


Statistische Aufbereitung von Klimaprojektionen: Downscaling und multivariate Bias-Adjustierung

Im Rahmen des BMVI-Expertennetzwerkes entwickelte
Verfahren zum Postprocessing von Klimamodelldaten

von
Stefan Krähenmann, Andreas Walter und Lara Klippel



Berichte des Deutschen Wetterdienstes

Statistische Aufbereitung von Klimaprojektionen: Downscaling und multivariate Bias-Adjustierung

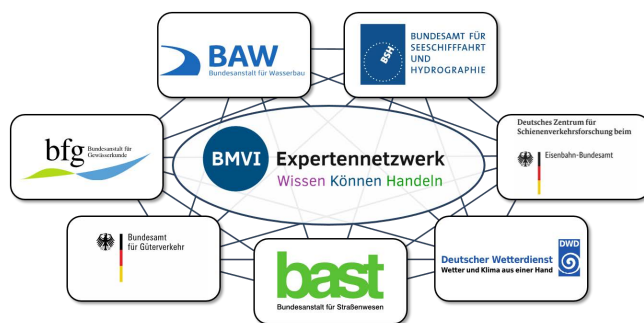
Im Rahmen des BMVI-Expertennetzwerkes entwickelte
Verfahren zum Postprocessing von Klimamodelldaten

von
Stefan Krähenmann, Andreas Walter und Lara Klippel

Zitationsvorschlag:

Krähenmann, S., Walter, A., Klippel, L., 2021: Statistische Aufbereitung von Klimaprojektionen: Downscaling und multivariate Bias-Adjustierung – Im Rahmen des BMVI-Expertennetzwerkes entwickelte Verfahren zum Postprocessing von Klimamodelldaten. *Berichte des Deutschen Wetterdienstes* 254, 25 S., Offenbach am Main, Selbstverlag des Deutschen Wetterdienstes.

Dieser Bericht ist im Rahmen einer Forschungsaktivität des Themenfelds 1 „Klimawandelfolgen und Anpassung“ des BMVI-Expertennetzwerkes „Wissen – Können – Handeln“ entstanden.



Titelfoto: Darstellung sogenannter räumlicher Kovarianzmuster im HYRAS-Gebiet, die zum Downscaling regionaler Klimaprojektionen mittels einer Hauptkomponentenanalyse gewonnen werden. Abgebildet sind vier Kovarianzmuster der Tagesmitteltemperatur (Details siehe Kapitel 4).

ISSN: 2194-5969 (Online)
ISBN: 978-3-88148-528-9 (Online)

Nutzungsbedingungen:

Dieses Dokument steht unter folgender Creative Commons-Lizenz:



Sie dürfen das Werk bzw. den Inhalt unter folgenden Bedingungen vervielfältigen, verbreiten und öffentlich zugänglich machen: Sie müssen den Namen des Autors/Rechteinhabers in der von ihm festgelegten Weise nennen. Dieses Werk bzw. dieser Inhalt darf nicht für kommerzielle Zwecke verwendet werden und es darf nicht bearbeitet, abgewandelt oder in anderer Weise verändert werden. Mit der Verwendung dieses Dokumentes erkennen Sie die Nutzungsbedingungen an.

Die in den DWD-Berichten veröffentlichten Texte werden allein von ihren jeweiligen Autoren verantwortet; die darin zum Ausdruck gebrachte Meinung entspricht nicht notwendig der Meinung des Herausgebers (Deutscher Wetterdienst).

Fachliche Durchsicht: Dr. Michael Denhard, DWD

Herausgeber und Verlag:

Deutscher Wetterdienst
Selbstverlag des Deutschen Wetterdienstes
Am DFS-Campus 4
63225 Langen
selbstverlag@dwd.de
www.dwd.de

Korrespondenzadresse:

Deutscher Wetterdienst
Dr. Andreas Walter
Abteilung Klima- und Umweltberatung
Frankfurter Str. 135
63067 Offenbach am Main
andreas.walter3@dwd.de

Autoren:

Dr. Stefan Krähenmann
Dr. Andreas Walter, DWD
Dr. Lara Klippel, DWD

Zusammenfassung

Klimaprojektionsdaten liegen originär auf einem Gitter vor, das für die Ableitung von Anpassungsmaßnahmen an den Klimawandel vor Ort zu grob ist. Zudem sind Klimaprojektionsdaten eventuell mit systematischen Ungenauigkeiten (*Bias*) behaftet, die insbesondere bei der Analyse schwellenwertbezogener Indizes die Ergebnisse verfälschen können.

In diesem Bericht wird ein Verfahren zur multivariaten Bias-Adjustierung vorgestellt und bewertet. Multivariat bedeutet in diesem Zusammenhang, dass korrelierte Variablen gemeinsam adjustiert werden, was die Korrelation zwischen solchen Variablen erhält und insbesondere in der Klimafolgenforschung von enormer Wichtigkeit ist.

Es schließt sich die Vorstellung eines statistischen Verfahrens zur Generierung von höheren räumlichen Auflösungen der Modelldaten (*Downscaling*) an. Hierbei wird die originäre Modellauflösung von ~ 11 km x 11 km unter Zuhilfenahme einer Hauptkomponentenanalyse (*Principal Component Analysis*), der Ermittlung statistischer Beziehungen zwischen den originären Modelldaten und der ermittelten Hauptkomponenten und der Anwendung dieser Beziehungen auf hochauflösende Daten, zur Generierung eines Datensatz mit einer Zielauflösung von 5 km x 5 km genutzt.

Die Methode wurde im Rahmen des BMVI-Expertennetzwerkes „Wissen – Können – Handeln“ entwickelt und auf ein Ensemble von Klimaprojektionsdaten angewendet. Die Ergebnisse liefern wesentliche Beiträge in diesem Ressortforschungsprogramm, im Rahmen der Klimawirkungs- und Risikoanalyse 2021 und im Kontext der Deutschen Anpassungsstrategie an den Klimawandel sowie für Beratungsleistungen des Deutschen Wetterdienstes.

Summary

Climate projection data are originally available on a grid that is too coarse for deriving climate change adaptation measures at a given location. In addition, climate projection data may be subject to systematic inaccuracies (bias) that can bias results, particularly in the analysis of threshold-based indices.

In this report, a multivariate bias adjustment procedure is presented and evaluated. Multivariate in this context means that correlated variables are adjusted together, which preserves the correlation between such variables and is of enormous importance especially in climate impact research.

This is followed by the presentation of a statistical method for generating higher spatial resolutions of the model data (downscaling). The original model resolution of ~ 11 km x 11 km is used to generate a data set with a target resolution of 5 km x 5 km by means of a principal component analysis, the determination of statistical relationships between the original model data and the determined principal components, and the application of these relationships to high-resolution data.

The method was developed within the BMVI Network of Experts and applied to an ensemble of climate projection data. The results provide essential contributions in this departmental research program, in the context of the Climate Impact and Risk Analysis 2021 and in the context of the German Climate Change Adaptation Strategy as well as for consulting services of the German Meteorological Service.

Inhaltsverzeichnis

1	Einführung	5
1.1	Stand der Forschung	5
1.2	Aufgabenstellung und Zielsetzung	6
2	Verfügbare regionale Klimaprojektionen	7
2.1	Konfiguration der Projektionsläufe	7
3	Statistische Aufbereitung der Modellsimulationen	9
3.1	Bias-Adjustierung	9
3.2	Statistisches Downscaling	11
4	Anwendungsbeispiel	13
4.1	Hauptkomponentenanalyse (PCA)	13
4.2	Statistisches Downscaling	13
4.3	Multivariate Bias-Adjustierung	15
5	Fazit und Diskussion	22
	Literaturverzeichnis	24
	Abkürzungsverzeichnis	25

1 Einführung

1.1 Stand der Forschung

Die Kenntnis über das Auftreten, die Intensität und die Auswirkungen von Extremereignissen in der Zukunft sowie die Folgen des Klimawandels in Bezug auf die Verkehrsinfrastruktur in Deutschland ist eine der zentralen Fragestellungen im Themenfeld 1 („Klimawandelfolgen und Anpassung“) des BMVI-Expertennetzwerks „Wissen – Können – Handeln“.

Für die Simulation des zukünftig zu erwartenden Klimas werden vorwiegend globale und regionale Klimamodelle eingesetzt. Bei diesen Modellen handelt es sich um sogenannte Zirkulationsmodelle, die unter Verwendung physikalischer atmosphärischer Grundgleichungen Projektionen eines zukünftigen Klimas in verschiedenen räumlichen Auflösungen liefern. Aktuelle globale Klimamodelle (*General Circulation Models*, GCMs) setzen sich aus einem allgemeinen Zirkulationsmodell für die Atmosphäre, wie es beispielsweise auch für die Wettervorhersage eingesetzt wird und zusätzlichen Modellen für einzelne Komponenten des Klimasystems zusammen (ROECKNER 2003). In diesen sind etliche Komponenten des Klimasystems wie die Atmosphäre, der Ozean, die Kryosphäre und die Landoberfläche durch den Austausch von beispielsweise Energie, Wasser, Impuls, Aerosol und Kohlendioxid (CO₂) miteinander gekoppelt. Diese als Erdsystemmodelle (*Earth System Models*, ESMs) bezeichneten GCMs wurden in den letzten Jahren und Jahrzehnten zunehmend komplexer. Durch diese Erweiterungen wurden einige Unsicherheiten, die durch die Randbedingungen des Klimasystems verursacht werden und für langjährige Klimaprojektionen von großer Bedeutung sind, identifiziert und deutlich verringert.

Eine Reihe wichtiger ozeanischer und atmosphärischer Prozesse, die aufgrund des zu grobmaschigen Modellgitters der ESMs nicht explizit dargestellt werden können, müssen parametrisiert werden. Man spricht in diesem Fall auch von subskaligen Prozessen. Dies betrifft beispielsweise den Transfer solarer und terrestrischer Strahlung, die Phasenänderung des Wassers, die Niederschlagsbildung sowie turbulente und konvektive Austauschprozesse in der Atmosphäre und im Ozean. Die Parametrisierung eines physikalischen Prozesses stellt eine wesentliche Vereinfachung der Realität dar und führt zu einem Informationsverlust, der für einige Fragestellungen erhebliche Auswirkungen haben kann.

Einige physikalische Prozesse im Klimasystem können von Klimamodellen nicht oder nur unvollständig wiedergegeben werden. Diese Unsicherheit lässt sich zumindest teilweise durch die Kombination mehrerer unterschiedlicher Global- und Regionalmodelle oder durch unterschiedliche Beschreibung bzw. Parametrisierung der physikalischen Prozesse in einem Modell abschätzen. Auch mit immer höherer Leistungsfähigkeit von Großrechnern in Verbund mit einer immer höheren räumlichen Auflösung der Klimamodelle bleiben Modelle jedoch weiterhin stark vereinfachte Abbilder der komplexen natürlichen Systeme. Die daraus resultierenden Abweichungen zu den Beobachtungen können bestenfalls verringert werden. Durch die stufenweise Verfeinerung der räumlichen Auflösung einer sogenannten (Mehrfach-) Nestung in einer Modellkette, entstehen ebenfalls Unsicherheiten, denn Ungenauigkeiten (z. B. in der Modellphysik) der gröber aufgelösten Modelldaten beeinflussen den genesteten Modelldatensatz.

Falls ein geeigneter, qualitativ hochwertiger Beobachtungsdatensatz (HYRAS; z. B. RAUTHE et al. 2013) für den Vergleich mit Klimamodelldaten existiert, kann eine Minimierung dieser Modellfehler durch geeignete statistische Korrekturverfahren vorgenommen werden. Dies ist eine wichtige Voraussetzung für die Interpretation der Klimamodelldaten zum Beispiel in Bezug auf die Analyse von

Veränderungen von Klimakennwerten sowie für viele Klimafolgemodellierungen. Jedoch sind diese hochqualitativen Datensätze nicht für alle relevanten Variablen vorhanden. So existieren bisher beispielsweise nur zeitlich grob aufgelöste Vergleichsdatsätze für Windfelder über Land sowie nur wenige Datensätze für ozeanische und atmosphärische Variablen auf See. Ein Ansatz, diese Lücke zu schließen, stellen sogenannte Reanalysedaten (z. B. COSMO-REA6; u. a. BOLLMEYER et al. 2015) dar, die gegenwärtig bei der Bestimmung modellinterner Ungenauigkeiten verstärkt zum Einsatz kommen. Allerdings liegen diese Datensätze zurzeit noch nicht in klimatologisch relevanten Zeitskalen (mindestens 30 Jahre) vor.

Viele Wirkmodelle, zum Beispiel Wasserhaushaltsmodelle oder Abflussmodelle, sind für den Antrieb durch absolute meteorologische Werte (im Normalfall Messwerte) konzipiert. Klimaprojektionen weichen oft aufgrund von Modelleinschränkungen systematisch von den gemessenen Werten ab, sodass der Abschätzung und Korrektur modellinterner Fehler daher eine große Bedeutung in der Klimafolgenforschung zukommt, insbesondere wenn die interessierende klimatologische Größe auf der Überschreitung definierter Schwellen, wie zum Beispiel der Änderung der Anzahl Tage mit einem Temperaturmaximum von mindestens 30 °C (heiße Tage), basiert. Hierzu existieren unter anderem Bias-Adjustierungs-Verfahren unterschiedlicher Komplexität. Sie reichen von einfachen Skalierungsansätzen, über eine Anpassung der Verteilungsfunktion einzelner Variablen bis hin zu multivariaten Ansätzen. Die Bias-Adjustierung basiert dabei auf dem Vergleich zwischen Modell-Kontrolllauf und den Vergleichsdaten über eine möglichst lange Referenzperiode. Eine grundlegende Annahme hierbei ist die Stationarität des Bias in der Zeit. Ist eine Korrektur der absoluten Werte nicht möglich, können relative Werte betrachtet werden, wie zum Beispiel die Änderung bestimmter Perzentile einer Häufigkeitsverteilung.

1.2 Aufgabenstellung und Zielsetzung

Im Rahmen des BMVI-Expertenetzwerkes werden im Schwerpunkt „Szenarienbildung“ hochaufgelöste Klimaprojektionsrechnungen Bias-adjustiert. Ziel ist es, hochaufgelöste Klimaprojektionen bereitzustellen, um detaillierte Aussagen zum Klimawandel in Deutschland und dabei auch zu den möglichen Änderungen im Auftreten von Extremereignissen (z. B. Sturmereignisse und Starkniederschläge) machen zu können. Daraus können wiederum Wirkmodellbetreiber für ihre Klimawirkungsanalysen Empfehlungen für Anpassungsstrategien ableiten.

Um die Spannbreite der möglichen Klimaänderungen abschätzen zu können, empfiehlt es sich, ein Ensemble von Klimaprojektionen zu erstellen. Da dynamisch angetriebene hochaufgelöste Klimaprojektionen aufgrund von Grenzen bei Kosten, Zeit und Speicherkapazitäten nicht möglich sind, wird die Spannbreite globaler Klimasimulationen durch statistisches Downscaling auf die regionale Ebene übertragen. Dazu werden aus Vergleichsdaten über eine Hauptkomponentenanalyse abgeleitete typische Verteilungsmuster genutzt.

Im Wesentlichen umfasst der Arbeitsprozess drei Schritte:

1. Hauptkomponentenanalyse hochauflösender Vergleichsdatsätze (Präprozessierung)
2. Bias-Adjustierung
3. Statistisches Downscaling

In Kapitel 3 werden diese einzelnen Schritte beschrieben.

2 Verfügbare regionale Klimaprojektionen

Kernaufgabe des BMVI-Expertennetzwerks ist es, robuste Änderungssignale von für den Verkehrssektor relevanten Kennwerten unter Berücksichtigung bestehender Szenarien- (z. B. Emissionsszenarien) und Modellunsicherheiten abzuleiten. Grundlage sind Ergebnisse globaler ESMs, die im fünften Sachstandsbericht des Weltklimarates (IPCC 2013) Verwendung fanden. Die hier verwendeten Klimaszenarien basieren auf einheitlichen Modellstandards. Ein Großteil der regionalen Klimaprojektionen für die Atmosphäre wurde im Rahmen des EURO-CORDEX-Projektes erzeugt und bereitgestellt. Dieses Ensemble basiert auf verschiedenen Globalmodellen und mehreren regionalen Klimamodellen (*Regional Climate Models*, RCMs), die mit drei verschiedenen Emissionsszenarien (RCP2.6, RCP4.5 und RCP8.5) angetrieben wurden. Im Rahmen des ReKliEsDe-Projekts wurden diese Simulationen systematisch für Deutschland und dessen Flusseinzugsgebiete ausgewertet und durch weitere Simulationen ergänzt. Die für das Expertennetzwerk verwendbaren regionalen Klimaprojektionen sind in Abbildung 1 zusammengestellt. Zu allen aufgeführten RCP-basierten Simulationen stehen auch entsprechende historische Läufe zur Verfügung. Um den Abschluss der Arbeiten im Expertennetzwerk nicht zu gefährden, wurden nur Klimaprojektionsläufe, die bis zum 30.06.2018 vorlagen, berücksichtigt. Für zukünftige Analysen können jedoch weitere Klimaprojektionsläufe berücksichtigt werden.

RCM \ GCM	CCLM			RACMO			RCA4			REMO			WRF		
	RCP 2.6	RCP 4.5	RCP 8.5	RCP 2.6	RCP 4.5	RCP 8.5	RCP 2.6	RCP 4.5	RCP 8.5	RCP 2.6	RCP 4.5	RCP 8.5	RCP 2.6	RCP 4.5	RCP 8.5
CanESM2			r1									r1			
EC-EARTH	r12	r12	r12	r12	r1 r12	r1 r12	r12	r12	r1			r12			r12
HadGEM2-ES		r1	r1	r1	r1	r1	r1	r1	r1			r1			r1
IPSL-CM5A-MR								r1	r1						
MICRO5	r1		r1									r1			
MPI-ESM_LR	r1	r1	r1				r1	r1	r1	r1 r2	r1 r2	r1 r2	r1		r1

EURO-CORDEX

ReKliEs-De

DWD

Abbildung 1: Übersicht der DWD-Referenz-Ensembles mit den verwendeten Globalmodell (GCM)- und Regionalmodell (RCM)-Paaren pro RCP-Szenario. Farblich hinterlegt ist die jeweilige Herkunft (EURO-CORDEX, ReKliEs-De, DWD). Die Kürzel r1, r2, r12 stehen für verschiedene Realisierungen im Ensemble der Globalmodelle.

2.1 Konfiguration der Projektionsläufe

Die Klimadaten werden in täglicher Auflösung für den Zeitraum 1951–2100 (je nach Verfügbarkeit) basierend auf Beobachtungs- bzw. Reanalysedaten aufbereitet. Dabei werden für die RCM-Daten bis 2005 historische Läufe und ab 2006 RCP-basierte Simulationen verwendet. Im Expertennetzwerk werden folgende Zeitscheiben für die Auswertung der Änderungssignale des Klimamodellensembles betrachtet:

- Referenz/ Modellvalidierung: 1971–2000
- Nahe Zukunft: 2031–2060
- Ferne Zukunft: 2071–2100

Die Zeitscheibe 1971–2000 wird als Bezugszeitraum für die Berechnung der Klimaänderungssignale verwendet, da ein Teil der Klimaprojektionsdaten erst ab 1970 vorliegt und somit eine konsistente Betrachtung des Ensembles für die im Vorgängerprojekt KLIWAS (Auswirkungen des Klimawandels auf Wasserstraßen und Schifffahrt in Deutschland) verwendete Referenzperiode 1961–1990 nicht möglich ist. Zur Wahrung des zeitlichen Abstandes zwischen Bezugszeitraum und „naher Zukunft“ im Vergleich zu anderen Projekten wie KLIWAS, verschiebt sich auch die Zeitscheibe der „nahen Zukunft“ von 2021–2050 auf 2031–2060. Eine Verschiebung der Zeitscheibe „ferne Zukunft“ ist nicht möglich, da die regionalen Klimaprojektionsdaten nur bis 2099 bzw. 2100 vorliegen. So weit wie möglich werden auch komplette Zeitreihen und/oder längere Zeitscheiben in die Untersuchungen aufgenommen.

Die im Rahmen des BMVI-Expertennetzwerkes verwendeten regionalen Klimaprojektionen liegen in einer zeitlichen Auflösung von einem Tag und einer räumlichen Auflösung von 0.11° (~12 km) vor. Die Klimaprojektionen werden mittels eines statistischen Downscaling-Verfahrens auf ein 5 km x 5 km Gitter übertragen (entspricht dem Gitter des HYRAS-Datensatzes, ETRS89-LCC; siehe RAUTHE et al. 2013).

3 Statistische Aufbereitung der Modellsimulationen

3.1 Bias-Adjustierung

Um Aussagen über mögliche Änderungen unseres Klimas treffen zu können, werden globale Klimamodelle benötigt, die möglichst viele relevante Prozesse des Klimasystems abbilden. Globale Modellsimulationen werden in einer relativ geringen räumlichen Auflösung gerechnet, um Rechenzeit zu sparen. Zur Modellierung regionaler Prozesse werden regionale Klimamodelle nachgeschaltet, die mit den Ergebnissen der Globalmodelle angetrieben werden. Klimamodelle erzeugen eine näherungsweise Darstellung der Realität, weshalb systematische Fehler (Bias) resultieren. Vor der weiteren Verwendung der Ergebnisse als Input für Wirkmodelle, müssen diese Fehler quantifiziert, sowie möglichst minimiert werden. Der Bias wird durch den Vergleich zwischen Referenzdaten (zumeist Beobachtungs- oder Reanalysedaten) und einem Kontrolllauf des Klimamodells für den gleichen Zeitraum ermittelt. Für zahlreiche, bei Untersuchungen im Binnenland benötigten Parametern, stehen Beobachtungsdaten in ausreichender räumlicher Dichte und Qualität zur Verfügung, sodass gegitterte Referenzdatenfelder erstellt werden können. Andere wichtige Klimaparameter, wie die Windgeschwindigkeit und der Luftdruck sind derzeit nicht Teil der HYRAS-Datensätze (RAUTHE et al. 2013). Zur Korrektur dieser Parameter werden hochauflösende Reanalysedaten (COSMO-REA6, BOLLMEYER et al. 2015; NIERMANN et al. 2017) verwendet.

In der Vergangenheit wurde eine Reihe unterschiedlich komplexer Korrekturverfahren entwickelt. Die Anpassung des Modellwerts durch einen konstanten Versatz (z. B. additiv bzw. multiplikativ) stellt die einfachste Art der Bias-Minimierung dar. Voraussetzung ist eine annähernd lineare Beziehung des Versatzes zwischen Modell- und Referenzdaten. Die Anpassung basiert auf monatlichen Korrekturwerten, die beispielsweise aus Differenzen zwischen beobachteten und modellierten Werten abgeleitet werden. Ziel linearer Skalierung ist die Übereinstimmung monatlicher Mittelwerte der korrigierten Modelldaten und der beobachteten Werte.

Hingegen passen Quantil-Mapping-Verfahren über eine Abbildungsvorschrift Häufigkeitsverteilungen von Projektionsdaten denen realer Beobachtungen an. Dabei werden die einzelnen Quantile der Häufigkeitsverteilung separat angepasst, wodurch mittlere Werte und Extrema voneinander unabhängig korrigiert werden. Eine gängige Annahme ist, dass eine Häufigkeitsverteilung stationär ist, was in einem sich ändernden Klima allerdings nicht für alle Klimaparameter zutreffen muss.

Wie bei der linearen Skalierung wird auch beim Quantil-Mapping die Konsistenz der Klimavariablen zueinander nicht berücksichtigt. Die individuelle Bearbeitung der verschiedenen Parameter birgt die Gefahr, dass die physikalische Abhängigkeit meteorologischer Größen verloren geht. Beim Einsatz komplexer, multiparametrischer Wirkmodelle, wie beispielsweise einem Wasserhaushaltsmodell, kann dies zu ungenauen oder gar falschen Ergebnissen führen. Um dieser Gefahr entgegen zu treten, wird das Quantil-Mapping-Verfahren um eine multivariate Komponente erweitert. Dabei wird neben den statistischen Momenten auch die Konsistenz der Klimavariablen angepasst.

Zur Korrektur der im Rahmen des BMVI-Expertennetzwerks verwendeten Klimaprojektionen wird ein neues, multivariates Bias-Adjustierungsverfahren (CANNON 2018) angewandt. Dieses Verfahren kombiniert die Korrektur marginaler Verteilungen (d. h. jede Variable separat betrachtet) via univariatem *Quantil-Delta-Change-Mapping* (QDCM) mit einer Anpassung der Abhängigkeitsstruktur zwischen den Variablen durch multivariate Skalierung. Während das Quantil-Mapping auf marginale Verteilungen eines multivariaten Datensatzes abzielt und dabei die Abhängigkeitsstruktur der Vari-

ablen zueinander unter Umständen verschlechtert, korrigiert der multivariate Algorithmus die Abhängigkeitsstruktur, jedoch nicht die komplette marginale Verteilung. Im Expertennetzwerk kommt die R-basierte Funktion MBCn (*Multivariate Bias Correction in n dimensions*; CANNON 2018), die Quantil-Mapping mit multivariater linearer Skalierung kombiniert, zur Anwendung.

Die gesamte Korrektur erfolgt gitterpunktweise und für jeden Kalendermonat separat, da der Bias sowohl jahreszeitlich als auch regional variiert. Als Referenzdatensätze dienen Tageswerte der Lufttemperatur (Tagesmittel: TAS; Tagesminimum: TASMIN; Tagesmaximum: TASMAY; Taupunkt: TDEW) aus den HYRAS-Rasterdatensätzen. Da der Taupunkt mit den übrigen Temperaturparametern hoch korreliert ist, wird dieser an Stelle der relativen Feuchte (diese wird von Projektpartnern benötigt) bei der Bias-Adjustierung verwendet. Im Anschluss an die Bias-Adjustierung wird die relative Feuchte aus den korrigierten Taupunktwerten berechnet.

Grundsätzlich sind im Rahmen einer Bias-Adjustierung drei Typen von Datensätzen involviert: historische Referenzdaten (z. B. Beobachtungen), historische Klimamodelldaten und Klimaprojektionsdaten, die zumindest teilweise außerhalb des historischen Zeitraums liegen. Wird Quantil-Mapping auf modellierte Variablen im historischen Zeitraum angewendet, besitzen Bias-adjustierte Modelldaten definitionsgemäß dieselbe marginale Verteilung wie die Referenzdaten. Schwierigkeiten entstehen, wenn Quantil-Mapping auf Projektionsdaten angewendet wird, deren Wertebereich außerhalb des Bereichs historischer Simulationsdaten liegt. Es muss eine Art von Extrapolation erfolgen.

Methoden wie äquidistantes oder äquiproportionales Quantil-Mapping (WANG und CHEN 2014) machen zusätzlich Gebrauch von Simulationsdaten im Projektionszeitraum. CANNON (2015) zeigte, dass diese Methoden äquivalent zu *Quantil-Delta-Change-Mapping* (OLSSON et al. 2009) sind, die im Rahmen des BMVI-Expertennetzwerks verwendet wird. In diesen Verfahren werden projizierte Änderungen in den Quantilen der Klimaprojektion mit Hilfe einer Quantil-für-Quantil-Korrektur beibehalten. Die Extrapolation ist dabei bereits im Verfahren mit integriert.

Bei QDCM werden Mess- sowie Modellwerte (für den historischen und zukünftigen Zeitraum) zunächst aufsteigend sortiert und Perzentilen zugeordnet. Beim Vergleich modellierter und beobachteter Perzentile wird darauf basierend jedem Perzentil ein bestimmter Bias (bzw. Korrekturwert) zugewiesen. Die historischen, bzw. projizierten Modelldaten werden anschließend, für jedes Perzentil spezifisch, mit dem entsprechenden Korrekturwert adjustiert. Ein Nachteil dieser Methode ist, dass aufgrund der Klimaänderung die höchsten Temperaturwerte und somit auch die höchsten Perzentile erst gegen Ende des 21. Jahrhunderts auftreten. Als Folge davon werden Werte am Ende des 21. Jahrhunderts besonders häufig mit einem Korrekturwert behandelt, der im historischen Zeitraum nur für hohe Perzentile gilt. Ein großer Teil der Werte zu Beginn des Projektionszeitraums (ab 2006) wird dagegen mit einem Korrekturwert behandelt, der im historischen Zeitraum einem mittleren oder niedrigen Perzentil entspricht. Dieses Vorgehen führt zu einer Verwischung des Klimasignals. Um dieses Problem zu umgehen, wird ein sogenannter *Moving-Window-Ansatz* eingesetzt: die Klimaprojektionen werden für 35-Jahreszeitscheiben gesondert sortiert bzw. korrigiert sowie jeweils die mittleren 15 Jahre abgespeichert.

Im multivariaten Ansatz nach CANNON (2018) wird zunächst eine zufällige orthogonale Rotation auf den zu korrigierenden Datensatz angewendet, gefolgt von QDCM der rotierten Daten. Der zusätzliche Rotationsschritt (im Vergleich zum univariaten Fall) ermöglicht das Quantil-Mapping von Linearkombinationen der originalen Variablen. Die Wiederholung beider Schritte ermöglicht eine Korrektur der multivariaten Verteilung. Der Algorithmus besteht aus drei Phasen: a) Anwendung einer or-

thogonalen Rotation auf die Ausgangs-, Projektions- und Beobachtungsdaten; b) Korrektur der marginalen Verteilungen der rotierten Daten; c) Anwendung einer inversen Rotation. Diese drei Schritte werden wiederholt ausgeführt, bis die multivariate Verteilung der modellierten und der beobachteten Daten im historischen Zeitraum übereinstimmt. Zu beachten ist, dass das Ergebnis der Bias-Adjustierung aufgrund der zufälligen Rotation nicht deterministisch ist. Folglich liefern zwei Bias-Adjustierungsanwendungen jeweils leicht voneinander abweichende Ergebnisse. Die Abweichung ist für mittlere Werte gering, für Extrema kann diese jedoch einige Prozent betragen.

Untersuchungen zeigten, dass der Niederschlag über dem HYRAS-Gebiet nur schwach mit den temperaturbasierten Variablen korreliert ist ($R^2 < 0,1$). Zudem lieferte die Anwendung des multivariaten Verfahrens nach CANNON (2018) auf Niederschlag in Kombination mit den temperaturbasierten Parametern insbesondere für Extrema keine robusten Ergebnisse. Daher wurde entschieden, den Niederschlag unabhängig von den übrigen Parametern mit Hilfe von QDCM zu korrigieren. Das QDCM-Verfahren wurde darüber hinaus nur auf Werte bis zum 99,9. Perzentil angewendet, für höhere Werte wurde der Korrekturwert linear extrapoliert. Grund dafür ist, dass Ereignisse mit sehr hohen Niederschlagsmengen ($> 99,9$. Perzentil) in den Referenz- und Projektionsdaten nicht ausreichend repräsentiert sind und zudem eine hohe Streuung aufweisen.

Die Globalstrahlung (RSDS) wird mittels linearer Skalierung basierend auf Monatsmittelwerten der HYRAS-Daten korrigiert. Untersuchungen des HYRAS-Datensatzes (HYRAS-v1) ergaben, dass die RSDS-Werte lediglich für längere Mittelungsperioden vertrauenswürdig sind.

Der Luftdruck in Meereshöhe (PSL) wurde ebenfalls mittels linearer Skalierung Bias-adjustiert. Das einfache und schnelle Verfahren ist ausreichend, da PSL einen relativ geringen Wertebereich (Extrema weichen weniger als 5 % vom langjährigen Mittelwert ab) abdeckt, sowie relativ einfach zu modellieren ist. Als Referenz dienen Luftdruckdaten des Reanalysedatensatzes COSMO-REA6.

Die mittlere tägliche Windgeschwindigkeit (sfcWind) wurde mittels Quantil-Mapping Bias-adjustiert. Grund hierfür ist deren geringe Korrelation mit den übrigen Klimaparametern. Daneben wurden beim Quantil-Mapping nur Werte bis zum 99,9. Perzentil berücksichtigt, für höhere Werte wurde der Korrekturfaktor linear extrapoliert. Auch für diesen Parameter wurden Daten von COSMO-REA6 verwendet. Zu beachten ist, dass Extrema sowie Werte in höheren Lagen und an der Küste im Reanalysedatensatz einen Bias aufweisen (für hohe Windgeschwindigkeiten bis zu 10 m/s), der aufgrund mangelnder Stationsdaten nicht identifiziert werden kann.

3.2 Statistisches Downscaling

Statistisches Downscaling beinhaltet die Schätzung regionaler oder lokaler Klimavariablen aus Variablen größerer Skalen. Im Rahmen der Klimafolgenforschung, basiert statistisches Downscaling auf der Beziehung zwischen beobachteten Prädiktoren und Prädiktanten, angewendet auf Prädiktoren dynamischer Modellsimulationen. Ist eine solche Beziehung vorhanden, können gröberskalige Bedingungen, dargestellt von einem RCM (Prädiktor), auf die Projektion angewendet werden (TRZASKA und SCHNARR 2014).

Innerhalb der COST Action 733 wurde eine Reihe unterschiedlicher statistischer Downscaling-Verfahren untersucht (u. a. TVEITO und HUTH 2016; PHILIPP et al. 2010; BECK und PHILIPP 2010).

Das statistische Downscaling der Bias-adjustierten Resultate regionaler Klimamodelle erfolgt unter Zuhilfenahme einer Hauptkomponentenanalyse (*Principal Component Analysis*, PCA) ermittelter ty-

pischer Verteilungsmuster der jeweiligen Klimavariablen. Darunter liefert die PCA u. a. die Ladungsmatrix der Hauptkomponenten (*Principal Component, PC*), die im Folgenden *PC-Loading* genannt wird. Feinskalige Muster der jeweiligen Klimavariablen werden durch die Hauptkomponentenanalyse eines hochauflösenden Beobachtungs- oder Modelldatensatzes abgebildet.

Die Hauptkomponentenanalyse ist eine multivariate statistische Technik die häufig im Bereich der Atmosphärenwissenschaften verwendet wird (WILKS 2006). PCA ist im Grunde eine Untersuchungsmethode, die es erlaubt in meteorologischen Raum-Zeit-Feldern einen Satz typischer räumlicher Muster zu finden, die den größten Teil deren Varianz beschreiben.

Dazu wird eine Hauptachsentransformation durchgeführt, die das Koordinatensystem derart verändert wird, dass die Daten de-korreliert werden. Im Falle normalverteilter Datensätze sind die einzelnen Komponenten jedes Datensatzes nach der PCA voneinander unabhängig. Das nullte Moment der Komponenten charakterisiert die Normierung, das erste den Mittelwert und das zweite die Kovarianzen. Bei nicht normalverteilten Datensätzen bleibt ein Residuum als zusätzlicher Term.

Im Prinzip wird mittels PCA die große Zahl oft hoch miteinander korrelierter Variablen (redundante Information) auf deutlich weniger Variablen reduziert. Die neuen Variablen stellen Linearkombinationen der originalen Variablen dar und werden derart gewählt, sodass ein möglichst großer Teil der Varianz der originalen Variablen erklärt wird. Das Ziel der PCA, die Reduktion der Dimensionalität, wird erreicht indem nur die ersten „n“ Hauptkomponenten verwendet werden.

Hier wird die PCA für jeden Kalendermonat auf eine ausreichend lange Zeitreihe (> 10 Jahre) eines hochauflösenden Referenzdatensatzes (Beobachtungs- oder Modelldatensatz in der Zielauflösung) angewendet. Die Anzahl der resultierenden PCs entspricht der Anzahl der Zeitschritte des Datensatzes (bei 10 Jahren und täglicher Auflösung (z. B. im Januar) entspricht dies 310 PCs). Hochauflösende Felder einzelner Tage werden anschließend mittels linearer Kombination (multiple lineare Regression) einiger PCs (z. B. 30 PCs) erzeugt.

Die Downscaling-Methode umfasst somit folgende Schritte:

1. Anwendung der PCA auf hochauflösende Rasterdaten (Beobachtungen oder Reanalysedaten)
2. Regression: Ermittlung der statistischen Beziehung zwischen geringaufgelösten Modelldaten und den in Schritt 1. ermittelten *PC-Loadings* (hierzu räumliche Aggregation der *PC-Loadings* auf geringere Modellauflösung durch die Beschränkung auf die ersten Hauptkomponenten) → liefert Regressions-Koeffizienten
3. Anwendung der Regressions-Koeffizienten auf hochauflösende *PC-Loadings* (liefert Hintergrundfeld)
4. Differenz zwischen Regressions-Schätzwert und dem Wert der Modelldaten in der geringen Auflösung wird mittels inverser Distanzgewichtung in die Fläche interpoliert (liefert Residuenfeld)
5. Summe aus Regressionsfeld aus Schritt 2 und Residuenfeld aus Schritt 4 liefert das Downscaling-Resultat

4 Anwendungsbeispiel

4.1 Hauptkomponentenanalyse (PCA)

Zum Downscaling regionaler Klimaprojektionen werden mittels einer Hauptkomponentenanalyse ermittelte räumliche Kovarianzmuster verschiedener Klimavariablen als Prädiktoren verwendet. Diese Muster stehen im Zusammenhang mit wiederkehrenden Wetterereignissen über der HYRAS-Region, inklusive deren hochauflösender Strukturen. Typische Muster werden monatlich aus den täglichen Feldern des Zeitraums 1961–2010 ermittelt. Abbildung 2 zeigt die ersten fünf PCs der mittleren Tagesmitteltemperatur, Abbildung 3 jene des Niederschlags für die Monate Januar (a-e) und Juli (f-j).

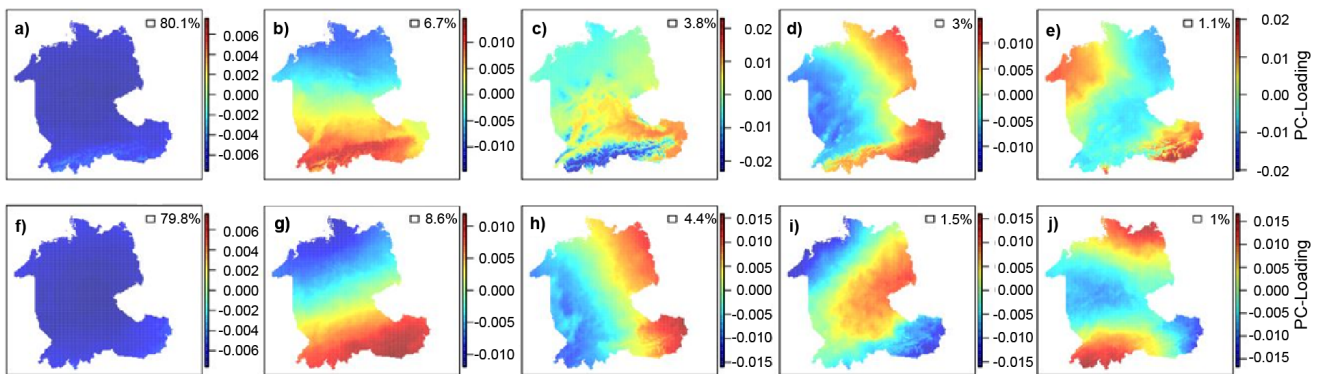


Abbildung 2: Räumliche Kovarianzmuster bzw. *PC-Loadings* der Tagesmitteltemperatur, a-e) im Januar und f-j) im Juli. Die Prozentangaben stehen für die erklärte Varianz.

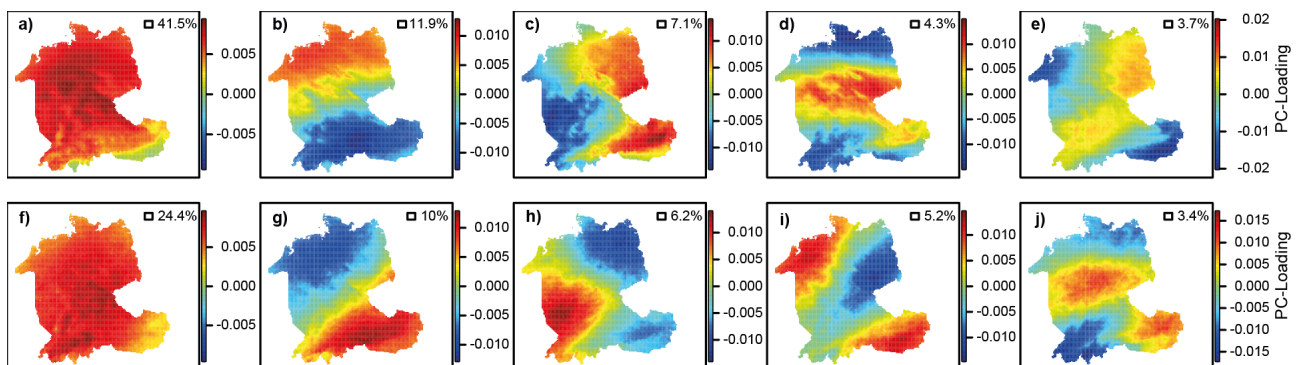


Abbildung 3: Räumliche Kovarianzmuster bzw. *PC-Loadings* des Tagesniederschlags, a-e) im Januar und f-j) im Juli. Die Prozentangaben stehen für die erklärte Varianz.

4.2 Statistisches Downscaling

Abbildung 4 illustriert die relevanten Schritte zur Erstellung hochauflösender Felder der Tagesmitteltemperatur für den 29.6.1995. Das originale Temperaturfeld des Modells MPI-REMO über der HYRAS-Region (0.11° Auflösung) ist in Abbildung 4a dargestellt. Multiple lineare Regression, unter Verwendung der ersten 30 Kovarianzfelder, sowie Länge, Breite und Geländehöhe, liefert die in Abbildung 4b gezeigte Temperaturkarte als Zwischenprodukt. Die Regressionskoeffizienten werden in der Auflösung des regionalen Klimamodells (~ 12 km) geschätzt. Dazu werden die aus den Be-

obachtungsdaten in $5 \times 5 \text{ km}^2$ Auflösung ermittelten Kovarianzfelder zunächst auf die Modellauflösung aggregiert. Die Koeffizienten werden anschließend auf die hochauflösenden Kovarianzfelder ($5 \times 5 \text{ km}^2$) angewendet. Um lokale Einflüsse besser erfassen zu können, erfolgt die Regression unabhängig in 13 Teilregionen des HYRAS-Gebiets. Das großräumige Muster der Lufttemperatur ändert sich zwar kaum, besonders in Regionen komplexer Topographie (Alpen- und Mittelgebirgsraum) werden kleinskalige topographische Strukturen wie Täler und Bergmassive jedoch gut modelliert.

In einem weiteren Schritt werden im Regressionsschritt unzureichend erfasste lokale Abweichungen mittels inverser Distanzgewichtung (*Inverse Distance Weighting*, IDW) interpoliert. Zur Quantifizierung der lokalen Abweichungen bzw. Residuen, werden die Regressionkoeffizienten ebenfalls auf Kovarianzfelder in Modellauflösung angewendet und das Resultat mit den modellierten Werten verglichen. Die Differenz entspricht dabei dem Residuum. Die Abweichungen zwischen der mittels Regression geschätzten und der modellierten Temperaturwerte sind meist gering ($<5 \text{ }^\circ\text{C}$). Die größten Abweichungen treten dabei an der Küste sowie im Alpenraum auf. IDW-Interpolation der Residuen liefert die in Abbildung 4c illustrierte räumliche Verteilung. Summation der Resultate beider Schritte (lineare Regression und Residueninterpolation) liefert das in Abbildung 4d dargestellte hochauflösende Endprodukt.

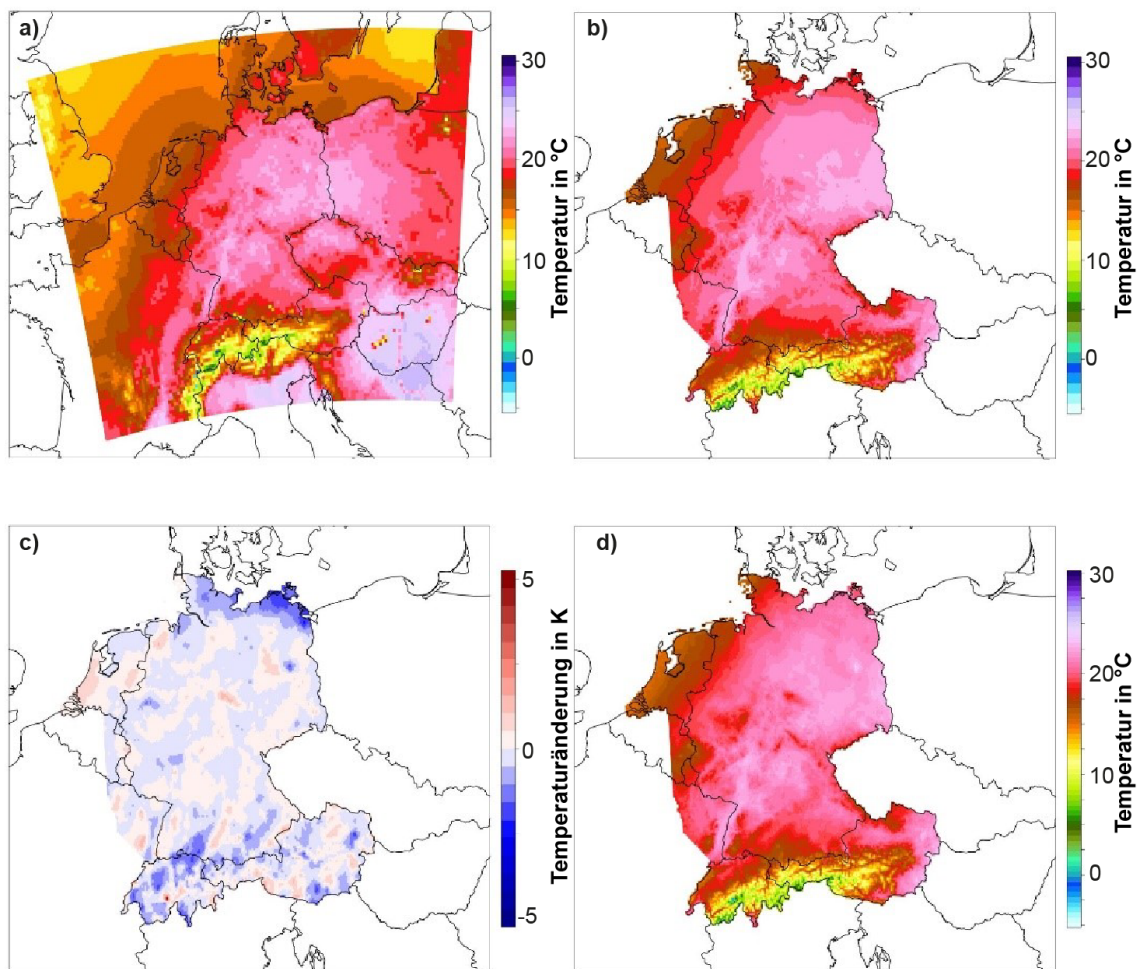


Abbildung 4: Schritte zum Downscaling der Tagesmitteltemperatur des Modells MPI-REMO am 29.06.1995, a) Originalfeld, b) Downscaling nach Anwendung multipler linearer Regression, c) interpolierte Regressionsresiduen und d) Downscaling-Resultat.

4.3 Multivariate Bias-Adjustierung

Die Vorgehensweise zur multivariaten Bias-Adjustierung wird im Folgenden anhand des Modells MPI-REMO am Gitterpunkt 9.96° E / 51.51° N illustriert. Abbildung 5a zeigt die empirische Verteilungsfunktion (ecdfs) der Beobachtungen (schwarze Linie) und der Modelldaten (grün). Gut zu erkennen ist, dass der Bias stark vom Perzentil abhängt (siehe auch Abbildung 5b). Während der Bias für die untersten Perzentile leicht positiv ist (das Modell ist hier zu warm), sind insbesondere die mittleren und etwas abgeschwächt auch die hohen Perzentile negativ (das Modell ist zu kalt). In Abbildung 5c ist das Klimasignal (für den Zeitraum 2020–2050 im Vergleich zu 1971–2000) in Abhängigkeit vom Perzentil dargestellt. Das Klimasignal variiert mit dem Perzentil sehr stark und ist im gezeigten Beispiel für mittlere Perzentile stärker ausgeprägt als für Extrema.




Abbildung 5: a) Verteilungsform für die mittlere Lufttemperatur, sowie b) für QDCM benötigte Perzentil-Abhängigkeit des Bias und c) Klimasignal 2021–2050 im Vergleich zu 1971–2000. Dargestellt für das Klimamodell MPI-REMO im Januar und am Gitterpunkt 9.96° E/51.51° N.

Entsprechend der Empfehlung des IPCCs (STOCKER et al. 2015) wurde das hier angewendete Bias-Adjustierungsverfahren für einen unabhängigen Zeitraum evaluiert. Das heißt der Bezugszeitraum (1951–1960 sowie 1981–1990) und der Evaluationszeitraum (1961–1980; Abbildung 6a) überschneiden sich nicht. Der Evaluationszeitraum wurde so gewählt, dass das Klimasignal im betrachteten Zeitraum möglichst gering ausfällt. Geprüft wurden fünf unterschiedliche Bias-Adjustierung Settings über einem Gebiet von 11x11 Gitterpunkten (Modellauflösung 0.11°) im Raum Fulda (Abbildung 6b). Auswertgrundlage sind die DWD-Referenz-Ensembles (Abbildung 1). Folgende fünf Settings wurden geprüft:

- Setting 1: MBCn mit allen Variablen
- Setting 2: MBCn mit Temperaturvariablen (inklusive TDEW)
- Setting 3: MBCn mit PR und RSDS
- Setting 4: QDCM
- Setting 5: MBCn mit Temperaturparametern + RSDS

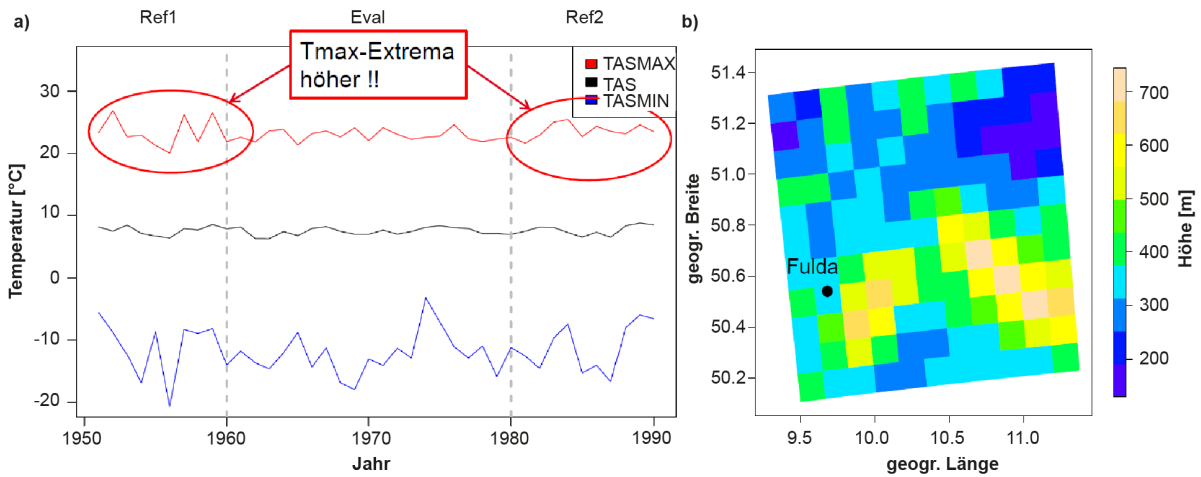


Abbildung 6: a) Evaluationszeitraum und b) Evaluationsgebiet.

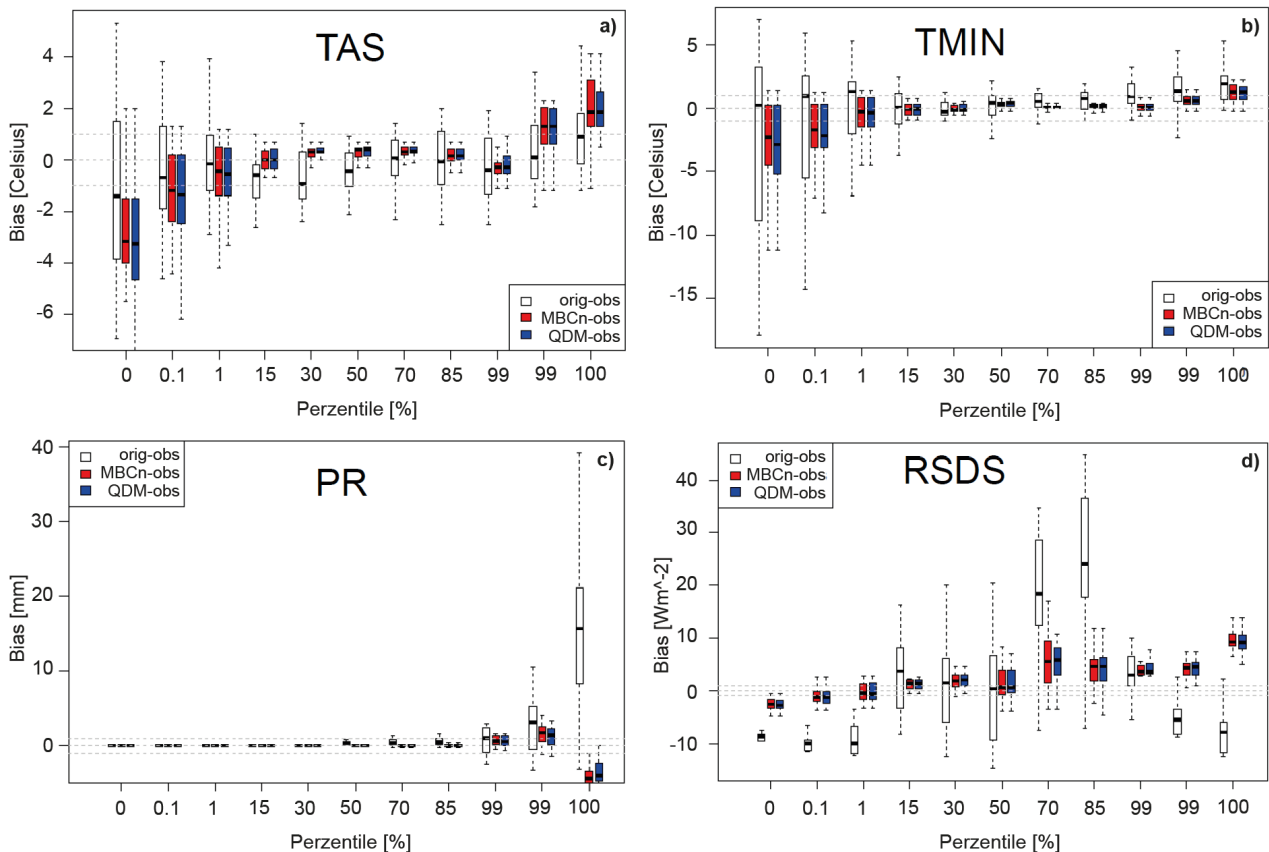


Abbildung 7: Bias-Perzentilbewertung für die Tagesmitteltemperatur (a), Minimumtemperatur (b), Niederschlag (c) und Globalstrahlung (d). Dargestellt sind Setting1 (rot) und Setting 4 (blau), sowie, das gesamte Ensemble (weiß) für das Zielgebiet um Fulda.

Abbildung 7 zeigt den perzentilweise ausgewerteten Bias für vier Variablen und zwei Settings (rot: MBCn mit allen Variablen, blau: QDCM) über alle Gitterzellen im Auswertebereich (um Fulda). Bei TAS reduzieren beide Settings den Bias im Bereich vom 15. Perzentil bis zum 99. Perzentil. Die Differenzen zwischen den korrigierten Modellwerten und den Beobachtungen liegen im Mittel bei 0

und streuen deutlich weniger. In den niedrigsten Perzentilen wird der Bias nach der Korrektur dagegen im Mittel noch etwas negativer, die Streuung nimmt hingegen ein wenig ab. Im hohen Perzentilbereich werden die höchsten Werte nach der Korrektur noch etwas mehr überschätzt als zuvor. Die Zeitreihe in Abbildung 6a liefert die Erklärung dazu. Offensichtlich sind die Extrema in der Bezugsperiode etwas ausgeprägter als im Auswertzeitraum und folglich nicht stationär. Somit kann die Bias-Adjustierung hier für Extrema keine robusten Resultate liefern. Ein ähnliches Ergebnis wird für TASMİN gefunden. Auch hier tritt vor allem im mittleren Perzentilbereich eine deutliche Verbesserung auf. Allerdings bereits ab dem 1. Perzentil. Zudem wird der Bias für die höchsten Perzentile ebenfalls etwas kleiner.

Auch für den Niederschlag lieferte die Bias-Adjustierung beider Settings im Allgemeinen ein gutes Ergebnis, insbesondere bis zum 99. Perzentil. Zu beachten ist, dass zur Ableitung der Transferfunktion für den Niederschlag nur Werte bis zum 99,9. Perzentil berücksichtigt werden. Der Korrekturwert für darüber liegende Niederschlagswerte ergibt sich aus einer linearen Extrapolation der Korrekturwerte vom 99,5. bis 99,9. Perzentil. Niederschlagswerte über dem 99,9. Perzentil werden vor der Korrektur zwar überschätzt, danach aber aufgrund der Vorgehensweise bei der Korrektur recht deutlich unterschätzt.

Die Auswertung für die Globalstrahlung ergab für die meisten Perzentile erhebliche Unterschiede zwischen den Beobachtungen und den unkorrigierten Modelldaten. Die deutlichen Differenzen in den unkorrigierten Daten stehen mit Ungenauigkeiten in den Beobachtungsdaten in Zusammenhang. Untersuchungen der HYRAS-Daten (HYRAS-v1) ergaben, dass die Globalstrahlungswerte niedriger Perzentile teilweise deutlich zu hoch sind. Ursache dafür ist, dass nur wenige Stationen in Deutschland Globalstrahlung messen. Um dennoch eine hohe räumliche Stationsdichte zu erlangen, wurden mittels eines von ANGSTROM (1956) beschriebenen Verfahrens deutlich häufigere Sonnenscheindauerdaten in Globalstrahlung umgerechnet. Dieses Verfahren liefert für eine bestimmte Sonnenscheindauer jeweils den deterministischen Erwartungswert zurück (unabhängig davon um welche Uhrzeit die Sonne schien). Die tatsächliche Globalstrahlung kann aber für eine bestimmte Sonnenscheindauer sehr unterschiedlich ausfallen. Da die Mittelwerte über längere Zeiträume in den HYRAS-Daten allerdings gut repräsentiert sind, wurde entschieden, die modellierte Globalstrahlung auf Basis klimatologischer Monatswerte zu korrigieren.

Wie aus den Abbildungen 8a und 8b zu entnehmen ist, sind die Temperaturgrößen jeweils hoch miteinander korreliert. Die Korrelation zwischen TAS und TASMİN ist dabei etwas höher als jene zwischen TASMİN und TASMİN. Die Temperaturgrößen sind zudem mäßig gut korreliert mit RSDS, aber nahezu gar nicht mit PR. Im Vergleich mit den Beobachtungsdaten zeigen die Modelldaten für sämtliche Variablen eine sehr ähnliche Korrelation. Jedoch werden die Korrelationen zwischen TAS und TASMİN, bzw. zwischen TASMİN und TASMİN nach Anwendung von MBCn noch etwas verbessert.

Der PR ist in den Beobachtungsdaten nur schwach mit TDEW und RSDS (Abbildung 8c) korreliert. Diese geringe Korrelation wird von den Modellen allgemein gut wiedergegeben. Die ursprünglich leicht überschätzte Korrelation zwischen PR und TDEW wird nach Anwendung von MBCn verbessert. Die Korrelation zwischen PR und RSDS ist in den Modelldaten dagegen deutlich höher als in den Beobachtungsdaten, wobei die Unterschiede zwischen den Modellen ebenfalls groß ist (große Streuung). Die scheinbar deutliche Überschätzung im Modell dürfte aber mit den Ungenauigkeiten in den HYRAS-Daten im Zusammenhang stehen. Gerade bei Regen ist die Trübung der Atmosphäre hoch und die Globalstrahlung zugleich tief, dies wurde bei der Berechnung der Globalstrahlung aus der Sonnenscheindauer im HYRAS-Datensatz allerdings nicht berücksichtigt.

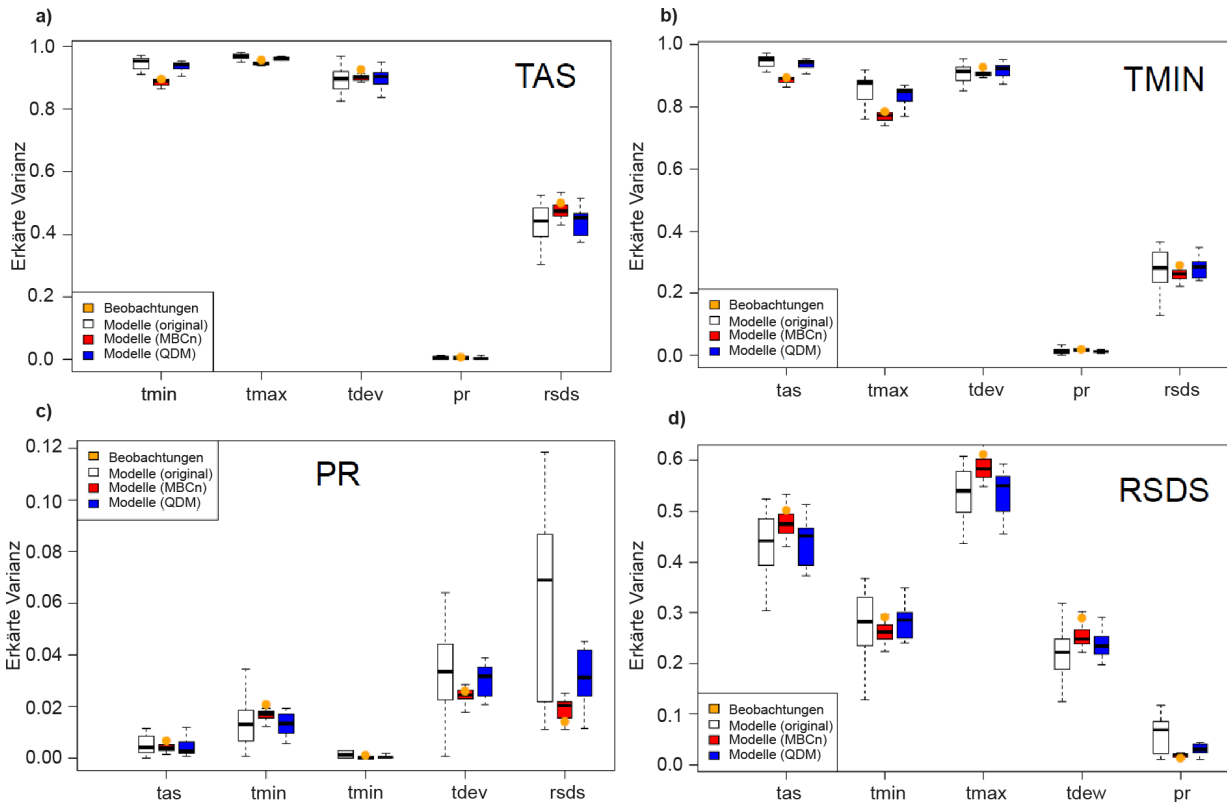


Abbildung 8: Erklärte Varianz zwischen den Variablen für zwei Settings, das gesamte Ensemble und das Zielgebiet, für a) TAS, b) TMIN, c) PR und d) RSDS. Dargestellt ist jeweils die Spanne der Korrelationen über alle Ensemblemitglieder für unkorrigierte (weiß), mittels MBCn (rot) bzw. QDCM Bias-adjustierte Daten (blau), sowie die Korrelation in den Beobachtungsdaten (orange).

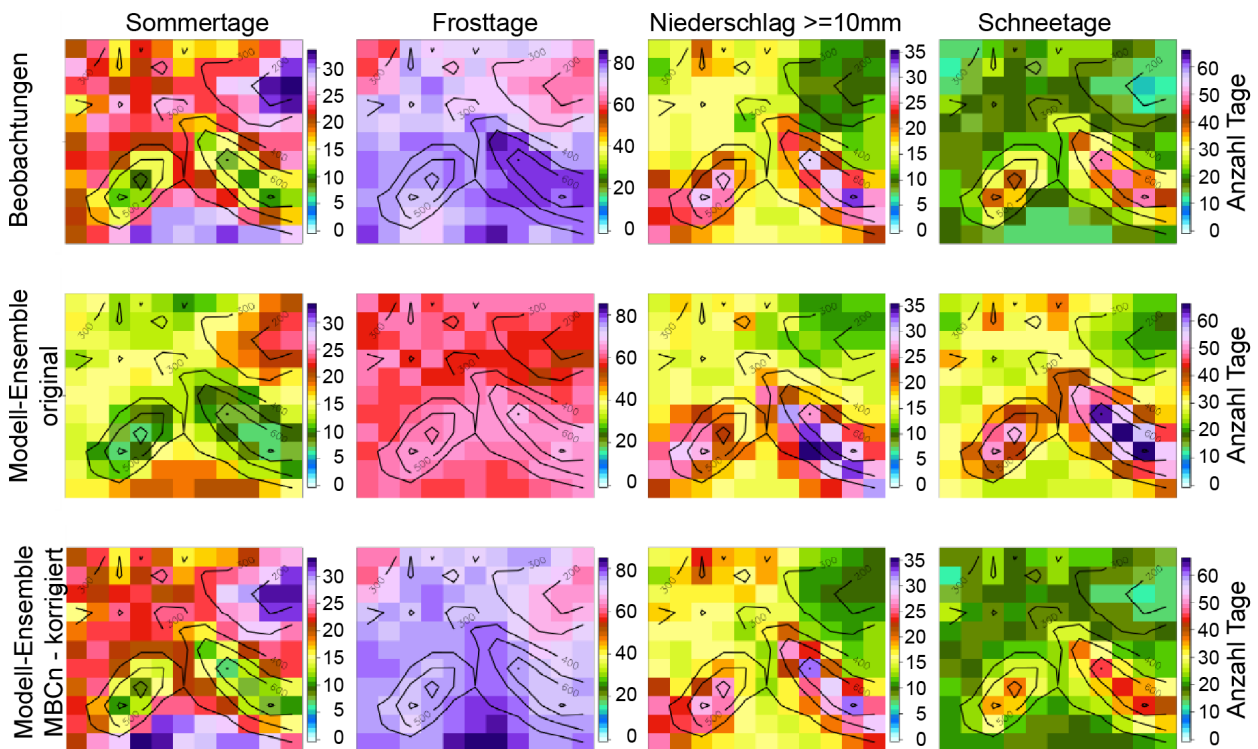


Abbildung 9: Vergleich von vier Klimaindizes (Sommertage, Frosttage, PR $\geq 10\text{mm}$, Schneetage) in originalen bzw. Bias-adjustierten Modelldaten mit Beobachtungen, für das gesamte Ensemble sowie das Zielgebiet.

Im Ensemble-Mittel werden nach der Bias-Adjustierung sämtliche Klimaindizes realistischer dargestellt (Abbildung 9). Vor der Bias-Adjustierung waren die Unterschiede zwischen Ensemblemittel und Beobachtungen dagegen noch teils beträchtlich. Interessant ist, wie sich die Anzahl Schneetage (Tage mit min. 1 mm Niederschlag und $TAS < 0\text{ °C}$) durch die Bias-Adjustierung verbessert. Dies zeigt, dass die Konsistenz zwischen den beiden Größen TAS und PR auch nach der Bias-Adjustierung realistisch wiedergegeben wird.

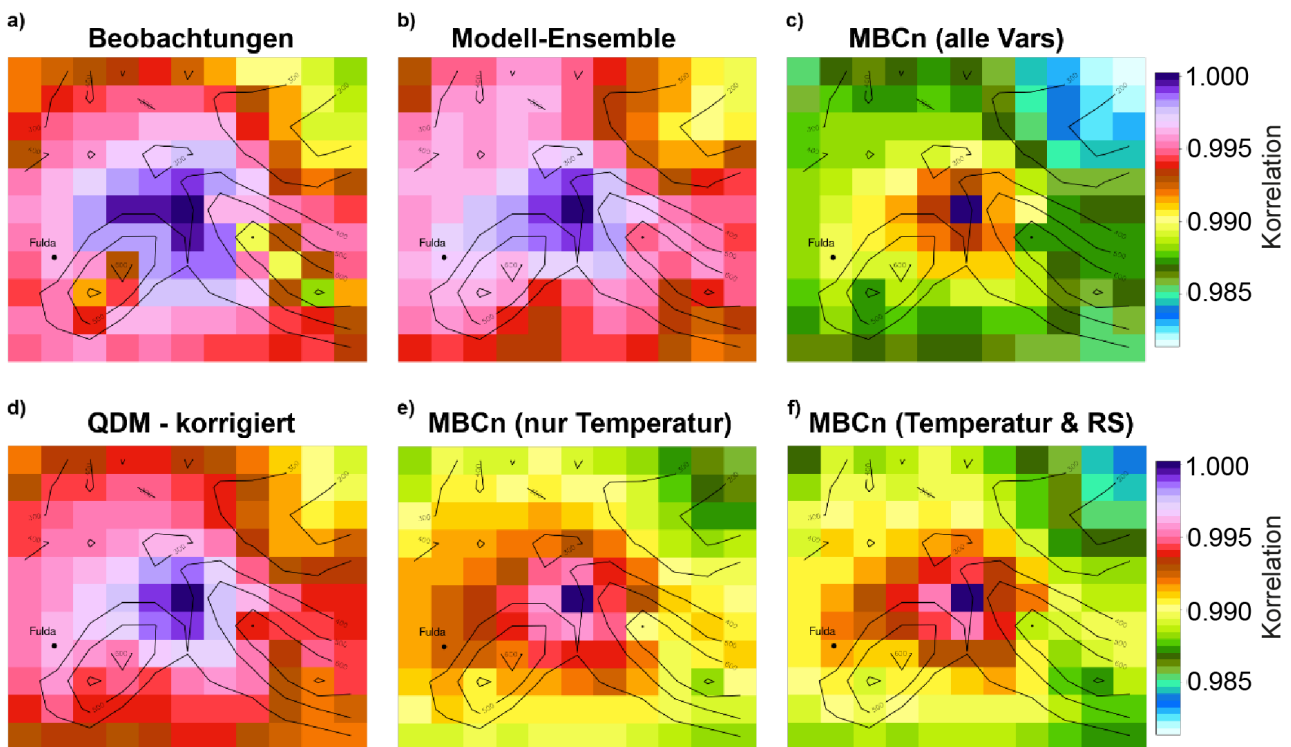


Abbildung 10: Korrelation der mittleren Gitterzelle mit den übrigen Gitterzellen für das Tagesmittel der Lufttemperatur (TAS), a) Beobachtungen, b) originale Modelldaten, c) MBCn mit allen Variablen, d) QDCM, e) MBCn nur mit Temperaturvariablen und f) MBCn mit Temperaturvariablen sowie RSDS.

Im Beobachtungsdatensatz ist die TAS-Zeitreihe des mittleren Gitterpunktes des Untersuchungsgebiets zumeist sehr hoch korreliert mit den außenliegenden Gitterpunkten (Abbildung 10a). Lediglich in erhöhten Lagen ($>500\text{ m}$) ist die Korrelation deutlich geringer. Dies wird vom Ensemble der unkorrigierten Modelldaten insgesamt gut wiedergegeben. Allerdings wird die Korrelation in erhöhten Lagen etwas überschätzt. Dies dürfte daran liegen, dass Inversionslagen (in diesem Fall ist die Korrelation in unterschiedlichen Höhenlagen geringer) in Klimamodellen nur unzureichend oder gar nicht wiedergegeben werden können. Eine multivariate Bias-Adjustierung (Abbildung 10c, 10e, 10f) stört die räumliche Korrelation sichtlich, die Korrelation nimmt von der mittleren Gitterzelle ausgehend rascher ab. Die Abnahme der Autokorrelation ist bei Verwendung aller Klimavariablen am höchsten. Werden nur temperaturbasierte Variablen berücksichtigt, bleibt die räumliche Autokorrelation etwas besser erhalten; wobei die Höhenabhängigkeit der Korrelation nicht verbessert wird. Am besten erhalten bleibt die Autokorrelation, wenn die Variablen unabhängig (mit QDCM) voneinander Bias-adjustiert werden (Abbildung 10d). Die Verminderung der räumlichen Korrelation bei Verwendung von MBCn liegt daran, dass der Korrekturwert für sehr extreme TAS-Werte (sehr hohes oder sehr niedriges Perzentil) sich von Gitterzelle zu Gitterzelle teils deutlich unterscheiden kann.

Die Korrektur mittels MBCn führt dabei zu relativ groben Temperaturkarten für extreme Tage, mit erheblichen räumlichen Unterschieden. Je mehr Variablen mittels MBCn gleichzeitig berücksichtigt werden, umso weniger robust ist der Korrekturwert für Tage mit extremen Werten.

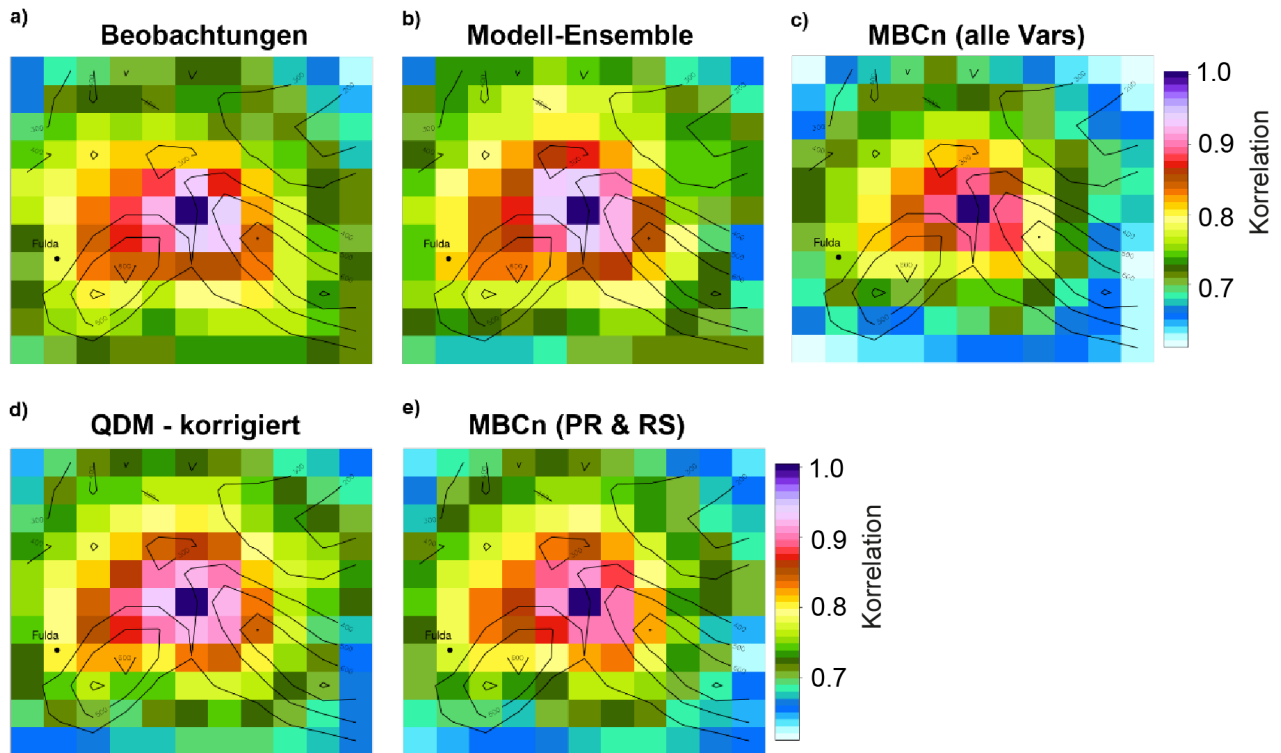


Abbildung 11: Korrelation der mittleren Gitterzelle mit den übrigen Gitterzellen für den Niederschlag (PR), a) Beobachtungen, b) originale Modelldaten, c) MBCn mit allen Variablen, d) QDCM, e) MBCn mit PR und RSDS.

Die räumliche Autokorrelation ist für PR deutlich geringer als für TAS (Abbildung 11). Dies liegt an der höheren räumlichen Variabilität des Niederschlags. Die beobachtete räumliche Korrelation (Abbildung 11a) wird von den originalen Modelldaten (Abbildung 11b) gut wiedergegeben. MBCn unter Verwendung aller Variablen führt wiederum zu einer Verminderung der Autokorrelation, wenn auch etwas weniger stark ausgeprägt als bei TAS. Auch hier erhält QDCM die räumliche Struktur etwas besser als MBCn. Die Verminderung der räumlichen Korrelation bei Verwendung von MBCn ist für PR etwas weniger gravierend. Die Korrektur mittels MBCn führt dabei zwar ebenfalls (wie für TAS) zu relativ groben Niederschlagskarten für extreme Tage, allerdings unterscheiden sich sehr extreme PR-Werte in der Realität an einzelnen Tagen von Gitterzelle zu Gitterzelle ebenfalls deutlich.

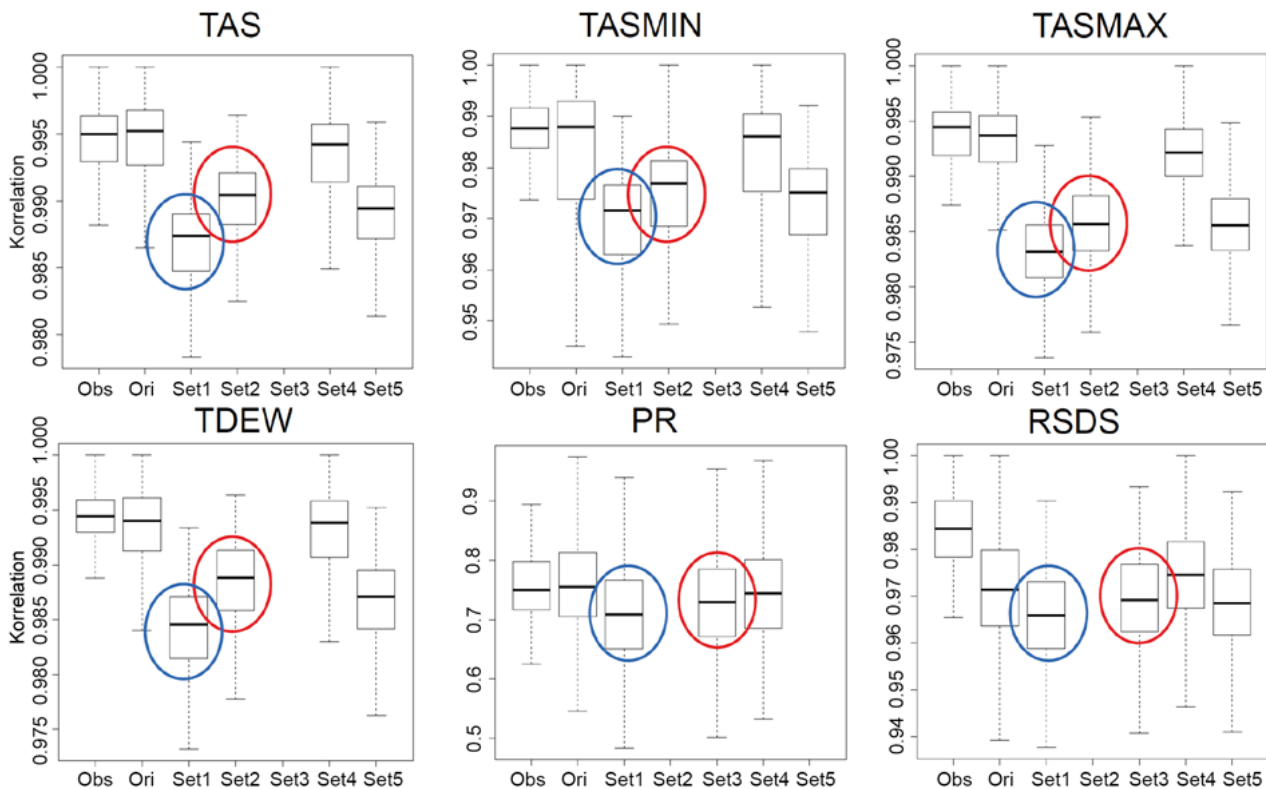


Abbildung 12: Korrelation der mittleren Gitterzelle mit den übrigen Gitterzellen für 6 Klimavariablen und 5 verschiedene Settings. Die Spannweite ergibt sich für die Beobachtungen über die Gitterzellen im Gebiet und die Modelle zudem über das Ensemble.

Wie bereits Abbildungen 10 und 11 zeigen, reproduzieren Klimamodelle die räumliche Autokorrelation für tägliche Daten gut, was auch Abbildung 12 bestätigt. Univariate Bias-Adjustierung (Setting 4) stört die Korrelation am wenigsten, MBCn mit sämtlichen Variablen am meisten. Gut zu sehen ist auch, dass MBCn besonders im Fall der Temperaturvariablen zu einer Verminderung der räumlichen Korrelation führt. Dieser Effekt ist bei PR aufgrund seiner natürlichen hohen räumlichen Variabilität nicht so stark ausgeprägt. Gut zu sehen ist in Abbildung 12 (unten links) dass das Modellensemble eine deutlich geringere räumliche Autokorrelation aufweist, als die Beobachtungen. Dies liegt daran, dass zur Erstellung des HYRAS-Datensatzes oftmals aus Sonnenscheindauer berechnete RSDS-Werte verwendet wurden und diese aufgrund des Umrechnungsverfahrens eine zu geringe räumliche Variabilität aufweisen.

5 Fazit und Diskussion

Mittels Kreuzvalidierung wurde ein von CANNON (2018) entwickeltes Bias-Adjustierungsverfahren in unterschiedlichen Settings über einem Gebiet um Fulda (9.5° E – 11.5° E / 50.1° N – 51.4° N) geprüft. Insgesamt brachten sämtliche Settings eine deutliche Verbesserung der Klimaprojektionsdaten in den unterschiedlichen Perzentilen. Allerdings konnten extreme Werte (unterste bzw. oberste Perzentile) für die verschiedenen Klimaparameter nur bedingt verbessert werden, bzw. vergrößerte sich der Bias nach der Bias-Adjustierung gar. Grund dafür ist die Instationarität der Extremwerte und deren Seltenheit, weshalb die Korrekturwerte nicht robust geschätzt werden können.

Im MBCn-Mode wurde der Bias ebenso gut verbessert wie im QDCM-Mode. Daneben verbesserte sich mittels MBCn insbesondere die Korrelation zwischen den Temperaturvariablen. Allerdings brachte die Anwendung von MBCn eine Verschlechterung der räumlichen Autokorrelation. Dies ist besonders auffällig für temperaturbasierte Variablen. Der im MBCn Verfahren ermittelte Korrekturwert ist für sehr extreme TAS-Werte (sehr hohes oder sehr niedriges Perzentil) an einzelnen Tagen von Gitterzelle zu Gitterzelle teils deutlich verschieden. Die Korrektur mittels MBCn führt dann zu relativ großen Temperatursprüngen. Je mehr Variablen gleichzeitig in MBCn berücksichtigt werden, umso weniger robust ist der Korrekturwert für extreme Tage. Für Niederschlag konnte zwar ebenfalls eine Reduktion der räumlichen Korrelation gefunden werden, allerdings weniger gravierend. Allerdings ist die räumliche Korrelation von Niederschlag wesentlich geringer als beispielsweise bei der Tagesmitteltemperatur, unter anderem unterscheiden sich extreme Niederschlagswerte in der Realität an einzelnen Tagen von Gitterzelle zu Gitterzelle ebenfalls deutlich.

Zu beachten ist, dass das Ergebnis der Bias-Adjustierung aufgrund der zufälligen Rotation nicht deterministisch ist. Folglich liefern zwei idente Bias-Adjustierungsanwendungen jeweils leicht voneinander abweichende Ergebnisse. Die Abweichung ist für mittlere Werte gering, für Extrema kann diese jedoch einige Prozent betragen (siehe Kapitel 3.1).

Basierend auf den Resultaten wurde entschieden, die temperaturbasierten Variablen multivariat mittels MBCn zu korrigieren. Dadurch verbessert sich einerseits die Korrelation der Parameter zueinander, andererseits bleibt die räumliche Korrelation besser erhalten.

Der Niederschlag (PR) wird mittels QDCM univariat adjustiert. Wobei nur Werte bis hin zum 99,9. Perzentil berücksichtigt werden. Für höhere Werte ist eine robuste Abschätzung des Korrekturwerts nicht möglich und dieser wird linear extrapoliert. Aus diesem Grund sind nur Auswertungen bis zum 99,9 Perzentil möglich.

Untersuchungen ergaben, dass die Globalstrahlung (RSDS) des HYRAS-Datensatzes lediglich im längeren zeitlichen Mittel vertrauenswürdig ist. Daher wird RSDS mittels linearer Skalierung Bias-adjustiert. Als Folge der mittelwert-basierten Korrektur von RSDS, sind Extrema in deren Bias-adjustierten Daten mit Bedacht zu verwenden. Von extremwertstatistischen Auswertungen wird abgeraten.

Der Luftdruck in Meereshöhe (PSL) wird ebenfalls mittels linearer Skalierung Bias-adjustiert. Da PSL einen relativ geringen Wertebereich hat, kann hier ein einfaches Korrekturverfahren eingesetzt werden. Aufgrund von Umrechnungsfehlern (von PS in PSL) weisen die korrigierten Daten in Lagen oberhalb von 100 m. ü. M. einen Bias von maximal 3 hPa auf.

Die mittlere tägliche Windgeschwindigkeit (sfcWind) wird mittels Quantil-Mapping Bias-adjustiert. Dabei ist zu beachten, dass der Referenzdatensatz COSMO-REA6 in seinen Extremen sowie in

höheren Lagen und an der Küste für hohe Windgeschwindigkeiten bis zu 10 m/s einen (aufgrund von Mangel an Stationsdaten zur Auswertung) nicht genau bekannten Bias aufweist. Zudem werden beim Quantil-Mapping nur Windwerte bis zum 99,9. Perzentil berücksichtigt, für darüber liegende Werte wird der Korrekturfaktor linear extrapoliert. Daher sind Extrema sowie Daten in erhöhten Lagen sowie an der Küste mit Bedacht zu verwenden.

Literaturverzeichnis

- ANGSTROM, A., 1956: On the computation of global radiation from records of sunshine. *Arkiv för Geofysiks* **22**, 471-479.
- BECK, C., PHILIPP, A., 2010: Evaluation and comparison of circulation type classifications for the European domain. *Phys. Chem. Earth* **35**, 374-387.
- BOLLMEYER, C., KELLER, J.D., OHLWEIN, C., WAHL, S., CREWELL, S., FRIEDERICHS, P., HENSE, A., KEUNE, J., KNEIFEL, S., PSCHIEDT, I., REDL, S., STEINKE, S., 2015: Towards a high-resolution regional reanalysis for the European CORDEX domain. *Q.J.R. Meteorol. Soc.* **141**, 1-15.
- CANNON, A.J., 2018: Multivariate quantile mapping bias correction: An N-dimensional probability density function transform for climate model simulations of multiple variables. *Climate Dynamics* **50**, 31-49.
- CANNON, A.J., SOBIE, S.R., MURDOCK, T.Q., 2015: Bias correction of simulated precipitation by quantile mapping: how well do methods preserve relative changes in quantiles and extremes? *Journal of Climate* **28**, 6938-6959.
- IPCC, STOCKER, T.F., Qin D., Plattner G.-K., Tignor M., Allen S.K., Boschung J., Nauels A., Xia Y., Bex, V., Midgley, P.M., 2013: Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. *Cambridge University Press*, Cambridge and New York, 1535 pp.
- NIERMANN, D., BORSCHKE, M., KAISER-WEISS, A., VAN DEN BESSELAA, E., VAN DER SCHRIER, G., CORNES, R., DE VREEDE E., LUSSANA C., TVEITO, O.E., CANTARELLO, L., FREI, C., ISOTTA, F., DAVIE, J., 2017: Report for Deliverable 3.6: Scientific report on assessment of regional analysis against independent data sets. Seventh Framework Programme Theme 6 (SPACE).
- OLSSON, J., BERGGREN, K., OLOFSSON, M., VIKLANDER, M., 2009: Applying climate model precipitation scenarios for urban hydrological assessment: a case study in Kalmar City, Sweden. *Atmos. Res.* **92**, 364-375.
- PHILIPP, A., BARTHOLY, J., BECK, C., ERPICUM, M., ESTEBAN, P., FETTWEIS, X., HUTH, R., JAMES, P., JOURDAIN, S., KREIENKAMP, F., KRENNERT, T., LYKOUKIDIS, S., MICHAELIDES, S., PIANKO-KLUCZYNSKA, K., POST, P., RASILLA, D., SCHIEMANN, R., SPEKAT, A., TYMVIOS, F., 2010: COST733CAT – a database of weather and circulation type classifications. *Phys. Chem. Earth* **35**, 360-373.
- RAUTHE, M., STEINER, H., RIEDIGER, U., MAZURKIEWICZ, A., GRATZKI, A., 2013: A Central European precipitation climatology – Part I: Generation and validation of a high-resolution gridded daily data set (HYRAS). *Met Z* **22**, 235-256.
- ROECKNER, E., 2003: Allgemeine Zirkulationsmodelle, Atmosphäre. In: Deutscher Wetterdienst (Hrsg.): Numerische Klimamodelle – Was können sie, wo müssen sie verbessert werden? Teil II: Modellierung natürlicher Klimaschwankungen, *Promet* **29**, 6-14.
- STOCKER, T.F., DAHE, Q., PLATTNER, G.-K., TIGNOR, M., 2015: IPCC Workshop on Regional Climate Projections and their Use in Impacts and Risk Analysis Studies. São José dos Campos, Brazil, 15-18 September 2015.
- TRZASKA S., SCHNARR E., 2014: A review of downscaling methods for climate change projections. *United States Agency for International Development*, Pennsylvania, 56pp.
- TVEITO, O.E., HUTH, R., 2016: Circulation-type classifications in Europe: results of the COST 733 Action. *Int. J. Climatol.* **36**, 2671-2672.
- WANG, L., CHEN, W., 2014: Equiratio cumulative distribution function matching as an improvement to the equidistant approach in bias correction of precipitation. *Atmos. Sci. Lett.* **15**, 1-6.
- WILKS, S.D., 2006: Statistical methods in the atmospheric sciences. *Academic Press*, Burlington, 627 pp.

Abkürzungsverzeichnis

HYRAS	Hydrometeorologische R asterdatensätze
IDW	Inverse Distanzgewichtung (<i>Inverse Distance Weighting</i>)
MBCn	<i>Multivariate Bias Correction in n dimensions</i>
PC	Hauptkomponenten (<i>Principal Component</i>)
PCA	Hauptkomponentenanalyse (<i>Principal Component Analysis</i>)
PR	Niederschlag (<i>Precipitation</i>)
PSL	Luftdruck auf Meereshöhe (<i>sea-level pressure</i>)
QDCM	<i>Quantile-Delta-Change-Mapping</i>
RSDS	Globalstrahlung (<i>surface downward solar radiation</i>)
TAS	Tagesmittel der Lufttemperatur (<i>surface air temperature</i>)
TASMAX	Tagesmaximum der Lufttemperatur (<i>maximum surface air temperature</i>)
TASMIN	Tagesminimum der Lufttemperatur (<i>minimum surface air temperature</i>)
TDEW	Taupunkt (<i>dew point temperature</i>)

Berichte des Deutschen Wetterdienstes

Nr. 253 L. Hannak und S. Brinckmann:

Parallelmessungen an deutschen Klimareferenzstationen – Schlussfolgerungen im Hinblick auf Homogenität und Messunsicherheiten

Nr. 252 G. Mühlbacher, M. Koßmann, K. Sedlmeier und K. Winderlich:

Stadtklimatische Untersuchungen der sommerlichen Temperaturverhältnisse und des Tagesgangs des Regionalwindes („Alpines Pumpen“) in München

Nr. 251 T. Winterrath, C. Brendel, M. Hafer, T. Junghänel, A. Klameth, E. Walawender, E. Weigl und A. Becker: Erstellung einer radargestützten Niederschlagsklimatologie

Nr. 250 C. Hinz:

Optische Erscheinungen und andere ungewöhnliche Wetterphänomene auf der Wetterwarte Fichtelberg

Nr. 249 H. Noppel:

Modellbasierte Analyse des Stadtklimas als Grundlage für die Klimaanpassung am Beispiel von Wiesbaden und Mainz: Abschlussbericht zum Arbeitspaket 3 des Projekts KLIMPRAX Wiesbaden/Mainz - Stadtklima in der kommunalen Praxis

Nr. 248 U. Sievers:

Das kleinskalige Strömungsmodell MUKLIMO_3. - Teil 2: Thermodynamische Erweiterungen

Nr. 247 K. Trusilova und W. Riecke:

Klimauntersuchung für die Metropolregion Hamburg zur Entwicklung verschiedener meteorologischer Parameter bis zum Jahr 2050

Nr. 246 S. Hänsel, A. Schucknecht, F. Böttcher, C. Bernhofer und J. Matschullat:

Niederschlagsveränderungen in Sachsen von 1901 bis 2100 - Starkniederschlags- und Trockenheitstrends

Nr. 245 P. Winkler:

Untersuchung zu historischen und neuzeitlichen Dampfdruckmessungen am Observatorium Hohenpeißenberg

Nr. 244 C. Brendel, E. Brisson, F. Heyner, E. Weigl und B. Ahrens:

Bestimmung des atmosphärischen Konvektionspotentials über Thüringen

Nr. 243 K. Hoffmann, W. Bivour, B. Früh, M. Koßmann und P.-H. Voß:

Klimauntersuchungen in Jena für die Anpassung an den Klimawandel und seine erwarteten Folgen - ein Ergebnisbericht

Nr. 242 C. Stein und G. Maliltz:

Das Hochwasser an Elbe und Donau im Juni 2013: Wetterentwicklung und Warnmanagement des DWD: Hydrometeorologische Rahmenbedingungen

Nr. 241 A. Hoff, C. Drüe und H.-R. Sonnabend:

Messphysik und Datenverarbeitung der Verkehrsflugzeuge als meteorologische Sensorträger

Nr. 240 U. Sievers:

Das kleinskalige Strömungsmodell MUKLIMO_3. - Teil 1: Theoretische Grundlagen, PC-Basisversion und Validierung

Nr. 239 F. Herbert:

Die Erschließung der Rossby-Welle durch Lärmfilterung

Nr. 238 G. Augter:

Vergleich der Referenzmessungen des Deutschen Wetterdienstes mit automatisch gewonnenen Messwerten

Gesamtliste der „Berichte des Deutschen Wetterdienstes“ unter www.dwd.de/selbstverlag.



Deutscher Wetterdienst

Selbstverlag des Deutschen Wetterdienstes

Bildungszentrum

Am DFS-Campus 4

63225 Langen