, V. KREY, J.-F. LAMARQUE, T. MASUI, M. MEINSHAUSEN, N. NAKICENOVIC, S. SMITH & S. ROSE (2011): The representative concentration pathways: an overview. – *Climatic Change* 109, 5–31. DOI: 10.1007/s10584-011-0148-z.

VAUTARD, R., A. GOBIET, D. JACOB, M. BELDA, A. COLETTE, M. DÉQUÉ, J. FERNÁNDEZ, M. GARCÍA-DÍEZ, K. GOERGEN, I. GÜTTLER, T. HALENKA, T. KARACOSTAS, E. KATRAGKOU, K. KEULER, S. KOTLARSKI, S. MAYER, E. VAN MEIJGAARD, G. NIKULIN, M. PATARČIĆ, J. SCINOCCA, S. SOBOLOWSKI, M. SUKLITSCH, C. TEICHMANN, K. WARRACH-SAGI, V. WULFMAYER & P. YIOU (2013): The simulation of European heat

- waves from an ensemble of regional climate models within the EURO-CORDEX project. – *Climate Dynamics* 41, 9-10, 2555–2575. DOI: 10.1007/S00382-013-1714-Z.
- VERBAND DER LANDWIRTSCHAFTSKAMMERN (2010): *Klimawandel und Landwirtschaft. Anpassungsstrategien im Bereich Pflanzenbau*. Berlin: Verband der Landwirtschaftskammern.
- VERDUGO-VÁSQUEZ, N., G. GUTIÉRREZ-GAMBOA, I. DÍAZ-GÁLVEZ, A. IBACACHE & A. ZURITA-SILVA (2021): Modifications Induced by Rootstocks on Yield, Vigor and Nutritional Status on *Vitis vinifera* Cv Syrah under Hyper-Arid Conditions in Northern Chile. – *Agronomy* 11, 5, 979. DOI: 10.3390/AGRONOMY11050979.
- VILLALBA-PRADAS, A. & F. J. TAPIADOR (2022): Empirical values and assumptions in the convection schemes of numerical models. – *Geoscientific Model Development* 15, 9, 3447–3518. DOI: 10.5194/GMD-15-3447-2022.
- VOGEL, E., M. G. DONAT, L. V. ALEXANDER, M. MEINSHAUSEN, D. K. RAY, D. KAROLY, N. MEINSHAUSEN & K. FRIELER (2019): The effects of climate extremes on global agricultural yields. – *Environmental Research Letters* 14, 5, 054010. DOI: 10.1088/1748-9326/AB154B.
- VOGEL, J., P. RIVOIRE, C. DEIDDA, L. RAHIMI, C. A. SAUTER, E. TSCHUMI, K. V. D. WIEL, T. ZHANG & J. ZSCHEISCHLER (2021): Identifying meteorological drivers of extreme impacts: An application to simulated crop yields. – *Earth System Dynamics* 12, 1, 151–172. DOI: 10.5194/ESD-12-151-2021.
- VOLDOIRE, A., E. SANCHEZ-GOMEZ, D. S. Y MÉLIA, B. DECHARME, C. CASSOU, S. SÉNÉSI, S. VALCKE, I. BEAU, A. ALIAS, M. CHEVALLIER, M. DÉQUÉ, J. DESHAYES, H. DOUVILLE, E. FERNANDEZ, G. MADEC, E. MAISONNAVE, M. P. MOINE, S. PLANTON, D. SAINT-MARTIN, S. SZOPA, S. TYTECA, R. ALKAMA, S. BELAMARI, A. BRAUN, L. COQUART & F. CHAUVIN (2012): The CNRM-CM5.1 global climate model: description and basic evaluation. – *Climate Dynamics* 2012 40:9 40, 9, 2091–2121. DOI: 10.1007/S00382-011-1259-Y.
- VON STORCH, H., H. LANGENBERG & F. FESER (2000): A Spectral Nudging Technique for Dynamical Downscaling Purposes. – *Monthly Weather Review* 128, 10, 3664 – 3673. DOI: 10.1175/1520-0493(2000)128<3664:ASNTFD>2.0.CO;2.

- VON STORCH, H. & F. W. ZWIERS (2003): *Statistical Analysis in Climate Research*. Cambridge: Cambridge University Press.
- WAGNER, S., P. BERG, G. SCHÄDLER & H. KUNSTMANN (2013): High resolution regional climate model simulations for Germany: Part II-projected climate changes. – *Climate Dynamics* 40, 1-2, 415–427. DOI: 10.1007/S00382-012-1510-1.
- WANG, S., Y. ZHANG, W. JU, J. M. CHEN, P. CIAIS, A. CESCATTI, J. SARDANS, I. A. JANSSENS, M. WU, J. A. BERRY, E. CAMPBELL, M. FERNÁNDEZ-MARTÍNEZ, R. ALKAMA, S. SITCH, P. FRIEDLINGSTEIN, W. K. SMITH, W. YUAN, W. HE, D. LOMBARDOZZI, M. KAUTZ, D. ZHU, S. LIENERT, E. KATO, B. POULTER, T. G. SANDERS, I. KRÜGER, R. WANG, N. ZENG, H. TIAN, N. VUICHARD, A. K. JAIN, A. WILTSHIRE, V. HAVERD, D. S. GOLL & J. PEÑUELAS (2020): Recent global decline of CO₂ fertilization effects on vegetation photosynthesis. – *Science* 370, 6522, 1295–1300. DOI: 10.1126/science.abb7772.
- WANG, X. & F. LIU (2021): Effects of Elevated CO₂ and Heat on Wheat Grain Quality. – *Plants* 10, 5, 1027. DOI: 10.3390/PLANTS10051027.
- WATANABE, M., J. S. KUG, F. F. JIN, M. COLLINS, M. OHBA & A. T. WITTENBERG (2012): Uncertainty in the ENSO amplitude change from the past to the future. – *Geophysical Research Letters* 39, L20703.
- WEBBER, H., F. EWERT, J. E. OLESEN, C. MÜLLER, S. FRONZEK, A. C. RUANE, M. BOURGAULT, P. MARTRE, B. ABABAEI, M. BINDI, R. FERRISE, R. FINGER, N. FODOR, C. GABALDÓN-LEAL, T. GAISER, M. JABLON, K. C. KERSEBAUM, J. I. LIZASO, I. J. LORITE, L. MANCEAU, M. MORIONDO, C. NENDEL, A. RODRÍGUEZ, M. RUIZ-RAMOS, M. A. SEMENOV, S. SIEBERT, T. STELLA, P. STRATONOVITCH, G. TROMBI & D. WALLACH (2018): Diverging importance of drought stress for maize and winter wheat in Europe. – *Nature Communications* 2018 9:1 9, 1, 1–10. DOI: 10.1038/s41467-018-06525-2.
- WHITE, J. W., G. HOOGENBOOM, B. A. KIMBALL & G. W. WALL (2011): Methodologies for simulating impacts of climate change on crop production. – *Field Crops Research* 124, 3, 357–368. DOI: 10.1016/J.FCR.2011.07.001.
- WIESMEIER, M., R. HÜBNER & I. KÖGEL-KNABNER (2015): Stagnating crop yields: An overlooked risk for the carbon balance of agricultural soils?. – *Science of The Total Environment* 536, 1045–1051. DOI: 10.1016/J.SCITOTENV.2015.07.064.

- WILHELM, C., D. RECHID & D. JACOB (2014): Interactive coupling of regional atmosphere with biosphere in the new generation regional climate system model REMO-iMOVE. – *Geoscientific Model Development* 7, 3, 1093–1114. DOI: 10.5194/GMD-7-1093-2014.
- WILKS, D. S. (2011): *Statistical methods in the atmospheric sciences*. 3. Auflage. Oxford, Amsterdam, Waltham, San Diego: Academic Press.
- WONG, G., D. MARAUN, M. VRAC, M. WIDMANN, J. M. EDEN, T. KENT, G. WONG, D. MARAUN, M. VRAC, M. WIDMANN, J. M. EDEN & T. KENT (2014): Stochastic Model Output Statistics for Bias Correcting and Downscaling Precipitation Including Extremes. – *Journal of Climate* 27, 18, 6940–6959. DOI: 10.1175/JCLI-D-13-00604.1.
- WOOLLINGS, T., C. FRANZKE, D. L. HODSON, B. DONG, E. A. BARNES, C. C. RAIBLE & J. G. PINTO (2014): Contrasting interannual and multidecadal NAO variability. – *Climate Dynamics* 2014 45, 539–556. DOI: 10.1007/S00382-014-2237-Y.
- WU, Y., C. MIAO, X. FAN, J. GOU, Q. ZHANG & H. ZHENG (2022): Quantifying the Uncertainty Sources of Future Climate Projections and Narrowing Uncertainties With Bias Correction Techniques. – *Earth's Future* 10, 11, e2022EF002963. DOI: 10.1029/2022EF002963.
- ZHAO, C., B. LIU, S. PIAO, X. WANG, D. B. LOBELL, Y. HUANG, M. HUANG, Y. YAO, S. BASSU, P. CIAIS, J. L. DURAND, J. ELLIOTT, F. EWERT, I. A. JANSSENS, T. LI, E. LIN, Q. LIU, P. MARTRE, C. MÜLLER, S. PENG, J. PEÑUELAS, A. C. RUANE, D. WALLACH, T. WANG, D. WU, Z. LIU, Y. ZHU, Z. ZHU & S. ASSENG (2017): Temperature increase reduces global yields of major crops in four independent estimates. – *Proceedings of the National Academy of Sciences of the United States of America* 114, 35, 9326–9331. DOI: 10.1073/PNAS.1701762114.
- ZHAO, Y., C. QIAN, W. ZHANG, D. HE & Y. QI (2021): Extreme temperature indices in Eurasia in a CMIP6 multi-model ensemble: Evaluation and projection. – *International Journal of Climatology* 41, 11, 5368–5385. DOI: 10.1002/JOC.7134.
- ZIEGLER, K. (2022): Implementierung von verbesserten Landoberflächenparametern und -prozessen in das hochaufgelöste Klimamodell REMO. Dissertation. Würzburg: Julius-Maximilians-Universität. DOI: 10.25972/OPUS-26128.
- ZIEGLER, K., F. POHL, F. POLLINGER & H. PAETH (2021): Different approaches of finding European climate analogue regions for the Steigerwald forest (Germany) in the future. EGU

General Assembly 2021, online, 19–30 Apr 2021, EGU21-9874. DOI: 10.5194/egusphere-egu21-542.

ZIEGLER, K., F. POLLINGER, D. ABEL & H. PAETH (2020): REMOLAND: New high-resolution surface boundary data for the regional climate model REMO and their impacts. EGU General Assembly 2020, Online, 4–8 May 2020, EGU2020-3005. DOI: 10.5194/EGUSPHERE-EGU2020-3005.

ZIMMERMANN, A., H. WEBBER, G. ZHAO, F. EWERT, J. KROS, J. WOLF, W. BRITZ & W. DE VRIES (2017): Climate change impacts on crop yields, land use and environment in response to crop sowing dates and thermal time requirements. – *Agricultural Systems* 157, 81–92. DOI: 10.1016/J.AGSY.2017.07.007.

ZIMMERMANN, J., M. HAUCK, C. DULAMSUREN & C. LEUSCHNER (2015): Climate Warming-Related Growth Decline Affects *Fagus sylvatica*, But Not Other Broad-Leaved Tree Species in Central European Mixed Forests. – *Ecosystems* 18, 4, 560–572. DOI: 10.1007/S10021-015-9849-X.

Anhang

A1 Untersuchungsgebiet

A1.1 Naturraum

Abbildung A1 zeigt einen Ausschnitt der Karte „Naturräume und Großlandschaften Deutschlands“ (BFN 2011)⁷⁴, welcher in etwa das Untersuchungsgebiet umfasst. Sie soll zur groben naturräumlichen Orientierung dienen. Das gesamte Gebiet befindet sich in der biogeographischen Region *kontinental* (im Vergleich zur *atlantischen* Prägung im Nordwesten und zur *alpinen* Prägung im untersten Südosten Deutschlands). Die Benennungen der Naturraumeinheiten sind in Tabelle A1 zu finden.

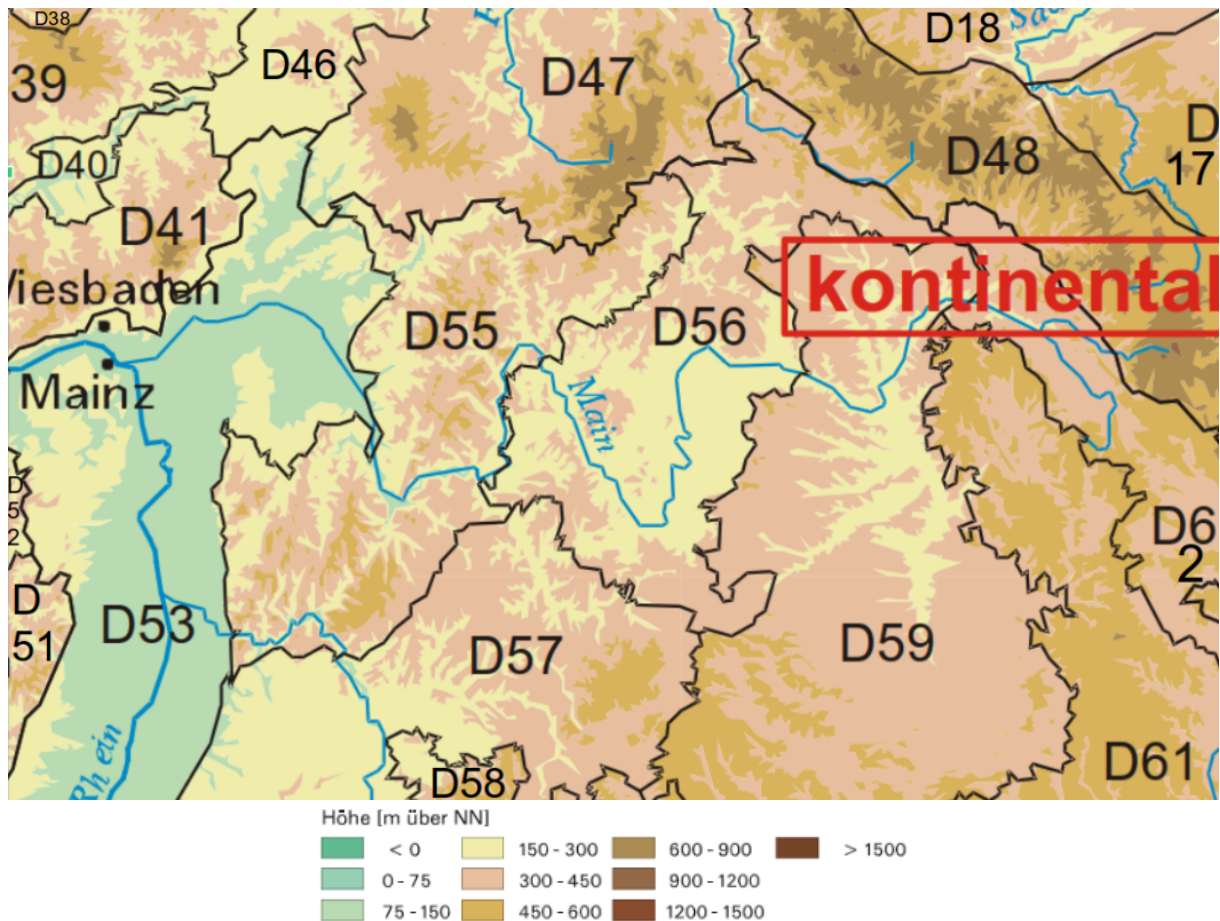


Abbildung A1: Naturräumliche Gliederung des Untersuchungsgebietes. Grober Ausschnitt auf das Untersuchungsgebiet, verändert nach BFN (2011).

⁷⁴Die Einteilung des Bundesamtes für Naturschutz (BFN 2011) stellt eine Überarbeitung der Gliederung nach SSYMANK (1994) dar.

Tabelle A1: Naturräume des Untersuchungsgebiets BFN (2011).

| Nr. | Naturraumeinheit |
|--------------------------------------------|--------------------------------------------------|
| Zentraleuropäisches Mittelgebirgsland | |
| D17 | Vogtland |
| D18 | Thüringer Becken und Randplatten |
| D38 | Bergisches Land, Sauerland (Süderbergkand) |
| D39 | Westerwald |
| D40 | Lahntal und Limburger Becken |
| D41 | Taunus |
| D46 | Westhessisches Berg- und Beckenland |
| D47 | Osthessisches Bergland (Vogelsberg und Rhön) |
| D48 | Thüringisch-Fränkisches Mittelgebirge |
| D51 | Pfälzer Wald (Haardtgebirge) |
| D52 | Saar-Nahe-Berg- und Hügelland |
| Südwestdeutsches Mittelgebirgs-/Stufenland | |
| D53 | Oberrheinisches Tiefland und Rhein-Main-Tiefland |
| D55 | Odenwald, Spessart, Südrhön |
| D56 | Mainfränkische Platten |
| D57 | Neckar- und Tauberland, Gäuplatten |
| D58 | Schwäbisches Keuper-Liasland |
| D59 | Fränkisches Keuper-Liasland |
| D61 | Fränkische Alb |
| D62 | Oberpfälzisch-Obermainisches Hügelland |

A1.2 Geologie

Die folgende Beschreibung bezieht sich auf Abbildung A2 und fasst die geologischen Situation zusammen. Sie beinhaltet gleichzeitig die Klassifizierung der Naturräume nach BFN (2011) (vgl. auch LFU o.J.) wie sie zum Teil auch in Abbildung 2.2 verzeichnet ist. Die entsprechende Gliederung mit geographischer Zuordnung ist im Anhang A1.1, Abbildung A1 zu finden.

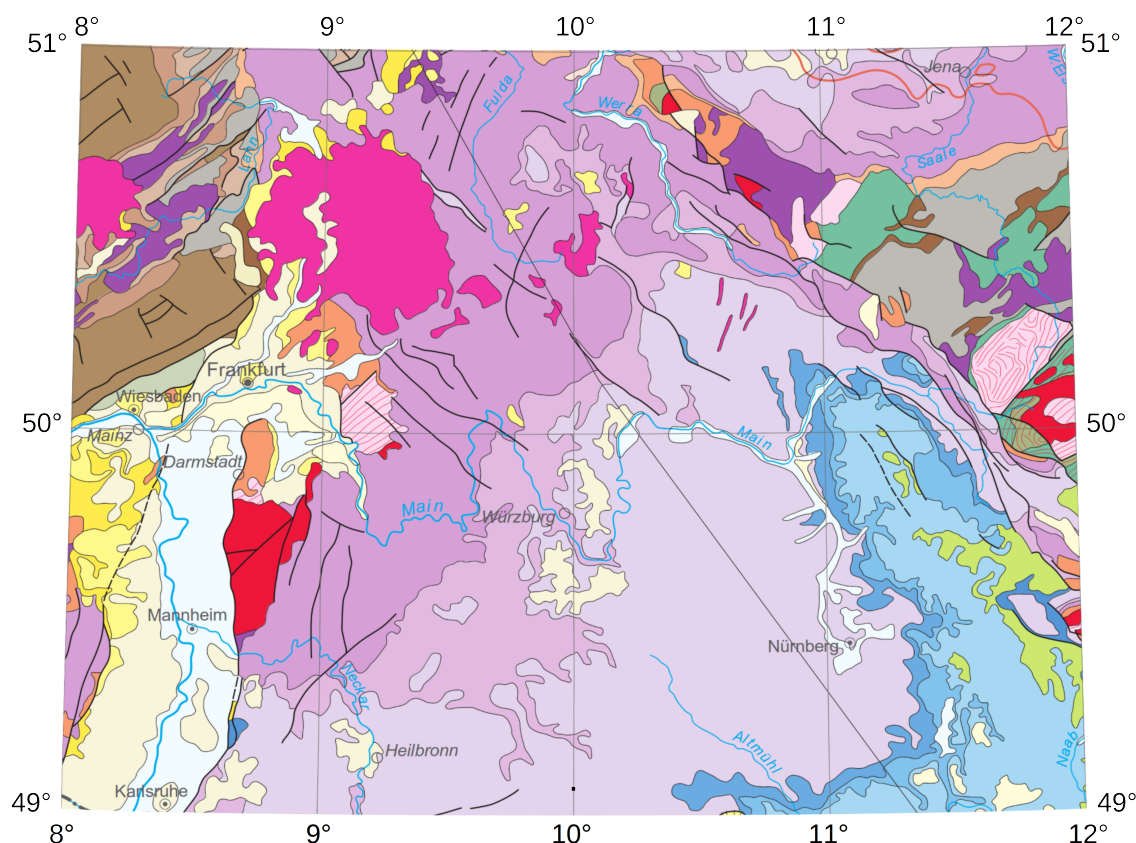


Abbildung A2: Geologie des Untersuchungsgebietes (BGR 2011), Legende siehe Anhang A1.1, Abbildung A3.

Im Bereich des Rhein-Main-Tieflandes (Südosten des Untersuchungsgebietes) finden sich känozoische Sedimentgesteine (hellblau, beige, Gelbtöne). Dieses ist nach Nordwesten abgegrenzt durch das Gebiet Taunus-Limburger Becken-Westerwald mit von känozoischen und paläozoischen Vulkaniten (kräftiges Magenta und Violett) unterbrochenen variszischen Sedimentgesteinen (Devon und Karbon, Braun- und Grautöne). Im Norden bis Nordosten schließen sich die känozoischen Vulkanite von Vogelsberg und Rhön (Osthessisches Bergland, kräftiges Magenta) ans Rhein-Main-Tiefland an. Westlich sind zudem im Bereich des Vorderen Spessarts (Nomenklatur IFL (1968), Vorspessart in Abbildung 2.2) metamorphe Gesteine und im Bereich des Vorderen Odenwalds (Nomenklatur IFL (1968)) Plutonite anstehend. Das Zentrum des

Untersuchungsgebiets ist triassisch geprägt (violette Farbtöne) mit Buntsandstein im Gebiet Odenwald-Spessart-(Süd-)Rhön. In den Bereichen von Mainfränkischen Platten sowie Neckar-/Tauberland und Gäuplatten steht von Nordwesten nach Südosten zunächst Muschelkalk und dann unterbrochen von pleistozänen Sedimenten Keuper an. Letzterer herrscht im Fränkischen Keuper-Liasland vor. Daran schließen sich auf der Fränkischen Alb unterer, mittlerer und oberer Jura (Blautöne) sowie Oberkreide (gelbgrün) an. Im Nordosten heben sich der Thüringer und Frankenwald inkl. Vogtland (variszisches und prävariszisches Grundgebirge, Plutonite und Paläozoische Vulkanite) sowie das Fichtelgebirge (Metamorphite, Plutonit prävariszisches Grundgebirge) ab (Thüringisch-Fränkisches Mittelgebirge zzgl. Vogtland). Sowohl im nordöstlichsten Bereich (Thüringer Becken und Randplatten) als auch im Oberpfälzisch-Obermainischen Hügelland zwischen Fränkischer Alb und Thüringisch-Fränkischem Mittelgebirge sind vorwiegend Gesteine des Trias anstehend (BGR 2011).

A2 Nutzung

Abbildung A4 zeigt die deutschen Standorte der Südzucker AG sowie umrandet das Untersuchungsgebiet.

A3 Feldfrüchte und deren Verwendung

Im Wirtschaftsjahr 2020/2021 wurden in Bayern (Deutschland) 58,2 % (62,2 %) des Getreides zu Futter- und 20,1 % (21,6 %) zu Nahrungszwecken verwendet. 9,8 % wurden industriell genutzt (deutschlandweit 7,5 % ohne energetische Verwertung + 8,9 % energetische Verwertung) (LEL & LFL 2022). Weizen wurde in Bayern zu 47,3 % als Tierfutter sowie zu 42,4 % für die menschliche Ernährung genutzt. 93,1 % der Wintergerstemenge wurde als Tierfutter verwendet, bei Sommergerste waren es 15,3 %, während 79,9 % industriell verwertet wurden (LEL & LFL 2022). Der Großteil der Hafererträge in Deutschland 2021/22 wurde verfüttert (80,3 %), 12,1 % wurden energetisch und 9,3 % als direkte Nahrung genutzt (BMEL & BLE 2020).

In den letzten Jahrzehnten dehnte sich die Maisanbaufläche in Deutschland deutlich aus (OLESEN *et al.* 2011), was unter anderem auf seine Nutzung als Energiepflanze für die Erzeugung von Strom, Wärme und Brennstoff zurückzuführen ist (PEICHL *et al.* 2018; FNR 2022a,b).



Abbildung A3: Legende zur Geologischen Karte Abbildung A2, verändert nach BGR (2011).

Deutsche Fabrikstandorte der Südzucker AG

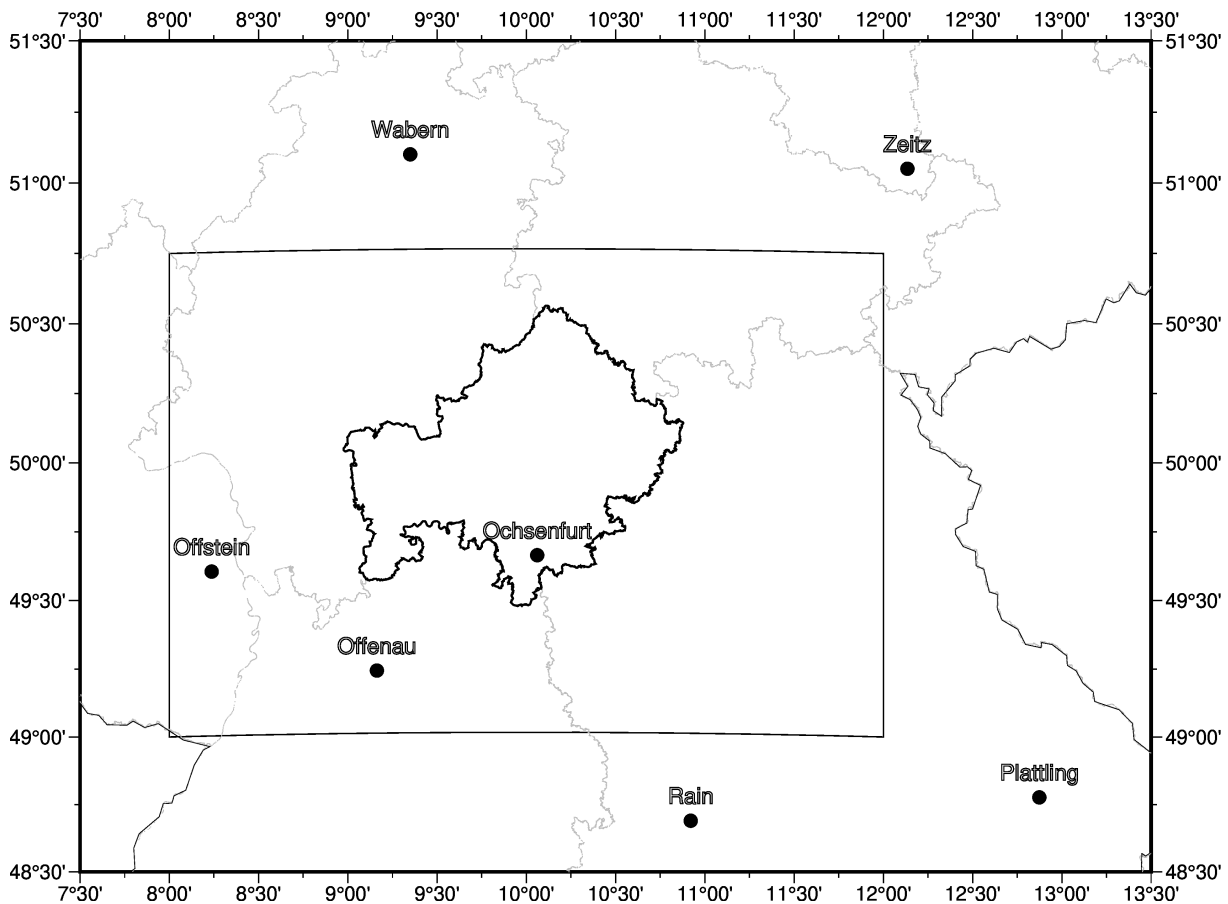


Abbildung A4: Deutsche Fabrikstandorte der Südzucker AG (Daten (SÜDZUCKER 2022),
Koordinaten und Grenzen (GEOBASIS-DE 2017)).

Dennoch nimmt die Verwendung von Silomais zur Biogaserzeugung nur den zweiten Rang nach der Nutzung als Viehfutter ein (FNR 2022b).

Ölsaaten werden allgemein für Nahrungs-, technische, energetische und Futterzwecke verwendet. Der größte Anteil des Rapsöls in Deutschland wird energetisch zur Biodieselherstellung genutzt. Zusätzlich ist Rapsöl das wichtigste Speiseöl Deutschlands (37,0 % Marktanteil, zum Vergleich Sonnenblumenöl 30,2 %, Olivenöl 18,6 %). Raps wird auf 78,0 % der bayerischen Ölsaatenanbaufläche angebaut und umfasst 81,2 % der Ölsaatenerträge (alle Zahlen zu Raps aus dem Jahr 2021, LEL & LFL 2022).

Danksagung

Die vorliegende Arbeit ist das Ergebnis meiner mehrjährigen Forschung am Institut für Geographie und Geologie der Julius-Maximilians-Universität Würzburg. Allen voran möchte mich bei Herrn Prof. Dr. Heiko Paeth bedanken. Wäre er nicht vor inzwischen etwa neun Jahren auf mich zugekommen, um mich aufgrund einer Frage in einem seiner Seminare dazu zu ermutigen, mein angewandtes Projekt des Masterstudiums bei ihm zu absolvieren, wäre ich wohl kaum so weit gekommen, eine Doktorarbeit aus dem Bereich der Klimaforschung zu schreiben. Tausend Dank für die Betreuung, Unterstützung sowie das mir entgegengebrachte Vertrauen, die Geduld, Interessensweckung sowie die Offenheit für neue und ungewöhnliche Ideen!

Ebenso danke ich Herrn Prof. Dr. Roland Baumhauer für die Wahrnehmung von Mentorat und Zweitgutachten sowie Frau Prof. Dr. Birgit Terhorst für die Mentoratsübernahme. Danke an alle jetzigen und ehemaligen Mitglieder der Arbeitsgruppe Klimatologie – insbesondere an Herrn Dr. Felix Pollinger, Frau Dr. Katrin Ziegler sowie Herrn Dr. Daniel Abel – für die wertvollen Impulse, Kritikpunkte und Diskussionen sowie Dorothee Ullrich für die große Unterstützung und Hilfsbereitschaft in technischen Angelegenheiten.

Mein Dank gilt ebenfalls dem Europäischen Fonds für regionale Entwicklung (EFRE) für dessen Kofinanzierung des *BigData@Geo*-Projektes. Die Anstellung in diesem Projekt ermöglichte mir die tiefgehende Forschung, auf der diese Arbeit basiert. Danke an alle Partnerunternehmen im Projekt für den Austausch und die wichtigen Anregungen.

Des Weiteren möchte ich den Organisationen danken, welche die von mir genutzten Daten erarbeitet und bereitgestellt haben:

- Für die Klimamodelldaten: Den in Tabelle 3.1 gelisteten Klimamodellierungsinstitutionen sowie der Arbeitsgruppe Regional Climate des World Climate Research Programme (WCRP) für die Koordination des CORDEX-Projektes und der Earth System Grid Federation (ESGF) für die Verfügbarmachung der Daten durch ihre Infrastruktur
- Für die DWD-Beobachtungsdaten: Dem Deutsche Wetterdienst (DWD) und dem dazugehörigen Climate Data Center (CDC)

Danksagung

- Für die E-OBS-Daten: Dem EU-FP6-Projekt UERRA, dem Copernicus Climate Change Service (C3S) sowie den Datenanbietern im ECA&D-Projekt
- Für die Ertragsdaten: Dem Bayerischen Landesamt für Statistik (LfStat) sowie dem Statistischen Bundesamt (Destatis)

Zu guter Letzt möchte ich meiner Familie danken: Meiner Tochter, meinem Mann, meinen Eltern sowie meinen Geschwistern. Danke für euer Verständnis, eure Geduld, euer Zuhören, eure Ratschläge und eure Liebe!