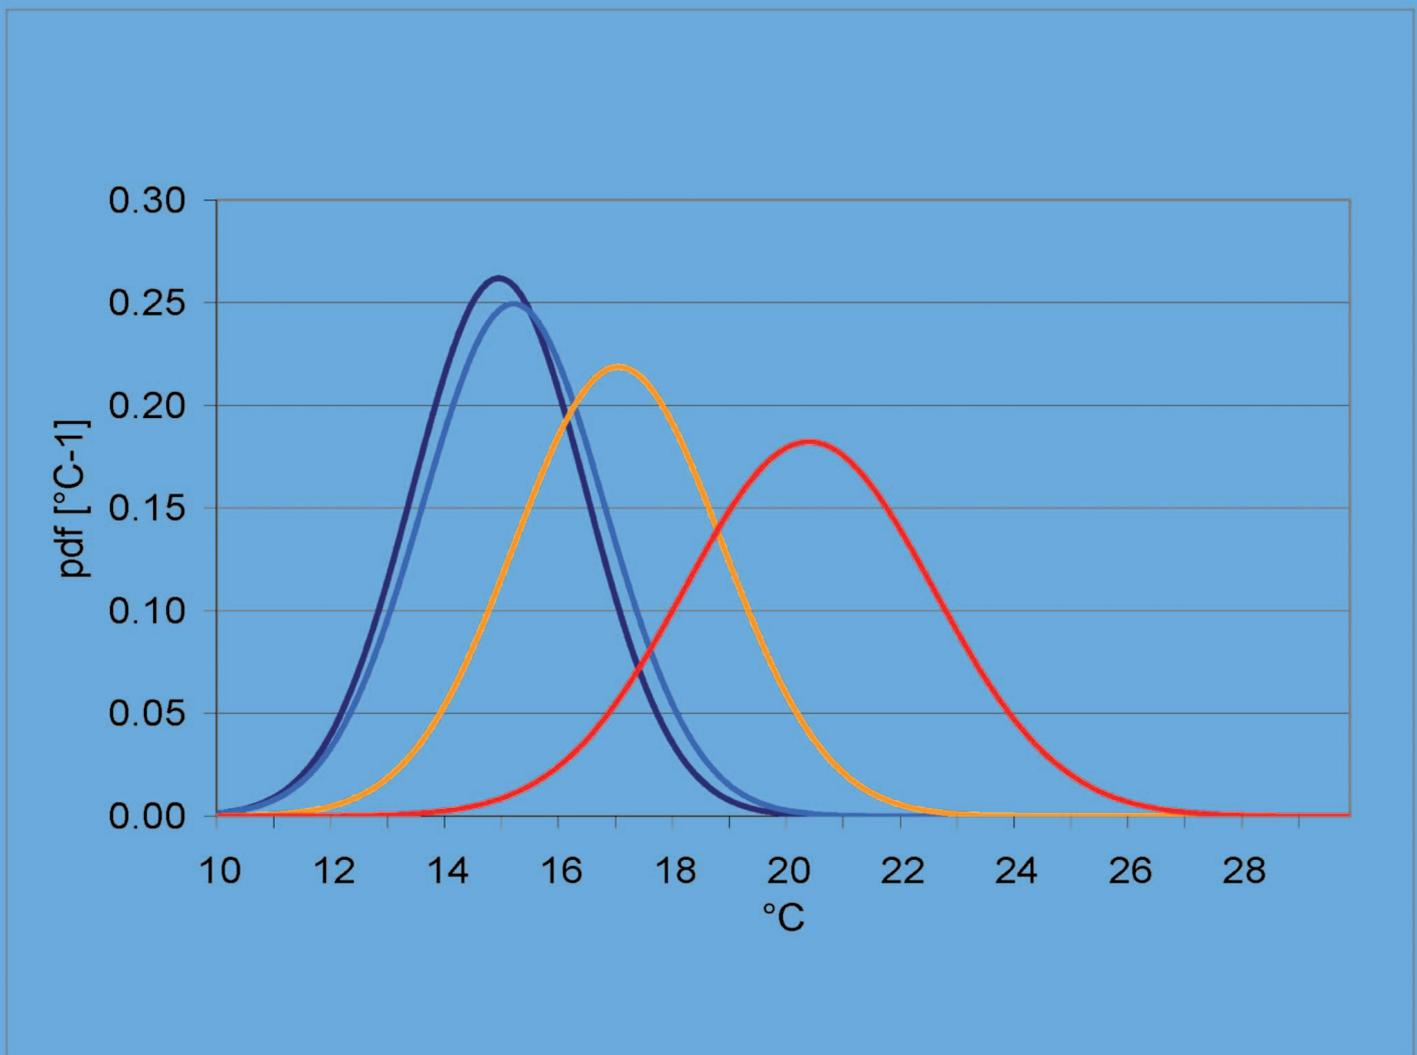


CSC Report 13

Statistische Verfahren zur Auswertung von Klimadaten aus Modell und Beobachtung

eingesetzt in Projekten und Institutionen,
die sich mit Klimafolgen und Anpassung befassen



Titelbild: © Katharina G. Bülow

Zitierhinweis:

Hennemuth, B., Bender, S., Bülow, K., Dreier, N., Keup-Thiel, E., Krüger, O., Mudersbach, C., Radermacher, C., Schoetter, R. (2013):
Statistische Verfahren zur Auswertung von Klimadaten aus Modell und Beobachtung, eingesetzt in Projekten und Institutionen, die sich mit Klimafolgen
und Anpassung befassen, CSC Report 13, Climate Service Center, Germany

Statistische Verfahren zur Auswertung von Klimadaten aus Modell und Beobachtung

eingesetzt in Projekten und Institutionen, die sich mit Klimafolgen und Anpassung befassen

Gesammelt, sortiert und editiert durch
Arbeitsgruppe Statistik am Climate Service Center (Hamburg)

Barbara Hennemuth (Helmholtz-Zentrum Geesthacht, Climate Service Center, Hamburg)
Steffen Bender (Helmholtz-Zentrum Geesthacht, Climate Service Center, Hamburg)
Katharina Bülow (Bundesamt für Seeschifffahrt und Hydrographie, Hamburg)
Norman Dreier (Technische Universität Hamburg-Harburg, Institut für Wasserbau)
Elke Keup-Thiel (Helmholtz-Zentrum Geesthacht, Climate Service Center, Hamburg)
Oliver Krüger (Helmholtz-Zentrum Geesthacht, Institut für Küstenforschung)
Christoph Mudersbach (Universität Siegen, Forschungsinstitut Wasser und Umwelt)
Christine Radermacher (Max-Planck-Institut für Meteorologie, Hamburg)
Robert Schoetter (Meteorologisches Institut, Universität Hamburg)

Inhaltsverzeichnis

1	Einleitung	5
2	Ziel der Broschüre	5
3	Aufbau der Statistikbroschüre	6
4	Nutzung der Verfahren	7
4.1	Allgemeine Hinweise	7
4.2	Interpretation und Bewertung der Ergebnisse	7
4.3	Kombination von Verfahren	8
5.	Statistische Verfahren	9
5.1	Allgemeine statistische Verfahren	14
5.1.1	Korrelationskoeffizient nach Pearson	15
5.1.2	Korrelationskoeffizient nach Spearman	16
5.1.3	Korrelationskoeffizient nach Kendall	18
5.2	Häufigkeitsverteilungen	20
5.2.1	Eindimensionale Häufigkeitsverteilung	21
5.2.2	Relative Häufigkeitsverteilungen	24
5.2.3	Zweidimensionale Häufigkeitsverteilung	26
5.3	Zeitreihenanalyse	29
5.3.1	Gleitendes Mittel	30
5.3.2	Methode gleitender Mittelwerte	31
5.3.3	Gleitender Mittelwert	33
5.3.4	Gleitender Median	34
5.3.5	Numerische Filterung: Hoch-, Tief- und Bandpassfilterung	35
5.3.6	Lineare Regression	36
5.3.7	Vergleich verschiedener Zeitscheiben hinsichtlich ihrer Mittelwerte, Variabilität und/oder Verteilung	37
5.3.8	Variable Trendanalyse	38
5.3.9	Strukturorientierte Zeitreihenzerlegung, Maximum Likelihood Methode	42
5.3.10	Varianzanalyse (ANOVA)	43
5.4	Bias-Korrektur	44
5.4.1	Quantile-Mapping mit Transferfunktion	46
5.4.2	Modifiziertes Quantile-Mapping	48
5.5	Signifikanztests	49
5.5.1	Trend-Rauschverhältnis	50
5.5.2	Mann-Kendall-Test	52
5.5.3	Cox-Lewis Test	53
5.5.4	Kolmogoroff-Smirnoff Test	55
5.5.5	Bootstrap-Hypothesis Test	56
5.5.6	Parametrischer Test (z-Test)	57
5.6	Regionalisierung	60
5.6.1	Downscaling	61
5.6.1.1	Statistisches Downscaling mit linearen statistischen Modellen	61
5.6.1.2	Statistisches Downscaling von Niederschlägen	62
5.6.2	Interpolation	64
5.6.2.1	Bilineare Interpolation im Rastermodell	64
5.6.2.2	Inverse Distance Weighting	66
5.6.2.3	Lineare Regression mit Residueninterpolation mittels Inverse Distance Weighting	68
5.6.2.4	Splines	69
5.6.2.5	Kriging	70

5.6.2.6	Polygonmethode	73
5.7	Analyse von Extremwerten	75
5.7.1	Auswahlverfahren	76
5.7.1.1	Block Maxima	76
5.7.1.2	Peak over Threshold	78
5.7.1.3	Nichtstationäre Peaks over Threshold	80
5.7.2	Parameterschätzung	82
5.7.2.1	Anpassung von extremwertstatistischen Verteilungsfunktionen mittels Maximum-Likelihood- oder Momenten-Methode.....	82
5.7.2.2	R-largest in Kombination mit einer GEV	84
5.7.2.3	Abstandsmaß zwischen empirischer und theoretischer Extremwert- Verteilungsfunktion (Kolmogorow-Smirnow-Lilliefors-Test)	85
5.7.3	Empirische Methoden	88
5.7.3.1	Überschreitungswahrscheinlichkeit bzw. Wiederholungszeitspanne	88
5.7.3.2	Schwellenwertstatistik, Empirische Überschreitungswahrscheinlichkeiten	89
5.7.4	Extremwertanalyseverfahren	90
5.7.4.1	Extremwertanalyse mit Allgemeiner Extremwertverteilung (GEV)	90
5.7.4.2	Instationäre Extremwertanalyse mit Allgemeiner Extremwertverteilung ..	91
5.7.4.3	Nichtstationäre Extremwertanalyse auf Basis eines nichthomogenen Poisson-Punktprozesses.....	92
5.7.4.4	Statistische Analyse multivariater Datensätze mithilfe von Archimedischen Copula-Funktionen.....	94
5.7.4.5	Verallgemeinerte Pareto Verteilung (GPD).....	96
5.7.4.6	Extremwertanalyse mit Kovariate: Peaks-over-threshold modelliert mit nicht-stationärem Poisson-Punkt-Prozess	98
5.8	Kennzahlen	100
5.8.1	Modellevaluierungskennzahlen.....	101
5.8.1.1	Vergleich von Zeitreihen durch Berechnung der Nash-Sutcliffe Modell- Effizienz.....	101
5.8.1.2	Quantitative Evaluierung von Klimamodellrechnungen in einem Referenzzeitraum	102
5.8.1.3	Evalierungskennzahlen für mesoskalige meteorologische Modelle sowie mesoskalige Ausbreitungsmodelle.....	103
5.8.1.4	Evaluierung der Häufigkeitsverteilung durch skill-score und hit-rate of the percentiles.....	104
5.8.1.5	Vergleich von Zeitreihen hydrologischer Größen durch Percent Bias ..	105
5.8.1.6	Aikaikes Informationskriterium	106
5.8.1.7	Brier Skill Score.....	107
5.8.2	Statistische Klimakennzahlen	108
5.8.2.1	Transpirationsdifferenz als Maß für die Standorteignung	108
5.8.2.2	Häufigkeit von Frosttagen nach Vegetationsbeginn/ zeitlicher Abstand von Terminen des letzten Frosttages und des Vegetationsbeginns	109
5.8.2.3	Abzählmethode zur Bestimmung der thermischen Vegetationsperiode	110
5.9	Raum-Zeit-Verfahren	111
5.9.1	Korrelation zweier Variablen (Korrelationskarten).....	112
5.9.2	Temperatursummenmethode zur Projektion phänologischer Eintrittstermine 113	
5.9.3	Objektive Wetterlagenklassifikation mit statistischen Verfahren	115
5.9.4	Generalisierte additive Modelle	116
5.10	Ensembleanalyse.....	118

5.10.1	Perzentilanalyse.....	119
5.10.2	Wahrscheinlichkeit der Ergebnisse / likelihood of outcome	121
5.10.3	Robustheit eines Klimaänderungssignals	123
5.10.4	Darstellungen	125
Literatur	132
Danksagung	139

1 Einleitung

Der Klimawandel betrifft sehr unterschiedliche Sektoren wie beispielsweise Land- und Forstwirtschaft, Stadt- und Regionalplanung, Naturschutz, Wasserwirtschaft, Energiebereitstellung, Tourismus. Die Folgen des Klimawandels sind bereits vielerorts zu beobachten und sie werden in Zukunft noch deutlicher zu spüren sein (vgl. z.B. DAS, 2008, Chmielewski, et al. 2009, Henson, 2011, Jendritzky, 2007, Zebisch et al., 2005). Es besteht die Notwendigkeit, rechtzeitig Maßnahmen zur Anpassung an den Klimawandel zu erarbeiten und ihre Umsetzung durch Entscheidungsträger in Politik, Verwaltung, Wirtschaft und Gesellschaft anzustoßen.

Im Rahmen des IPCC-Prozesses, aber auch in nationalen und internationalen Projekten wurden für einen Zeitraum von mehr als 140 Jahren (z. B. 1961 bis 2100) globale und regionale Klimaprojektionen berechnet. Diese stehen nicht nur der Klimaforschung zur weiteren Analyse zur Verfügung, sondern auch der Klimafolgenforschung. Damit können erstmals auch Experten anderer Fachrichtungen Klimamodelldaten als Eingangsdaten für Wirkmodelle nutzen.

Die Datensätze für Klimasimulationen der Gegenwart (z.B. 1961 - 2000) und für Zukunftsprojektionen (2001 - 2100) sind sehr umfangreich. Eine zentrale Rolle für die Bearbeitung großer Datenmengen spielen statistische Methoden und Auswerteverfahren. Diese Verfahren können für verschiedene Fragestellungen etwa die Grundwasser- und Flussbewirtschaftung (Arbeitsgruppe KLIWA, 2011), Starkniederschläge (Aquaplan, 2010) oder ökonomische Folgen (Morgan et al., 2009) sehr unterschiedlich sein. Darüber hinaus können Qualitätsmerkmale von Ergebnissen nur durch statistische Analysen ermittelt werden z. B. durch Signifikanz- oder Robustheitstests. Eine weitere wichtige Rolle spielt auch die Analyse von Extremwerten, da hier die Auswirkungen auf Wirtschaft und Gesellschaft am größten und gleichzeitig die zugehörigen Analysen am schwierigsten sind (Field et al., 2012).

Im Dezember 2010 fand am Climate Service Center (CSC) gemeinsam mit dem Forschungsprogramm KLIMZUG (Klimawandel in Regionen zukunftsfähig gestalten, www.klimzug.de) ein Workshop zum Thema „Statistische Verfahren zur Auswertung von Klimamodell- und Impaktmodelldaten“ statt. Auf dem vom CSC initiierten Workshop wurde die große Vielfalt an Fragestellungen und genutzten Verfahren deutlich, die in der Klimaforschung und Impaktforschung zum Einsatz kommen. Übereinstimmend wurde dort festgestellt, dass die strukturierte, übersichtliche Zusammenstellung statistischer Verfahren sowohl für laufende Projekte als auch im Hinblick auf zukünftige Anpassungsprojekte sinnvoll und hilfreich wäre. Dieses Anliegen wird durch die Arbeitsgruppe Statistik am Climate Service Center in der vorliegenden Statistikbroschüre umgesetzt.

Es wurden Verfahren aufgenommen, die für Klimamodelldaten, Impaktmodelldaten oder Beobachtungsdaten anwendbar sind.

2 Ziel der Broschüre

Berechnungen mit regionalen Klimamodellen umfassen üblicherweise lange Zeiträume von meistens 140 Jahren und mehr. Die Simulationen des Klimas werden sowohl das heutige Klima als auch Projektionen in die Zukunft werden auf der Basis von Szenarien der Treibhausgasemissionen und Landnutzungsänderungen des International Panel on Climate Change (IPCC) berechnet. Die Vielfalt an Modellen, Szenarien und Realisierungen bildet sich in enormen Datenmengen ab, die in internationalen Datenbanken, wie bspw. dem World Data Center for Climate (WDCC) am Deutschen Klimarechenzentrum (DKRZ) in Hamburg archiviert werden. Große Datenmengen werden von Wissenschaftlern für verschiedenste Anwendungsbereiche und Fragestellungen verwendet. Hierzu wird ein umfangreiches Wissen zu globalen und regionalen Klimamodellen benötigt, wie auf der CSC-Website dokumentiert

http://www.climate-service-center.de/011606/index_0011606.html.de, Status: Juni 2013
oder in den „Leitlinien zur Interpretation regionaler Klimamodelldaten“ des Bund-Länder-Fachgesprächs beschrieben ist
<http://klimawandel.hlug.de/?id=448>, Status: Mai 2012.

Bei der Nutzung der Daten sowie der Interpretation und Analyse der Ergebnisse kommen sehr viele verschiedene statistische Methoden und Verfahren zum Einsatz. An dieser Stelle setzt die Intention der Statistikbroschüre an. In ihr werden die Erfahrungen der Wissenschaftler, die in aktuellen Projekten an verschiedensten Themen arbeiten dokumentiert. Die Statistikbroschüre bildet strukturiert ab, welche Methoden und Verfahren Wissenschaftler der Klimaforschung und der Impaktmodellierung nutzen. In den Steckbriefen zu den statistischen Verfahren wird nicht nur der Anwendungsbereich kurz erläutert. Das Verfahren wird auch bewertet und die Voraussetzungen für dessen Nutzung werden angegeben. Die Statistikbroschüre ist also ein Produkt von „Nutzern für Nutzer“ und damit als eine Ergänzung zu der statistischen Fachliteratur und wissenschaftlichen Veröffentlichungen zu sehen.

Die Broschüre wendet sich daher an verschiedene Nutzer von Klima- und Impaktmodelldaten sowie Beobachtungsdaten, die Hilfe bei der Suche nach geeigneten Verfahren für ihre Auswertungen benötigen. Die Broschüre versteht sich nicht als Fachbuch, das die Grundlagen der Statistik vermittelt. Sie ergänzt vielmehr die vorhandene Literatur (wie Storch und Zwiers, 1998, Schönwiese, 2006 und Mudelsee, 2010) und gibt Anregungen, wie bestimmte Fragestellungen bearbeitet werden können. Die beschriebenen Verfahren enthalten darüber hinaus Angaben über den Verfasser des jeweiligen Steckbriefs, so dass dort Rückfragen möglich sind. Sollte der Verfasser nicht erreichbar sein, können die Fragen auch direkt an das CSC gestellt werden (csc-anfragen@hzg.de).

3 Aufbau der Statistikbroschüre

Um den Anwenderbezug herzustellen wurde eine Statistikbroschüre „von Nutzern für Nutzer“ konzipiert. Dadurch können neben der eigentlichen Methodik auch Erfahrungen, die bei der Anwendung gesammelt wurden, weitergegeben werden. Daher spiegelt sie das Spektrum von Methoden wider, die aktuell von Anwendern in der Klimafolgenforschung und in Anpassungsprojekten benutzt werden. Statistische Verfahren mit unterschiedlichen Anwendungen werden mehrfach aufgeführt, um das Spektrum der Einsatzmöglichkeiten zu dokumentieren. Die Gliederung der Methoden steigt von einfach zu komplex an.

Die Struktur der Statistikbroschüre basiert auf den Erfahrungen der Arbeitsgruppe Statistik. Bei der Zusammenstellung der Steckbriefe wird die Arbeitsgruppe von Dr. Petra Friederichs (Universität Bonn) und Dr. Manfred Mudelsee (Climate Risk Analysis, Hannover) fachlich beraten. Es wurden folgende Kategorien festgelegt, die in Anpassungsprojekten eine wichtige Rolle spielen:

- Allgemeine statistische Verfahren
- Häufigkeitsverteilungen
- Zeitreihenanalyse
- Bias-Korrektur
- Signifikanztests

- Regionalisierung
 - Downscaling
 - Interpolation
- Analyse von Extremwerten
 - Auswahlverfahren
 - Parameterschätzung
 - Empirische Methoden

- Extremwertanalyseverfahren
- Kennzahlen
 - Modellevaluierungskennzahlen
 - Statistische Klimakennzahlen
- Raum-Zeit-Verfahren

Großer Wert wurde auf die Voraussetzungen zur Anwendbarkeit, die Bewertung des Verfahrens und auf Anwendungsbeispiele gelegt.

Die Einführungstexte zu den Kategorien (Kapitel 5) wurden von Manfred Mudelsee für die englische Version der Statistikbroschüre verfasst und übersetzt.

Die Sammlung wird fortlaufend in unregelmäßigen Abständen aktualisiert. Daher besteht für alle Leserinnen und Leser die Gelegenheit, noch nicht beschriebene Verfahren bzw. neue Anwendungsbeispiele bereits beschriebener Verfahren einzusenden. Bei Bedarf können auch neue Kategorien eingeführt werden.

4 Nutzung der Verfahren

4.1 Allgemeine Hinweise

Das vorgestellte Dokument ist als Hilfestellung zu sehen, um die Entscheidung zu erleichtern, welches statistische Verfahren für welche Fragestellung eingesetzt werden kann, welche Voraussetzungen erfüllt sein müssen und wie es zu bewerten ist. Die in den Steckbriefen enthaltenen Literaturzitate sind im Literaturverzeichnis am Ende enthalten. Die Zusammenstellung der Verfahren erhebt keinen Anspruch auf Vollständigkeit. Die Broschüre lebt von den eingesandten Steckbriefen durch Nutzer.

Bei der Nutzung der hier beschriebenen statistischen Verfahren ist jeweils zu prüfen, ob die Voraussetzungen für die spezielle Anwendung erfüllt sind. Teilweise werden Verfahren auch dann angewendet, wenn Voraussetzungen verletzt sind. Das kann im Einzelfall vertretbar sein, wenn die Methode Ergebnisse liefert, die nur wenig von Ergebnissen abweichen, die ohne Verletzung der Voraussetzungen erzielt werden. Solche Verfahren werden als robust bezeichnet.

In der Broschüre sind jeweils Einzelverfahren beschrieben. Für bestimmte Fragestellungen müssen häufig mehrere Einzelverfahren hintereinander angewendet werden (siehe Abschnitt 4.3).

4.2 Interpretation und Bewertung der Ergebnisse

Großer Wert bei der Abfrage nach statistischen Verfahren wurde auf die Bewertung gelegt. Das soll den Nutzern bei der Qualitätsbestimmung ihrer Ergebnisse helfen.

Über die Bewertung der Methodik hinaus müssen aber noch weitere Gesichtspunkte beachtet werden, die bei der Auswertung und Analyse großer Datenmengen eine Rolle spielen. Dies betrifft bspw. die Empfehlung bei der Auswertung von Klimamodelldaten ein Modellensemble zu nutzen. Die so ausgewerteten Ergebnisse zeigen eine Bandbreite, die bewertet werden muss (siehe Abschnitt 5.10 Ensembleanalyse). Ferner wird empfohlen, wenn möglich auch mehrere Impactmodelle und Auswerteverfahren (,Methodenvielfalt') zu nutzen. Hinweise zur Interpretation der Ergebnisse finden sich auch unter <http://klimawandel.hlug.de/?id=448> und in Kreienkamp et al. (2012).

4.3 Kombination von Verfahren

In der Praxis wird die Anwendung eines Einzelverfahrens eher die Ausnahme darstellen. In der Regel wird eine Fragestellung mithilfe mehrerer statistischer Methoden analysiert. Ziel der Broschüre ist es nicht eine rezeptbuchartige Anleitung zur Kombination von statistischen Methoden bei komplexen Fragestellungen zu geben. Grundsätzlich gilt: Komplexe Fragestellungen benötigen statistischen Sachverstand!

Im Folgenden sollen einige mögliche und häufig genutzte Kombinationen von statistischen Methoden vorgestellt werden, um dem Nutzer einen Einstieg in die Thematik zu erleichtern.

Beispiel 1:

In der Praxis wird häufiger die Frage nach der Überschreitungswahrscheinlichkeit bzw. der mittleren Wiederkehrdauer bestimmter Extremereignisse gestellt. Diese Aufgabe kann über eine extremwertstatistische Analyse beispielsweise mittels der Allgemeinen Extremwertverteilung (Steckbrief Nr. 5.7.4.2) einer Zeitreihe erfolgen. Eine solche Analyse ist jedoch an Voraussetzungen geknüpft, die vorab geprüft werden müssen. Die wichtigsten Voraussetzungen sind hierfür die Stationarität, Homogenität und Unabhängigkeit (diese wird i.d.R. durch die geeignete Wahl des Extremwertkollektivs erreicht) der zu analysierenden Ereignisse. Daraus ergibt sich beispielsweise folgende Kombination von statistischen Methoden:

1. Berechnung des linearen Trends der Zeitreihe (z.B. Abschnitt 5.3.6) zur Prüfung der Stationarität
2. Überprüfung der Signifikanz des linearen Trends (z.B. Abschnitt 5.5.1)
3. Ggf. Korrektur der Zeitreihe bei signifikanten Trends oder Sprüngen
4. Anwendung der Allgemeinen Extremwertfunktion auf die (korrigierte) Zeitreihe (Abschnitt 5.7.4.2)

Beispiel 2:

Eine weitere Fragestellung ist die Ermittlung des Klimaänderungssignals entweder in den Klimamodell- oder Impaktmodelldaten anhand von Änderungen der Häufigkeitsverteilung eines Modellparameters und das Testen der Änderungen auf Signifikanz. Eine mögliche Kombination von statistischen Methoden wäre:

1. Ermittlung der relativen Häufigkeitsverteilung eines Klimamodell- bzw. Impaktmodellparameters für einen Zeitabschnitt der Gegenwart bzw. Zukunft (Abschnitt 5.2.2)
2. Berechnung der relativen Veränderung der Häufigkeiten der Zukunft bezogen auf die Gegenwart
3. Test auf Signifikanz des Unterschieds zwischen den relativen Häufigkeiten (z-Test) (Abschnitt 5.5.6)

Beispiel 3:

Im Rahmen von Zeitreihenanalysen sind vielfach die kurz- oder langfristigen Schwankungen zu untersuchen. Dies kann beispielsweise über Tief-, Hoch- oder Bandpassfilter geschehen. Für die Anwendung solcher Verfahren müssen lückenlose äquidistante Zeitreihen vorliegen. Mitunter weisen Zeitreihen jedoch Lücken auf und/oder die Messwerte sind nicht-äquidistant. Somit bietet sich folgende Vorgehensweise an:

1. Zeitliche Interpolation der vorhandenen Messwerte zur Lückenschließung und Generierung äquidistanter Zeitreihen mittels Splines (Abschnitt 5.6.2.4)
2. Anwendung diverser Tief-, Hoch- oder Bandpassfilter (Abschnitt 5.3.5)

Beispiel 4:

Im Rahmen der Extremwertanalyse, stellt sich oftmals die Frage, welche der Extremwert-Verteilungsfunktionen die Daten einer Stichprobe am besten beschreibt. In der Literatur sind Verfahren zur Beantwortung dieser Fragestellung unter dem Begriff „Goodness of fit“-Tests bzw. Tests zur Beurteilung der Anpassungsgüte bekannt. Es existieren mehrere Möglichkeiten die Anpassungsgüte zu beurteilen. Hier vorgestellt wird die Beurteilung anhand von Abstandsmaßen zwischen empirischer und theoretischer Extremwertverteilungsfunktion, welche z.B. durch folgende Schritte ermittelt werden können:

1. Auswahl der Stichprobe (Abschnitt 5.7.1)
2. Anpassung von Extremwert-Verteilungsfunktionen (z.B. GEV/GPD, Gumbel-, Weibull, Log-Normal-Verteilung etc.) an die Stichprobe (Abschnitt 5.7.2)
3. Berechnung von Abstandsmaßen zwischen empirischer und theoretischer Verteilungsfunktion (Abschnitt 5.7.2.3)

Eine Kombination von statistischen Verfahren zur Analyse von projizierten Extremwerten findet sich bspw. in einem Bericht des Deutschen Wetterdienstes (Deutschländer u. Dalelane, 2012).

5 Statistische Verfahren

Zusammenfassung. Das Klima ist ein Paradebeispiel für ein komplexes System, in dem zahlreiche Variable auf verschiedensten Raum-Zeit-Skalen miteinander interagieren. Basierend auf fundamentalen physikalischen Gesetzen können numerische Modelle das Klima und seine Folgen simulieren. Mithilfe statistischer Verfahren werden aus Modellergebnissen und Messdaten Rückschlüsse auf die Eigenschaften des Klimasystems geschlossen. Dabei sind gewisse Unsicherheiten unvermeidlich. Diese sind (1) die natürliche Variabilität des Klimas, (2) die Unvollkommenheit von Klima- und Impaktmodellen geschuldet durch Grenzen unseres Verständnisses und der Rechenleistung (trotz der Tatsache, dass Klimamodelle höchst entwickelte Rechenverfahren verwenden), (3) die räumliche und zeitliche Unvollständigkeit von Messdaten, die zur Kalibrierung von Modellen benötigt werden. Statistische Rückschlüsse sollten daher nicht nur auf dem Schätzwert selbst basieren, sondern auch dessen Unsicherheit berücksichtigen.

Die in den folgenden Abschnitten präsentierten statistischen Methoden wurden von Klima- und Umweltwissenschaftlern zur Untersuchung der Eigenschaften des Klimasystems verwendet und als besonders nützlich für diesen Forschungszweig erachtet. Allgemeine statistische Methoden (Abschnitt 5.1) behandelt generelle Konzepte. Häufigkeitsverteilungen (Abschnitt 5.2) behandelt Wahrscheinlichkeiten und Methoden, die auf die Verteilung einer Variablen schließen lassen. Extremwertanalyse (Abschnitt 5.7) stellt Methoden zur Extrahierung von Extremen in den Daten vor. Bias-Korrekturr (Abschnitt 5.4) und Regionalisierung (Abschnitt 5.6) sind Methoden, die insbesondere zur Verbesserung der Analyse von Modellergebnissen genutzt werden. Im Abschnitt Kennzahlen (Abschnitt 5.8) werden Indices zur qualitativen Bewertung von Simulationen beschrieben, sowie klimatische Kennzahlen, die auf elegante, moderne Weise hoch-dimensionale Klimamodellergebnisse in einer einzigen Zahl darstellen. Fortgeschrittene Methoden der statistischen Analyse finden sich in Raum-Zeit-Methoden (Abschnitt 5.9), Hypothesentests (Abschnitt 5.5) und Zeitreihenanalyse (Abschnitt 5.3). Der Abschnitt Ensembleanalyse (Abschnitt 5.10) behandelt den Umgang mit der großen Vielfalt an Klimamodellen, Treibhausgasemissions- sowie Landnutzungsszenarien und Realisierungen des simulierten Klimas.

Literatur. Bücher, die einen Großteil der Methoden behandeln und von/für Geowissenschaftler verfasst wurden sind der Klassiker *Statistical Analysis in Climate Research* (von Storch and Zwiers 1999) sowie *Climate Time Series Analysis* (Mudelsee 2010). Eine allgemein verfügbare und dennoch ausführliche Einführung in statistische Schlussfolgerungen ist die des Statistikers Wasserman (2004).

Mudelsee M (2010) Climate Time Series Analysis: Classical Statistical and Bootstrap Methods. Springer, Dordrecht, 474 pp.

von Storch H, Zwiers FW (1999) Statistical Analysis in Climate Research. Cambridge University Press, Cambridge, 484 pp.

Wasserman L (2004) All of Statistics: A Concise Course in Statistical Inference. Springer, New York, 442 pp.

Die Steckbriefe wurden verfasst von:

Arne Arns
Universität Siegen, Forschungsinstitut Wasser und Umwelt
arne.arns@uni-siegen.de

Jens Bender
Universität Siegen, Forschungsinstitut Wasser und Umwelt (fwu) und Forschungskolleg Siegen (FoKoS)
jens.bender@uni-siegen.de

Steffen Bender
Helmholtz-Zentrum Geesthacht, Climate Service Center
steffen.bender@hzg.de

Katharina Bülow
Bundesamt für Seeschifffahrt und Hydrographie, Hamburg
katharina.buelow@bsh.de
KLIWAS

Norman Dreier
Technische Universität Hamburg-Harburg, Institut für Wasserbau
norman.dreier@tuhh.de
KLIMZUG-Projekt RAdOst

Thomas Einfalt
hydro & meteo GmbH&Co.KG, Lübeck
thomas.einfalt@hydrometeo.de

Wolfgang Falk
Bayerisches Landesamt für Wald und Forstwirtschaft, Freising
Wolfgang.Falk@lwf.bayern.de

Maria Foltyn (ehemals LfULG)
Technische Universität Bergakademie Freiberg
foltyn@mailserver.tu-freiberg.de
KLIMZUG-Projekt REGKLAM

Johannes Franke
Technische Universität Dresden
johannes.franke@tu-dresden.de
KLIMZUG-Projekt: REGKLAM

Ulf Gräwe
Leibniz Institute for Baltic Sea Research Warnemuende
ulf.graewe@io-warnemuende.de
KLIMZUG-Projekt RAdOst

Stephanie Hänsel
Technische Universität Bergakademie Freiberg
stephanie.haensel@ioez.tu-freiberg.de
KLIMZUG-Projekt REGKLAM

Majana Heidenreich
Technische Universität Dresden
majana.heidenreich@tu-dresden.de
KLIMZUG-Projekt: REGKLAM

Sandra Hellmers
Technische Universität Hamburg-Harburg
Institut für Wasserbau
s.hellmers@tuhh.de
KLIMZUG NORD

Nils Hempelmann
Helmholtz-Zentrum Geesthacht, Climate Service Center
nils.hempelmann@hzg.de

Barbara Hennemuth
Helmholtz-Zentrum Geesthacht, Climate Service Center
barbara.hennemuth@hzg.de

Frank Herrmann
Forschungszentrum Jülich GmbH
Institut für Bio- und Geowissenschaften
f.herrmann@fz-juelich.de
KLIMZUG Nord

Peter Hoffmann
Universität Hamburg, Meteorologisches Institut
peter.hoffmann@zmaw.de
KLIMZUG NORD

Andreas Hoy
Technische Universität, Bergakademie Freiberg
andreas.hoy@ioez.tu-freiberg.de
KLIMZUG-Projekt: REGKLAM

Nina Hüffmeyer
Hamburger Stadtentwässerung AöR
nina.hueffmeyer@hamburgwasser.de
KLIMZUG NORD

Alrun Jasper-Tönnies
hydro & meteo GmbH&Co.KG, Lübeck
alrun.jasper-toennies@hydrometeo.de

Andreas Kochanowski
Andreas_kochanowski@gmx.de

Oliver Krüger
Helmholtz-Zentrum Geesthacht
Institut für Küstenforschung
Oliver.krueger@hzg.de

Daniel Leistner
Technische Universität Bergakademie Freiberg
Daniel.Leistner@ioez.tu-freiberg.de
KLIMZUG-Projekt REGKLAM

Christopher Moseley
MPI für Meteorologie
Christopher.moseley@zmaw.de
KLIMZUG NORD; KLIFF

Manfred Mudelsee
Climate Risk Analysis, Hannover
Alfred Wegener Institut für Polar- und Meeresforschung, Bremerhaven
mudelsee@climate-risk-analysis.com

Christoph Mudersbach
Forschungsinstitut Wasser und Umwelt
christoph.mudersbach@uni-siegen.de

Hannaleena Pöhler
UDATA Umweltschutz und Datenanalyse
Hydrologie, Klimafolgenforschung, Boden- und Grundwasserschutz
pohler@udata.de
KLIMZUG NORD

Susanne Pfeiffer
Helmholtz-Zentrum Geesthacht, Climate Service Center
susanne.pfeiffer@hzg.de

Markus Quirnbach
dr. papadakis GmbH, Hattingen
M.Quirnbach@drpapadakis.de
KLIMZUG-Projekt DYNAKLIM, ExUS

Christine Radermacher
MPI für Meteorologie, Hamburg
Christine.radermacher@zmaw.de

Diana Rechid
MPI für Meteorologie, Meteorologie
diana.rechid@zmaw.de
KLIMZUG NORD

Dörte Salecker
Institut für Wasserbau, Technische Universität Hamburg-Harburg
doerte.salecker@tuhh.de

Christian Schlamkow
Universität Rostock, Fachgebiet Küstenwasserbau, Rostock
christian.schlamkow@uni-rostock.de
KLIMZUG RAdOst

Robert Schoetter
Meteorologisches Institut, Universität Hamburg
robert.schoetter@zmaw.de
KLIMZUG NORD

Thomas Wahl
Universität Siegen, Forschungsinstitut Wasser und Umwelt (fwu)
und Forschungskolleg Siegen (FoKoS)
thomas.wahl@uni-siegen.de

Zhen-shan Xu,
College of Harbor, Coastal and Offshore Engineering,
Hohai University, Nanjing, P.R. China
xuzhenshanhhu@gmail.com

5.1 Allgemeine statistische Verfahren

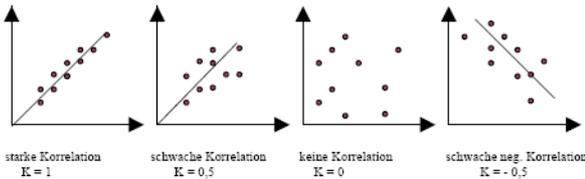
Ein fundamentales Konzept für die Analyse bivariater Datensätze (zwei Variablen) ist die Korrelationsanalyse. Diese beschreibt quantitativ, wie stark zwei Variablen miteinander kovariieren. Die dargestellten Korrelationsmethoden variieren in dem Grad ihrer Robustheit, vom wenig robusten Pearson-Korrelationskoeffizient (Abschnitt 5.1.1) zu den robusteren Verfahren nach Spearman (Abschnitt 5.1.2) und Kendall (Abschnitt 5.1.3). Es ist zu beachten, dass eine erhöhte Robustheit oft mit verminderter Genauigkeit einhergeht (die sich z.B. in längeren Fehlerbalken bemerkbar macht). In den Klimawissenschaften ist es aber häufig ratsam, die Robustheit zu favorisieren.

Literatur. Das Konzept der Robustheit wurde von Box (1953) eingeführt. Eine Erläuterung robuster Korrelationsmethoden findet sich in Kendall and Gibbons (1990).

Box GEP (1953) Non-normality and tests on variances. *Biometrika* 40:318–335.

Kendall M, Gibbons JD (1990) *Rank Correlation Methods*. 5th edn., Edward Arnold, London, 260 pp.

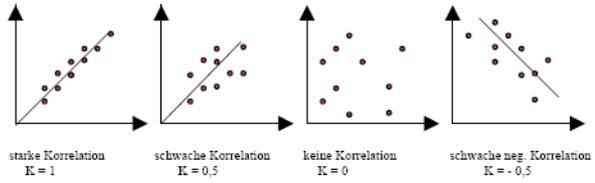
5.1.1 Korrelationskoeffizient nach Pearson

Übergeordnetes Ziel (Kategorie)	Allgemeine statistische Verfahren
Verfahren	Korrelationskoeffizient nach Pearson / Produkt-Moment-Korrelation
Beschreibung + Literatur	<p>Dimensionsloses Maß für den Grad des linearen Zusammenhangs zweier Variablen / Merkmale</p> $r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$ <p>\bar{x} = arithmetische Mittel von Merkmal x \bar{y} = arithmetische Mittel von Merkmal y</p> <p>C.D Schönwiese (2006): Praktische Statistik für Meteorologen und Geowissenschaftler, S.163 ff.</p>
Geeignet für (Parameter, zeitl. Auflösung)	alle Parameter die in einem potentiellen Zusammenhang stehen
Voraussetzungen für Anwendung	Setzt linearen Zusammenhang, mindestens intervallskalierte und (annähernd) normalverteilte Variable voraus, Datenunabhängigkeit → keine Autokorrelation, „Stichprobe ≥ 30“, zweidimensionaler Zusammenhang, bei dem keine andere(n) Variable(n) Einfluss auf den Zusammenhang haben
Ergebnis / Interpretation	<p>Wertebereich zwischen -1 und +1 +1 = vollständig positiver linearer Zusammenhang 0 = kein Zusammenhang -1 = vollständig negativer linearer Zusammenhang</p> <p>Repräsentativ nur für Stichprobe, nicht für Grundgesamtheit, je größer der Stichprobenumfang, umso aussagekräftiger das Ergebnis Statistischer Zusammenhang bedeutet nicht automatisch kausalen Zusammenhang. z.B. Geburtenraten und Storchpopulation (Scheinkorrelation)</p>
Bewertung	Standardkorrelationskoeffizient, anfällig gegenüber Ausreißern
Beispiel	 <p>© BGW Software: Excel, R-Statistics</p>
Kontakt / Projekt	Andreas Kochanowski Andreas_kochanowski@gmx.de

5.1.2 Korrelationskoeffizient nach Spearman

Übergeordnetes Ziel (Kategorie)	Allgemeine statistische Verfahren
Verfahren	Korrelationskoeffizient nach Spearman Rangkorrelationskoeffizient
Beschreibung + Literatur	<p>parameterfreies Maß für den Zusammenhang zweier Variablen / Merkmale, verteilungsfreies Verfahren, Daten werden in aufsteigende Rangfolge gebracht, Originalwerte werden durch Ränge „ersetzt“ und miteinander korreliert</p> $\rho = 1 - \frac{6 \cdot \sum_{i=1}^n (r_i - s_i)^2}{n^3 - n}$ <p> r_i = Rangplatz innerhalb Variable X des i. Merkmalsträgers s_i = Rangplatz innerhalb Variable Y des i. Merkmalsträgers n = Anzahl der Merkmalsträger </p> <p>C.D Schönwiese (2006): Praktische Statistik für Meteorologen und Geowissenschaftler, S.163 ff.</p>
Geeignet für (Parameter, zeitl. Auflösung)	alle Parameter, die in einem potentiellen Zusammenhang stehen
Voraussetzungen für Anwendung	mindestens ordinalskalierte Daten (gleiche Abstände / Teilung der Skalen), Datenunabhängigkeit → keine Autokorrelation, „Stichprobe ≥ 30“, zweidimensionaler Zusammenhang, bei dem keine andere(n) Variable(n) Einfluss auf den Zusammenhang haben
Ergebnis / Interpretation	<p>Wertebereich zwischen -1 und +1 +1 = vollständig positiver Zusammenhang 0 = kein Zusammenhang -1 = vollständig negativer Zusammenhang</p> <p>Repräsentativ nur für Stichprobe, nicht für Grundgesamtheit je größer der Stichprobenumfang, umso aussagekräftiger das Ergebnis, Statistischer Zusammenhang bedeutet nicht automatisch kausalen Zusammenhang, z.B. Geburtenraten und Storchpopulation (Scheinkorrelation)</p>
Bewertung	robust gegenüber Ausreißern, setzt keine Normalverteilung und Linearität der Daten voraus → auch bei logarithmischem, exponentiellem etc. Zusammenhang geeignet

Beispiel



© BGW

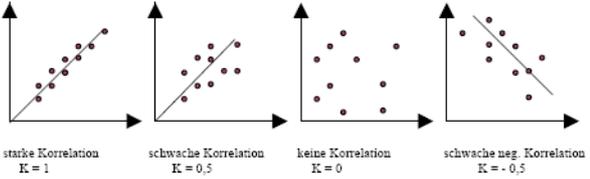
Software: R-Statistics

Kontakt / Projekt

Andreas Kochanowski
Andreas_kochanowski@gmx.de

5.1.3 Korrelationskoeffizient nach Kendall

Übergeordnetes Ziel (Kategorie)	Allgemeine statistische Verfahren
Verfahren	Korrelationskoeffizient nach Kendall / Rangkorrelationskoeffizient
Beschreibung + Literatur	<p>parameterfreies Maß für den Zusammenhang zweier Variablen / Merkmale verteilungsfreies Verfahren, Daten werden in aufsteigender Rangfolge gebracht, Originalwerte werden durch Ränge „ersetzt“ und miteinander korreliert setzt im Gegensatz zu Spearman nicht den gleichen Abstand zwischen benachbarten Rängen voraus Berechnung:</p> $\tau = \frac{C - D}{n(n - 1)^2}$ <p><i>D</i> – Anzahl der diskordanten Datenpaare <i>C</i> – Anzahl der konkordanten Datenpaare <i>n</i> – Anzahl der Daten</p> <p>Ein Datenpaar ist konkordant, wenn der Rang in beiden Datensätzen (X und Y) abfällt oder in beiden Datensätzen ansteigt (z.B. Rang von $x_1 >$ als Rang x_4 und Rang von $y_1 >$ als Rang y_4) Wenn dies nicht der Fall ist so ein Datenpaar diskordant (z.B. Rang von $x_1 >$ als Rang x_4 und Rang von $y_1 <$ als Rang y_4)</p> <p>D.S. Wilks (2006): Statistical methods in atmospheric sciences, S. 55-57 C.D Schönwiese (2006): Praktische Statistik für Meteorologen und Geowissenschaftler, S. 163 ff.</p>
Geeignet für (Parameter, zeitl. Auflösung)	alle Parameterpaare, die in einem monoton steigenden / fallenden Zusammenhang stehen, kleiner Stichprobenumfang möglich
Voraussetzungen für Anwendung	rein ordinalskalierte Daten (keine Gleichabständigkeit der Skalenwerte / Ränge vorausgesetzt), Datenunabhängigkeit → keine Autokorrelation, zweidimensionaler Zusammenhang, bei dem keine andere(n) Variable(n) Einfluss auf den Zusammenhang haben
Ergebnis / Interpretation	<p>Wertebereich zwischen -1 und +1 +1 = vollständig positiver Zusammenhang 0 = kein Zusammenhang -1 = vollständig negativer Zusammenhang</p> <p>Werte nach Kendall in der Regel etwas kleiner als Werte nach Spearman, Repräsentativ nur für Stichprobe, nicht für Grundgesamtheit, Statistischer Zusammenhang bedeutet nicht automatisch kausalen Zusammenhang. z.B. Geburtenraten und Storchpopulation (Scheinkorrelation)</p>

Bewertung	geeignet für kleine Stichproben und wenn Skalen ungleiche Teilung aufweisen, robust gegenüber Ausreißern, setzt keine Normalverteilung und Linearität der Daten voraus → auch bei logarithmischem, exponentiellem etc. Zusammenhang geeignet
Beispiel	 <p>starke Korrelation K = 1</p> <p>schwache Korrelation K = 0,5</p> <p>keine Korrelation K = 0</p> <p>schwache neg. Korrelation K = - 0,5</p> <p>© BGW Software: R-Statistics</p>
Kontakt / Projekt	Andreas Kochanowski Andreas_kochanowski@gmx.de

5.2 Häufigkeitsverteilungen

Es ist ein fundamentales Konzept, dass die unsicheren oder zufälligen Komponenten des Klimas (Klimavariabilität) als Verteilungen der Werte, die eine Klimavariablen annehmen kann beschrieben werden. In der statistischen Sprache (Wasserman 2004) bestimmt die Wahrscheinlichkeitsdichtefunktion (PDF) einer Variablen X mit kontinuierlichem Wertebereich die Wahrscheinlichkeit, X zwischen einem Wert x und $x+dx$ zu finden, wobei dx gegen 0 geht. Diese Wahrscheinlichkeit ist durch das Integral der PDF über dem Intervall $[x; x+dx]$ bestimmt. Bei den vorgestellten statistischen Methoden (Abschnitte 5.2.1, 5.2.2 und 5.2.3) wird die PDF aus Histogrammen abgeleitet.

Bei vielen statistischen Methoden werden Annahmen zur PDF der Zufallskomponente getroffen, so wie beispielsweise die Voraussetzung einer Normal- oder Gaußverteilung (Glockenkurve). In der Praxis sind die Voraussetzungen oft aber nicht erfüllt. Eine statistische Methode wird *robust* genannt, wenn sie selbst bei Verletzung der Voraussetzungen Ergebnisse von akzeptabler Genauigkeit liefert.

Was „akzeptabel“ in diesem Zusammenhang bedeutet, sollte von der jeweiligen Forschungsgemeinschaft definiert werden. So könnte beispielsweise eine wahre Abdeckung von 91% bei einem Konfidenzintervall von 95% aufgrund der Verletzung der Annahmen noch als akzeptabel angesehen werden, eine wahre Abdeckung von 78% aber nicht mehr.

Literatur. Ein kurzes, relevantes Paper zur Auswahl der Klassenweite im Histogramm wurde von Scott (1979) verfasst.

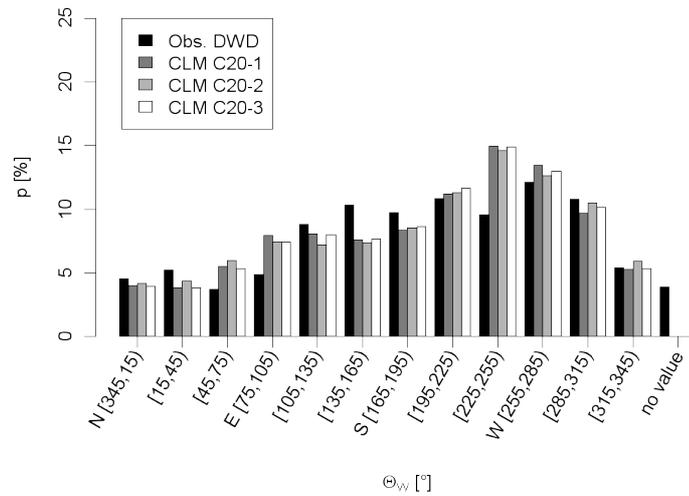
Scott DW (1979) On optimal and data-based histograms. *Biometrika* 66:605–610.

5.2.1 Eindimensionale Häufigkeitsverteilung

Übergeordnetes Ziel (Kategorie)	Häufigkeitsverteilungen
Verfahren	Eindimensionale Häufigkeitsverteilung
Beschreibung + Literatur	<p>(1) Ordnen der Daten der Stichprobe nach der Größe (2) Einteilung in Gruppen (sog. Klassen) mit konstanter oder variabler Breite und einer unteren (linken) und oberen (rechten) Klassengrenze (3) Auszählen wie häufig die Daten in den jeweiligen Klassen vorkommen (4) Darstellung der absoluten/prozentualen Anzahl z.B. in Form einer Häufigkeitstabelle oder grafisch durch z.B. Rechtecke in einem Histogramm (siehe Beispiel).</p> <p>Besonderes Augenmerk ist auf die Klassierung/Klasseneinteilung zu legen, da sich diese unmittelbar auf die Darstellung des Histogramms auswirkt und bei ungeeigneter Durchführung zu Fehlinterpretationen führt. Hierbei ist insbesondere auf die:</p> <p>a) Wahl der Klassenbreite b) Wahl der linken Klassengrenzen zu achten, da diese das Histogramm erheblich beeinflussen können.</p> <p>Es existieren verschiedene Faustregeln zur Wahl der Klassenbreite, in Abhängigkeit von der zu Grunde liegenden Verteilungsfunktion, z.B. für normal-verteilte Daten kann z.B. die Regel nach Scott angewendet werden:</p> $h = 3,49 \sigma / \sqrt[3]{n}$ <p>mit h: Klassenbreite σ: Standardabweichung der Daten n: Anzahl der Elemente der Stichprobe</p> <p>Für andere Verteilungen gibt Scott Korrekturfaktoren zur Berücksichtigung von Schiefe (skewness) und Wölbung (kurtosis) an:</p> <p><i>Scott, D. W. On optimal and data-based histogram. In: Biometrika (1979) 66 (3): 605-610. doi: 10.1093/biomet/66.3.605</i></p> <p>Zur Lösung des Problems der Wahl der linken Klassengrenzen, schlägt Scott z.B. das Average-Shifted-Histogramm vor:</p> <p><i>Scott, D. W. Multivariate Density Estimation: Theory, Practice, and Visualization. John Wiley, 1992. ISBN 978-0471547709.</i></p> <p>weitere Literatur (Auszug): <i>Sachs, L. Angewandte Statistik: Anwendung statistischer Methoden, 6. Aufl., Springer-Verlag Berlin, Heidelberg, New York, Tokio, 1984, ISBN 3-540-12800-X, S. 46-48.</i></p>

	<p>Von der Lippe, P. <i>Deskriptive Statistik</i>. Gustav Fischer Verlag, Stuttgart, Jena, 1993, ISBN 3-437-40268-4 http://www.von-der-lippe.org/dokumente/buch/buch03.pdf</p> <p>Plate E.-J.: <i>Statistik und angewandte Wahrscheinlichkeitslehre für Bauingenieure</i>, Ernst & Sohn Verlag für Architektur und technische Wissenschaften, Berlin, 1993, ISBN 3-433-01073-0, S.20-22.</p>																																																																																					
Geeignet für (Parameter, zeitl. Auflösung)	beliebige Variablen, z.B. Seegangdaten (Wellenhöhen) oder meteorologische Daten (Windgeschwindigkeiten)																																																																																					
Voraussetzungen für Anwendung	metrische Daten, welche sich der Größe nach ordnen lassen																																																																																					
Ergebnis / Interpretation	Die tabellarische Häufigkeitsverteilung bzw. das Histogramm gibt z.B. Aufschluss über die absolute oder prozentuale Anzahl einer Variablen (z.B. Wellenhöhe) in einer definierten Klasse.																																																																																					
Bewertung	Einfaches und sehr anschauliches Verfahren der deskriptiven Statistik für z.B. die Zeitreihenanalyse von Klimadaten. Werden Zeitreihen aus Beobachtungsdaten analysiert ist darauf zu achten, eine zusätzliche Klasse für Messfehler vorzusehen, damit die Summe der Häufigkeiten genau 1 bzw. 100% ergibt. Ferner ermöglicht das Verfahren Häufigkeiten aus unterschiedlichen Grundgesamtheiten zu vergleichen (z.B. Beobachtungs- und Simulationsdaten, siehe Bsp.) oder Klimaänderungssignale aus Simulationsdaten zu ermitteln (siehe Abschnitt 4.3 Kombination von Verfahren, Beispiel 2).																																																																																					
Beispiel	<p>Vergleich der relativen Häufigkeiten p [%] (dargestellt auf der Ordinate) von gemessenen (DWD) und simulierten (Cosmo-CLM) Windgeschwindigkeiten mit einer Klassenbreite von 2m/s (Abb. a) und Windrichtungen mit einer Klassenbreite von 30° (Abb. b) an der Küste von Warnemünde im Zeitraum 1971-2000.</p> <p>a)</p> <table border="1"> <caption>Estimated data for Figure a)</caption> <thead> <tr> <th>U [m/s] Class</th> <th>Obs. DWD [%]</th> <th>CLM C20-1 [%]</th> <th>CLM C20-2 [%]</th> <th>CLM C20-3 [%]</th> </tr> </thead> <tbody> <tr><td>[0,2)</td><td>11</td><td>8</td><td>7</td><td>7</td></tr> <tr><td>[2,4)</td><td>31</td><td>26</td><td>25</td><td>24</td></tr> <tr><td>[4,6)</td><td>26</td><td>28</td><td>28</td><td>28</td></tr> <tr><td>[6,8)</td><td>15</td><td>21</td><td>20</td><td>22</td></tr> <tr><td>[8,10)</td><td>8</td><td>11</td><td>11</td><td>11</td></tr> <tr><td>[10,12)</td><td>5</td><td>5</td><td>5</td><td>5</td></tr> <tr><td>[12,14)</td><td>3</td><td>2</td><td>2</td><td>2</td></tr> <tr><td>[14,16)</td><td>2</td><td>1</td><td>1</td><td>1</td></tr> <tr><td>[16,18)</td><td>1</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>[18,20)</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>[20,22)</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>[22,24)</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>[24,26)</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>[26,28)</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>[28,30)</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>no value</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> </tbody> </table>	U [m/s] Class	Obs. DWD [%]	CLM C20-1 [%]	CLM C20-2 [%]	CLM C20-3 [%]	[0,2)	11	8	7	7	[2,4)	31	26	25	24	[4,6)	26	28	28	28	[6,8)	15	21	20	22	[8,10)	8	11	11	11	[10,12)	5	5	5	5	[12,14)	3	2	2	2	[14,16)	2	1	1	1	[16,18)	1	0	0	0	[18,20)	0	0	0	0	[20,22)	0	0	0	0	[22,24)	0	0	0	0	[24,26)	0	0	0	0	[26,28)	0	0	0	0	[28,30)	0	0	0	0	no value	0	0	0	0
U [m/s] Class	Obs. DWD [%]	CLM C20-1 [%]	CLM C20-2 [%]	CLM C20-3 [%]																																																																																		
[0,2)	11	8	7	7																																																																																		
[2,4)	31	26	25	24																																																																																		
[4,6)	26	28	28	28																																																																																		
[6,8)	15	21	20	22																																																																																		
[8,10)	8	11	11	11																																																																																		
[10,12)	5	5	5	5																																																																																		
[12,14)	3	2	2	2																																																																																		
[14,16)	2	1	1	1																																																																																		
[16,18)	1	0	0	0																																																																																		
[18,20)	0	0	0	0																																																																																		
[20,22)	0	0	0	0																																																																																		
[22,24)	0	0	0	0																																																																																		
[24,26)	0	0	0	0																																																																																		
[26,28)	0	0	0	0																																																																																		
[28,30)	0	0	0	0																																																																																		
no value	0	0	0	0																																																																																		

b)



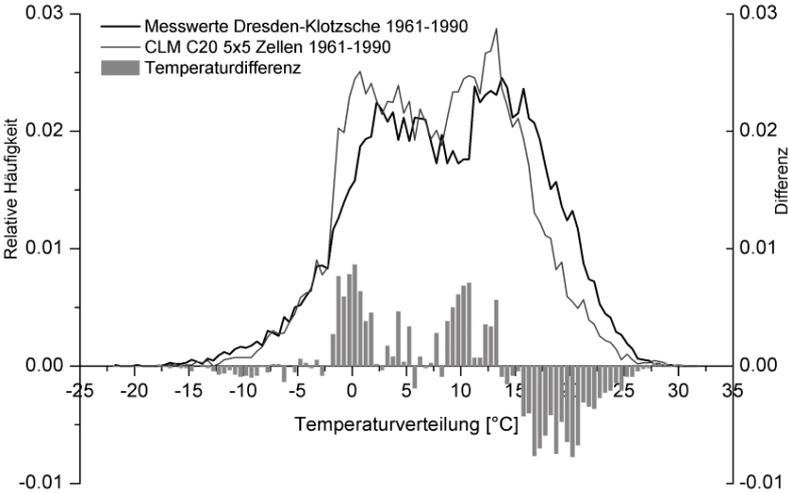
Interpretation der Ergebnisse:

In den Simulationsdaten treten im Vergleich zu den Beobachtungsdaten geringe und hohe Windgeschwindigkeiten seltener, mittlere Windgeschwindigkeiten jedoch häufiger auf (vgl. Abb. a). Der Wind kommt zudem in den Simulationsdaten häufiger aus Ost (E) bzw. West (W) und seltener aus Süd (S) (vgl. Abb. b).

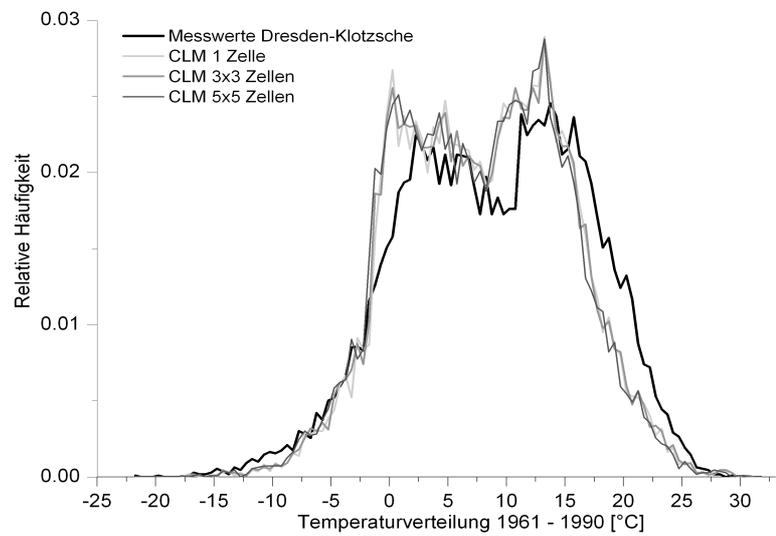
Kontakt / Projekt

Norman Dreier, Institut für Wasserbau, Technische Universität Hamburg-Harburg, norman.dreier@tuhh.de
 Christian Schlamkow, Geotechnik und Küstenwasserbau, Universität Rostock, christian.schlamkow@uni-rostock.de

5.2.2 Relative Häufigkeitsverteilungen

Übergeordnetes Ziel (Kategorie)	Häufigkeitsverteilungen
Verfahren	relative Häufigkeitsverteilungen (deskriptive Statistik)
Beschreibung + Literatur	<p>Ordnen der Daten der Stichprobe nach der Größe, Einteilung in Klassen. Häufigkeit pro Klasse bestimmen und Normierung (durch die Gesamtanzahl der Stichprobe teilen).</p> <p><i>Sachs L.: Angewandte Statistik: Anwendung statistischer Methoden, 6. Aufl., Springer-Verlag Berlin, Heidelberg, New York, Tokio, 1984, ISBN 3-540-12800-X, S. 46-48.</i></p> <p><i>Plate E.-J.: Statistik und angewandte Wahrscheinlichkeitslehre für Bauingenieure, Ernst & Sohn Verlag für Architektur und technische Wissenschaften, Berlin, 1993, ISBN 3-433-01073-0, S.20-22.</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	angewendet auf Temperatur und Niederschlag
Voraussetzungen für Anwendung	Zeitreihen in regelmäßigem Zeitraster
Ergebnis / Interpretation	Relative (prozentuale) Häufigkeit in einer bestimmten Klasse (z. B. Temperatur, Klassenbreite 0,5°C). Die dargestellten Häufigkeiten können in die relativen Summenhäufigkeiten (empirische Verteilungsfunktion) überführt werden.
Bewertung	Einfaches und sehr anschauliches Verfahren zur statistischen Auswertung von Zeitreihen. Die Wahl der Klassenbreite wirkt sich auf die Darstellung der Häufigkeitsverteilung aus (Klassenanzahl in Abhängigkeit des Stichprobenumfangs). Werden Beobachtungsdaten analysiert ist darauf zu achten eine zusätzliche Klasse für Messfehler vorzusehen, damit die Summe der relativen Häufigkeiten genau 1 bzw. 100% ergibt.
Beispiel / Publikation	<p>Beispiel 1: Vergleich der beobachteten und mit CLM modellierten Häufigkeiten der Tagesmitteltemperatur an der Station Dresden-Klotzsche à „cold“ Bias von CLM für Temperaturen >15°C</p>  <p>Beispiel 2: Vergleich der beobachteten und mit CLM modellierten Häufigkeiten der Tagesmitteltemperatur – mit</p>

und ohne räumliche(r) Mittelung → Häufigkeitsverteilung für Dresden-Klotzsche unabhängig von der Anzahl betrachteter Gitterzellen



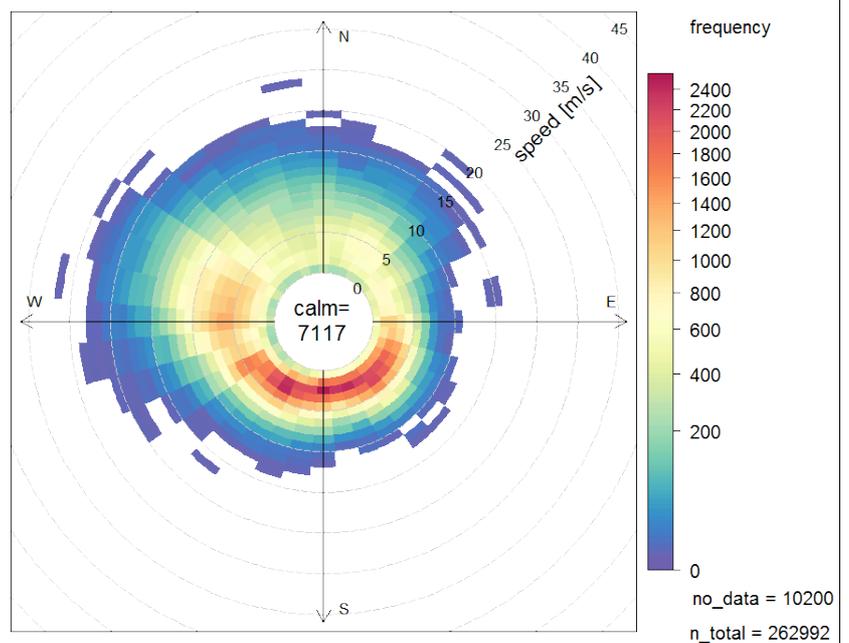
Kontakt / Projekt

Majana Heidenreich
Technische Universität Dresden
majana.heidenreich@tu-dresden.de
KLIMZUG-Projekt: REGKLAM

5.2.3 Zweidimensionale Häufigkeitsverteilung

Übergeordnetes Ziel (Kategorie)	Häufigkeitsverteilungen																																																						
Verfahren	Zweidimensionale Häufigkeitsverteilung																																																						
Beschreibung + Literatur	<p>Die zweidimensionale Häufigkeitsverteilung beschreibt die Gesamtheit aller auftretenden Kombinationen zweier Merkmale X (mit den Ausprägungen $x_i, i=1, \dots, l$) und Y (mit den Ausprägungen $y_j, j=1, \dots, m$).</p> <p>Analog zur eindimensionalen Häufigkeitsverteilung erfolgt die Angabe der Ausprägungskombination (x_i, y_j) entweder in Form von absoluten $n(x_i, y_j)$ und/oder relativen Häufigkeiten $h(x_i, y_j) = n(x_i, y_j)/n_{ges}$. Es gilt:</p> $\sum_{i=1}^l \sum_{j=1}^m n(x_i, y_j) = n_{ges} \quad \text{bzw.} \quad \sum_{i=1}^l \sum_{j=1}^m h(x_i, y_j) = 1$ <p>mit n_{ges}: Anzahl der Daten der Stichprobe.</p> <p>Die Darstellung der Ausprägungskombinationen erfolgt in Form der sog. „Kontingenztafel“ (Kreuztafel) oder grafisch in Form von Diagrammen (siehe Beispiel). Eine Kreuztafel mit Angabe der relativen Häufigkeiten ist nachfolgend dargestellt. Die äußersten Spalten der Tabelle sind die jeweilige Randverteilung (eindimensionale Häufigkeitsverteilung) des jeweiligen Merkmals.</p> <table border="1" data-bbox="625 1144 1273 1547"> <thead> <tr> <th rowspan="2">Merkmal X</th> <th colspan="5">Merkmal Y</th> <th rowspan="2">Rand- verteilung g X</th> </tr> <tr> <th>y_1</th> <th>...</th> <th>y_j</th> <th>...</th> <th>y_m</th> </tr> </thead> <tbody> <tr> <td>x_1</td> <td>h_{11}</td> <td>...</td> <td>h_{1j}</td> <td>...</td> <td>h_{1m}</td> <td>$h_{1.}$</td> </tr> <tr> <td>...</td> <td>...</td> <td>...</td> <td>...</td> <td>...</td> <td>...</td> <td>...</td> </tr> <tr> <td>x_i</td> <td>h_{i1}</td> <td>...</td> <td>h_{ij}</td> <td>...</td> <td>h_{im}</td> <td>$h_{i.}$</td> </tr> <tr> <td>...</td> <td>...</td> <td>...</td> <td>...</td> <td>...</td> <td>...</td> <td>...</td> </tr> <tr> <td>x_l</td> <td>h_{l1}</td> <td>...</td> <td>h_{lj}</td> <td>...</td> <td>h_{lm}</td> <td>$h_{l.}$</td> </tr> <tr> <td>Rand- verteilung Y</td> <td>$h_{.1}$</td> <td>...</td> <td>$h_{.j}$</td> <td>...</td> <td>$h_{.m}$</td> <td>$h_{..} = 1$</td> </tr> </tbody> </table> <p>Quelle: http://mars.wiwi.hu-berlin.de/mediawiki/mmstat_de/index.php/Zweidimensionale_H%C3%A4ufigkeitsverteilung_-_STAT-Zweidimensionale_H%C3%A4ufigkeitstabellen</p> <p>Für Hinweise zur Wahl der Klassenbreite und der linken Klassengrenzen des Merkmals X bzw. Y siehe eindimensionale Häufigkeitsverteilung (Steckbrief Nr. xy).</p> <p>Literatur (Auszug): Sachs L.: <i>Angewandte Statistik: Anwendung statistischer Methoden</i>, 6. Aufl., Springer-Verlag Berlin, Heidelberg, New York, Tokio, 1984, ISBN 3-540-12800-X, S. 46-48.</p>	Merkmal X	Merkmal Y					Rand- verteilung g X	y_1	...	y_j	...	y_m	x_1	h_{11}	...	h_{1j}	...	h_{1m}	$h_{1.}$	x_i	h_{i1}	...	h_{ij}	...	h_{im}	$h_{i.}$	x_l	h_{l1}	...	h_{lj}	...	h_{lm}	$h_{l.}$	Rand- verteilung Y	$h_{.1}$...	$h_{.j}$...	$h_{.m}$	$h_{..} = 1$
Merkmal X	Merkmal Y					Rand- verteilung g X																																																	
	y_1	...	y_j	...	y_m																																																		
x_1	h_{11}	...	h_{1j}	...	h_{1m}	$h_{1.}$																																																	
...																																																	
x_i	h_{i1}	...	h_{ij}	...	h_{im}	$h_{i.}$																																																	
...																																																	
x_l	h_{l1}	...	h_{lj}	...	h_{lm}	$h_{l.}$																																																	
Rand- verteilung Y	$h_{.1}$...	$h_{.j}$...	$h_{.m}$	$h_{..} = 1$																																																	

	<p><i>Von der Lippe, P. Deskriptive Statistik. Gustav Fischer Verlag, Stuttgart, Jena, 1993, ISBN 3-437-40268-4</i> http://www.von-der-lippe.org/dokumente/buch/buch07.pdf</p> <p><i>Plate E.-J.: Statistik und angewandte Wahrscheinlichkeitslehre für Bauingenieure, Ernst & Sohn Verlag für Architektur und technische Wissenschaften, Berlin, 1993, ISBN 3-433-01073-0, S.20-22.</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	beliebige Kombination von Variablen, z.B. Seegangdaten (Wellenhöhe und -anlaufrichtung) oder meteorologische Daten (Windgeschwindigkeit und -richtung)
Voraussetzungen für Anwendung	metrische Daten oder auch nominal bzw. ordinal skalierte Merkmale
Ergebnis / Interpretation	Die Kontingenztabelle (Kreuztabelle) bzw. die grafische Darstellung der zweidimensionalen Häufigkeitsverteilung gibt z.B. Aufschluss über die Ausprägungskombinationen zweier Merkmale X und Y (z.B. Wellenhöhe und -anlaufrichtung). Die Randverteilungen der Kreuztabelle geben darüber hinaus Aufschluss über die eindimensionalen Häufigkeitsverteilung des Merkmals X bzw. Y.
Bewertung	Komplexes Verfahren der deskriptiven Statistik für z.B. die Zeitreihenanalyse von Klimadaten. Werden Zeitreihen aus Beobachtungsdaten analysiert ist darauf zu achten, eine zusätzliche Klasse für Messfehler vorzusehen, damit die Summe der Häufigkeiten genau 1 bzw. 100% ergibt. Ferner ermöglicht das Verfahren Häufigkeiten aus unterschiedlichen Grundgesamtheiten zu vergleichen (z.B. Beobachtungs- und Simulationsdaten) oder Klimaänderungssignale aus Simulationsdaten zu ermitteln.
Beispiel	Darstellung der absoluten zweidimensionalen Häufigkeiten (siehe Abb., farblich codiert) von beobachteten Windgeschwindigkeiten und -richtungen an der Küste von Warnemünde im Zeitraum 1971-2000. Die gewählte Klassenbreite der Windgeschwindigkeiten beträgt 1m/s und die der Windrichtungen 10°.



Interpretation der Ergebnisse:

Anhand der Abb. lässt sich z.B. erkennen, dass Sturmereignisse (mit Windgeschwindigkeiten z.B. $\geq 20\text{m/s}$, \approx Windstärke 9) selten auftreten und vorwiegend aus südwestlichen bis nordwestlichen Richtungen kommen. Die meisten Ereignisse mit mittleren Windgeschwindigkeiten (z.B. $5\text{-}20\text{m/s}$) kommen ebenfalls aus westlichen Richtungen. Hier gilt, je höher die Windgeschwindigkeit, desto seltener ist das Ereignis und die Windrichtung dreht mit der Windgeschwindigkeit zunehmend in nordwestliche Richtungen. Ereignisse mit geringen Windgeschwindigkeiten (z.B. $0\text{-}5\text{m/s}$) treten am häufigsten aus südöstlichen bis südwestlichen Richtungen auf.

Kontakt / Projekt

Norman Dreier, Institut für Wasserbau, Technische Universität Hamburg-Harburg, norman.dreier@tuhh.de

5.3 Zeitreihenanalyse

„Klimawandel“ bezieht sich auf die Zeit und die Auswertung von modellierten oder beobachteten Zeitreihen ist ein wichtiges Werkzeug zur Analyse des Klimas.

Eine mögliche Betrachtung des Klimawandels ist die einer zeitabhängigen Zufallsvariable, die sich aus Trend, Ausreißern / Extremen und Variabilität / Rauschen zusammensetzt (Mudelsee, 2010); diese strukturierte Methode ist die Basis für eines der vorgestellten Verfahren (Abschnitt 5.3.1). Hierbei werden die Daten benutzt, um Parameter zu schätzen, die den Trend, die Variabilität und andere Komponenten beschreiben.

Die Abschätzung von Trends, d.h. die Quantifizierung des Klimawandels, hat höchste Priorität. Dies spiegelt sich auch in der Vielfalt der vorgestellten Methoden wieder: Bei der Linearen Regression (Abschnitt 5.3.6) wird ein einfaches parametrisches Trendmodell angesetzt; bei den verschiedenen Anwendungen von gleitenden Mittelwerten (Abschnitte 5.3.1, 5.3.2 und 5.3.3) muss dagegen keine parametrische Trendform vorausgesetzt werden; der gleitende Median (Abschnitt 5.3.4) ist das robuste Gegenstück zum gleitenden Mittelwert; weiterhin wird die flexible Trendanalyse (Abschnitt 5.3.8) als nichtparametrisches Verfahren vorgestellt. Nichtparametrische Regression wird vielfach auch als Glättung bezeichnet. Dahinter steckt die Idee, hochfrequente Variabilität (Rauschen) herauszufiltern. Dies geschieht z.B. mithilfe eines gleitenden Fensters. Andere Methoden zur Extrahierung von Trends mit niedriger Frequenz sind numerische Frequenzfilter (Abschnitt 5.3.5) sowie Vergleiche von Zeitscheiben (Abschnitt 5.3.7). Neben dem Trend kann auch die Variabilität einer klimatischen Variablen in verschiedene Klassen aufgespalten werden (Abschnitt 5.3.10).

Literatur. Das Buch von Mudelsee (2010) behandelt insbesondere die Analyse von Zeitreihen in univariaten (eine Variable) und bivariaten (zwei Variablen) Situationen. Das Buch von von Storch und Zwiers (1999) behandelt daneben auch die Zeitreihenanalyse mit mehr Dimensionen. Beide beinhalten ausführliche Vorschläge zu weiterführender Literatur.

Mudelsee M (2010) *Climate Time Series Analysis: Classical Statistical and Bootstrap Methods*. Springer, Dordrecht, 474 pp.

Von Storch H, Zwiers FW (1999) *Statistical Analysis in Climate Research*. Cambridge University Press, Cambridge, 484 pp.

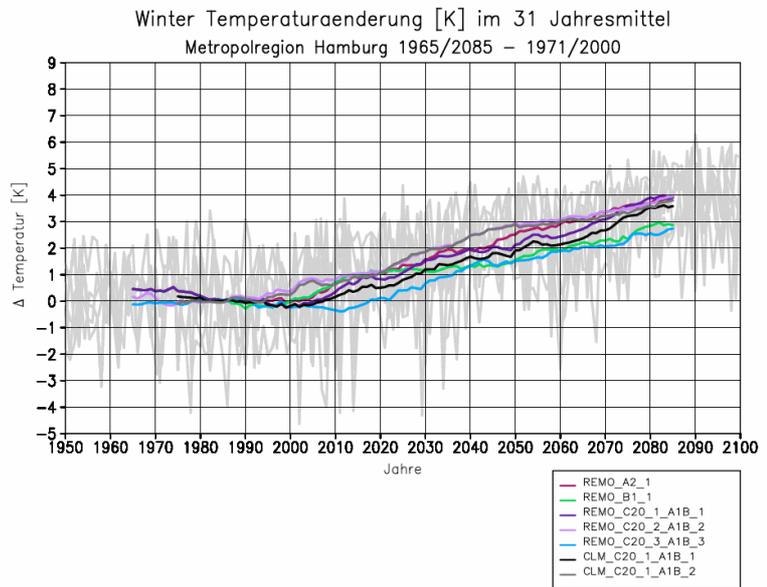
5.3.1 Gleitendes Mittel

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse zur Trendbestimmung
Verfahren	Gleitendes Mittel
Beschreibung + Literatur	Bildung arithmetischer Mittelwerte von zeitlich aufeinander folgenden Datenpunkten
Geeignet für (Parameter, zeitl. Auflösung)	Hier: Überstau-/Überlaufhäufigkeit und –mengen, zeitliche Auflösung beliebig
Voraussetzungen für Anwendung	lückenlose Zeitreihe
Ergebnis / Interpretation	Reduziert Variabilität und erlaubt so Untersuchung von Trends
Bewertung	schnelle und einfache Anwendung zur Untersuchung von Zeitreihen
Beispiel / Publikation	<i>Kuchenbecker et al., KA 2010</i>
Kontakt / Projekt	Nina Hüffmeyer Hamburger Stadtentwässerung AöR nina.hueffmeyer@hamburgwasser.de KLIMZUG-NORD

5.3.2 Methode gleitender Mittelwerte

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse allgemein
Verfahren	Methode gleitender Mittelwerte
Beschreibung + Literatur	Berechnung fortlaufender 10 bzw. 11-Jahresmittel sowie fortlaufender 30- bzw. 31-Jahresmittel transienter Zeitreihen simulierter Klimaparameter (Anmerkung: Bei der Abbildung der fortlaufenden Mittel auf den mittleren Zeitpunkt des gemittelte Zeitintervalls ist die Verwendung von 11- und 31- Jahresmittel sinnvoll)
Geeignet für (Parameter, zeitl. Auflösung)	Beliebige Parameter in monatlicher, saisonaler und jährlicher Auflösung
Voraussetzungen für Anwendung	Ausreichend lange lückenlose Zeitreihen
Ergebnis / Interpretation	Die Darstellung der Zeitreihen als gleitende 10- bzw. 11-Jahresmittel ermöglicht die Visualisierung der dekadischen Variabilität. Die Darstellung der Zeitreihen als gleitende 30- bzw. 31-Jahresmitte ermöglicht die Bestimmung der Bandbreite der Klimaänderung.
Bewertung	Einfache, schnelle Auswertung und Visualisierung
Beispiel / Publikation	<p><i>Jacob D, Göttel H, Kotlarski S, Lorenz P, Sieck K (2008): Klimaauswirkungen und Anpassung in Deutschland: Erstellung regionaler Klimaszenarien für Deutschland mit dem Klimamodell REMO. Forschungsbericht 204 41 138 Teil 2, i.A. des UBA Dessau</i></p> <p><i>Jacob D, Bülow K, Kotova L, Moseley C, Petersen J, Rechid D: Regionale Klimasimulationen für Europa und Deutschland – in Vorbereitung</i></p> <p>Beispiel 1: Projizierte Änderung der Temperatur im Winter in der Metropolregion Hamburg simuliert mit REMO und CLM im Vergleich zur Referenzperiode 1971-2000 dargestellt im gleitenden 11-Jahresmittel</p>

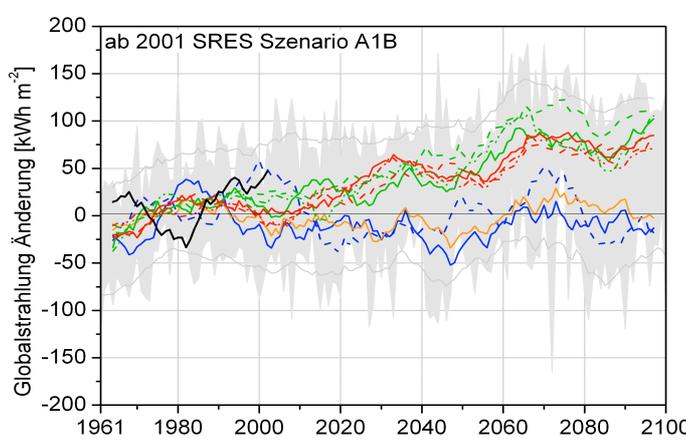
Beispiel 2: Projizierte Änderung der Temperatur im Winter in der Metropolregion Hamburg simuliert mit REMO und CLM im Vergleich zur Referenzperiode 1971-2000 dargestellt im gleitenden 31-Jahresmittel und grau hinterlegt mit den 1-Jahreswerten der verschiedenen Szenarien und Realisierungen



Kontakt / Projekt

Diana Rechid
MPI für Meteorologie
diana.rechid@zmaw.de
KLIMZUG NORD

5.3.3 Gleitender Mittelwert

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse (Trends)
Verfahren	Gleitender Mittelwert
Beschreibung + Literatur	einfache Trendschätzung mit Hilfe gleitender Mittelwerte <i>J.-P. Kreiß & G. Neuhaus (2006): Einführung in die Zeitreihenanalyse, Springer-Verlag.</i>
Geeignet für (Parameter, zeitl. Auflösung)	Monats- und Jahreswerte von Temperatur, Niederschlag, Strahlung u. a. meteorologischen Größen, Abflüsse
Voraussetzungen für Anwendung	lange lückenlose Zeitreihen; hier >100 Jahre
Ergebnis / Interpretation	Reduzierung der Variabilität → Visualisierung von Trends
Bewertung	Einfaches schnelles Verfahren
Beispiel / Publikation	Zentrierte/symmetrische 11jährig gleitende Mittelwerte <i>REGKLAM Heft 1 und 2 (Bernhofer et al., 2009 und 2011)</i> 
Kontakt / Projekt	Majana Heidenreich (TU Dresden), Daniel Leistner (TU BA Freiberg), Andreas Hoy (TU BA Freiberg) majana.heidenreich@tu-dresden.de daniel.leistner@ioez.tu-freiberg.de andreas.hoy@ioez.tu-freiberg.de KLIMZUG-Projekt: REGKLAM

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2009): Das Klima in der REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 1, Rhombos-Verlag Dresden

5.3.4 Gleitender Median

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse Trendschätzung
Verfahren	Gleitender Median
Beschreibung + Literatur	<p>Robuste nichtparametrische Trendschätzung.</p> <p>Robust bedeutet, dass die Methode nicht beeinflusst ist durch das Vorhandensein von Extremen. Man verwendet den gleitenden Median (berechnet über die Punkte innerhalb eines gleitenden Fensters) für eine nichtparametrische Hintergrund- oder Trendschätzung (und nicht das gleitende Mittel).</p> <p><i>Mudelsee M (2006) CLIM-X-DETECT: A Fortran 90 program for robust detection of extremes against a time-dependent background in climate records. Computers and Geosciences 32:141–144.</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	<p>Alle Parameter bei beliebiger Zeitauflösung.</p> <p>Es ist zu beachten, dass eine hohe Zeitauflösung eine starke Autokorrelation bewirken kann, was bei der Wahl der Anzahl der Fenster-Punkte zu berücksichtigen ist (d.h.: mehr Punkte sind dann heranzuziehen als bei Nicht-Autokorrelation).</p>
Voraussetzungen für Anwendung	Homogenität und Repräsentanz der Daten. Im Falle von Autokorrelation mag die Richtlinie durch Kreuzvalidierung weniger informativ sein, und es sollte mit unterschiedlichen Anzahlen von Fenster-Punkte gearbeitet werden.
Ergebnis/Interpretation	Trend- oder zeitabhängige Hintergrundschätzung
Bewertung	Robustes Standardverfahren; es gibt eine Richtlinie basierend auf Kreuzvalidierung (von der Software zur Verfügung gestellt), jedoch sollte auch mit anderen Werten (Anzahl Fenster-Punkte) experimentiert und die Sensitivität des Ergebnisses untersucht werden.
Beispiel/Publikation	<p>[SIEHE ABSCHNITT "NICHTSTATIONÄRE PEAKS OVER THRESHOLD]</p> <p>Der Originalartikel (Mudelsee 2006) erläutert die Methode und beschreibt die Fortran-90-Software CLIM-X-DETECT.</p>
Kontakt/Projekt	<p>Manfred Mudelsee Climate Risk Analysis, Hannover, Germany; mudelsee@climate-risk-analyis.com www.climate-risk-analysis.com</p>

5.3.5 Numerische Filterung: Hoch-, Tief- und Bandpassfilterung

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse
Verfahren	Numerische Filterung: Hoch-, Tief- und Bandpassfilterung (Filtergewichte z.B. aus der Gauß'schen standardisierten Normalverteilung)
Beschreibung + Literatur	<p>Darstellung kurz- und langfristiger Schwankungen (verschiedener Perioden) in Zeitreihen</p> <p>Numerische Filterung ist beispielweise anschaulich beschrieben bei:</p> <p><i>C.-D. Schönwiese. Praktische Statistik für Meteorologen und Geowissenschaftler. Gebrüder Bornträger, Berlin, Stuttgart: 1985</i></p> <p>Eine R-Funktion zur Berechnung der gefilterten Zeitreihe kann auf Anfrage bereitgestellt werden</p>
Geeignet für (Parameter, zeitl. Auflösung)	Hydrologischen Zeitreihen (Niederschlag, Verdunstung, Abflusskomponenten, etc.) Jahreswerte, Monatswerte, Tageswerte, Stundenwerte
Voraussetzungen für Anwendung	Vollständige (lückenlose) äquidistante Zeitreihe
Ergebnis / Interpretation	Ergebnis ist eine gefilterte Zeitreihe, die die kurz-/langfristigen Schwankungen der ursprünglichen Zeitreihe zeigt.
Bewertung	Tiefpassfilter zeigt besser als gleitender Mittelwerte die langfristigen Schwankungen.
Beispiel / Publikation	<i>W. Roedel u. T. Wagner: Physik unserer Umwelt: Die Atmosphäre, 4th ed., Springer-Verlag Berlin Heidelberg 2011, auf S. 177</i>
Kontakt / Projekt	Frank Herrmann Forschungszentrum Jülich GmbH Institut für Bio- und Geowissenschaften f.herrmann@fz-juelich.de KLIMZUG Nord

5.3.6 Lineare Regression

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse zur Trendbestimmung
Verfahren	Lineare Regression
Beschreibung +Literatur	<p>Beschreibung einer linearen Abhängigkeit einer Variablen von anderen unabhängigen Variablen der Form $y=c+ax$. Bei linearer Regression wird dabei die Summe der quadratischen Fehler (die Residualvarianz) minimiert. Anschaulich beschrieben bedeutet dies, dass eine Ausgleichsgerade zwischen den Größen eine möglichst gute Anpassung an sämtlich empirisch ermittelte (bzw. gemessene) y-Werte darstellen soll. Die Summe der Quadrate der vertikalen Abweichungen der y-Werte von der geschätzten Gerade soll kleiner sein als die von irgendeiner anderen Geraden.</p> <p>Siehe dazu z.B.: von Storch and Zwiers, <i>Statistical Analysis in Climate Research</i>; http://en.wikipedia.org/wiki/Linear_regression, ...</p> <p>Generell ist dieses Thema ausführlich in Literatur über die Einführung in die Statistik behandelt.</p>
Geeignet für (Parameter, zeitl.Auflösung)	Variablen, die von anderen Variablen abhängig sind, welche kontinuierlich sind und deren Zusammenhang untereinander linear ist.
Voraussetzungen für Anwendung	<p>Linearer Zusammenhang zwischen abhängiger und unabhängigen Variablen. Unabhängige und normalverteilte Residuen mit konstanter Varianz.</p> <p>Verletzungen dieser Annahmen führen meist zu falschen Ergebnissen und Schlussfolgerungen.</p> <p>Unbedingt berücksichtigt werden muss, dass die unabhängigen Variablen auch wirklich unabhängig voneinander sind. Je mehr die unabhängigen Parameter korrelieren, desto verfälschter wird das Ergebnis.</p>
Ergebnis Interpretation	Beschreibung des linearen Zusammenhangs durch ermittelte Parameter. Zudem wird in den meisten Statistikprogrammen auch die Signifikanz der Parameter (signifikant unterschiedlich von 0) automatisch ermittelt.
Beispiel	z.B. „ <i>A simple empirical model for decadal climate prediction</i> “ (Krueger, O & J-S von Storch), <i>Journal of Climate</i> , 2011, doi: 10.1175/2010JCLI3726.1
Kontakt / Projekt	Oliver Krüger Helmholtz-Zentrum Geesthacht Institut für Küstenforschung Oliver.krueger@hzg.de

5.3.7 Vergleich verschiedener Zeitscheiben hinsichtlich ihrer Mittelwerte, Variabilität und/oder Verteilung

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse (Trends)
Verfahren	Zeitscheibendifferenz -> Vergleich von „Zukunftszeitscheiben“ in den Projektionen (z. B. 2021–2050, 2071–2100) mit den in der Referenzperiode (z. B. 1961–1990) modellierten bzw. beobachteten Werten bzw. Verteilungen
Beschreibung + Literatur	Vergleich verschiedener Zeitscheiben hinsichtlich ihrer Mittelwerte, Variabilität und/oder Verteilung
Geeignet für (Parameter, zeitl. Auflösung)	Geeignet für verschiedener Klimaparameter wie Niederschlag, Temperatur, Wind, etc. sowie abgeleiteter Kenngrößen z. B. klimatologische Kenntage. Prinzipiell für alle zeitlichen Auflösungen möglich.
Voraussetzungen für Anwendung	Verglichene Zeitscheiben sollten gleich viele Jahre umfassen und lang genug zur statistischen Beschreibung des Klimas sein (möglichst 30a)
Ergebnis / Interpretation	Klimaänderungssignale sichtbar machen
Bewertung	Durch die Darstellung relativer Änderungssignale (Bezug zur Referenz des Modells anstelle zu den Beobachtungswerten) werden die Trends von Modellen mit unterschiedlichem systematischen Fehler (Bias) vergleichbar
Beispiel	REGKLAM Heft 1 und 2 (Bernhofer et al., 2009 und 2011)
Kontakt / Projekt	Majana Heidenreich (TU Dresden), Stephanie Hänsel (TU BA Freiberg) majana.heidenreich@tu-dresden, stephanie.haensel@ioez.tu-freiberg.de KLIMZUG-Projekt: REGKLAM

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2009): Das Klima in der REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 1, Rhombos-Verlag Dresden

5.3.8 Variable Trendanalyse

Übergeordnetes Ziel (Kategorie) KB	Zeitreihenanalyse (Trends)
Verfahren	Variable Trendanalyse
Beschreibung + Literatur	Darstellung aller in einem definierten Zeitfenster verfügbaren Trendkombinationen; vgl. Rapp J (2000) Konzeption, Problematik und Ergebnisse klimatologischer Trendanalysen für Europa und Deutschland . Berichte des DWD, 212, Offenbach, 145 S.
Geeignet für (Parameter, zeitl. Auflösung)	Zeitreihen von Häufigkeiten (z. B. Zirkulationsformen), Klimaparameter (z. B. Temperatur); zeitliche Auflösung: frei definierbar (eigene Verwendung: jährliche Auflösung)
Voraussetzungen für Anwendung	Lückenlose und möglichst lange und homogene Zeitreihe
Ergebnis / Interpretation	Maximale Informationsfülle in maximal möglicher Kompression, beseitigt Bias zeitlich subjektiv festgelegter Trendzeiträume
Bewertung	Ermöglicht Interpretation komplexer Änderungssignale mit maximaler Genauigkeit; hohe Komplexität erschwert Interpretation
Beispiel/ Publikation	Rapp 2000; Hoy A, Sepp M, Matschullat J (in Bearbeitung): "Variability of atmospheric circulation in Europe and Russia (1901-2010)"
Kontakt / Projekt	Andreas Hoy (TU BA Freiberg) andreas.hoy@ioez.tu-freiberg.de KLIMZUG-Projekt: REGKLAM, TP 2.1

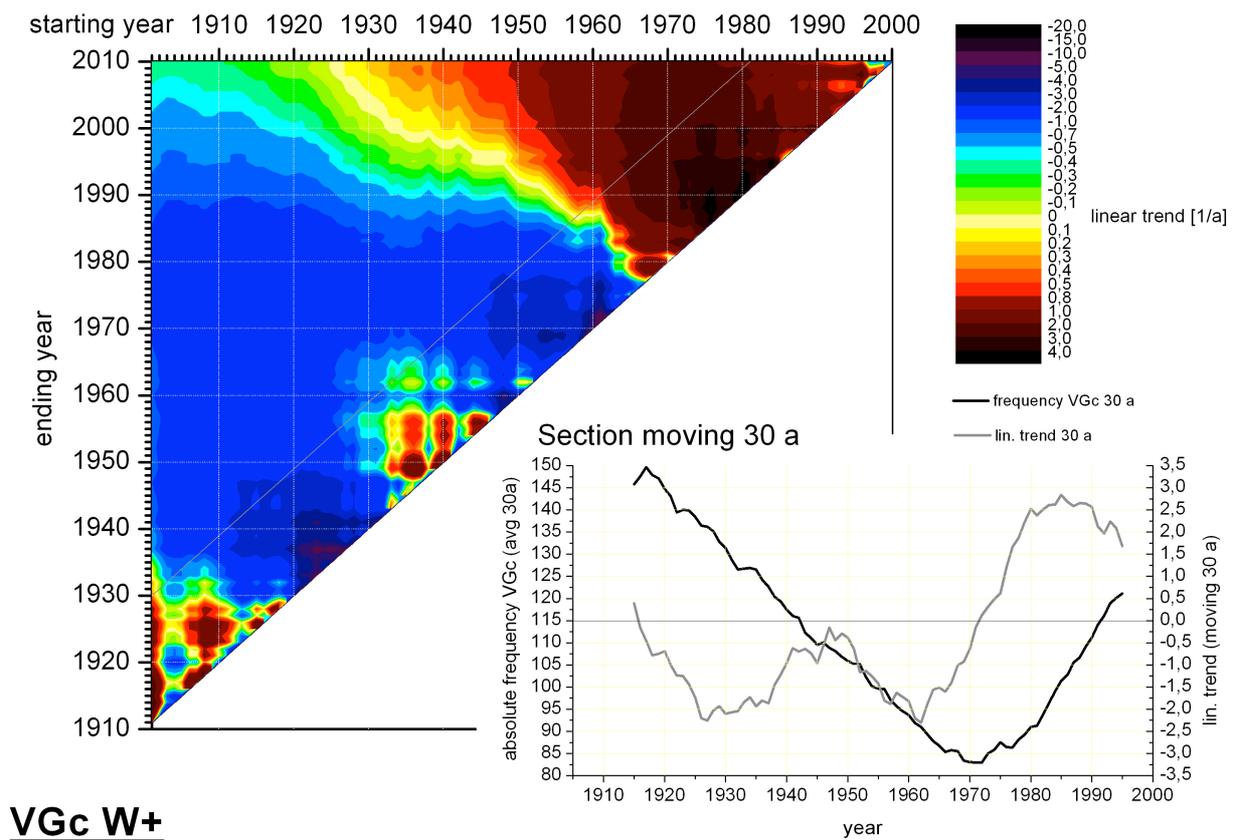
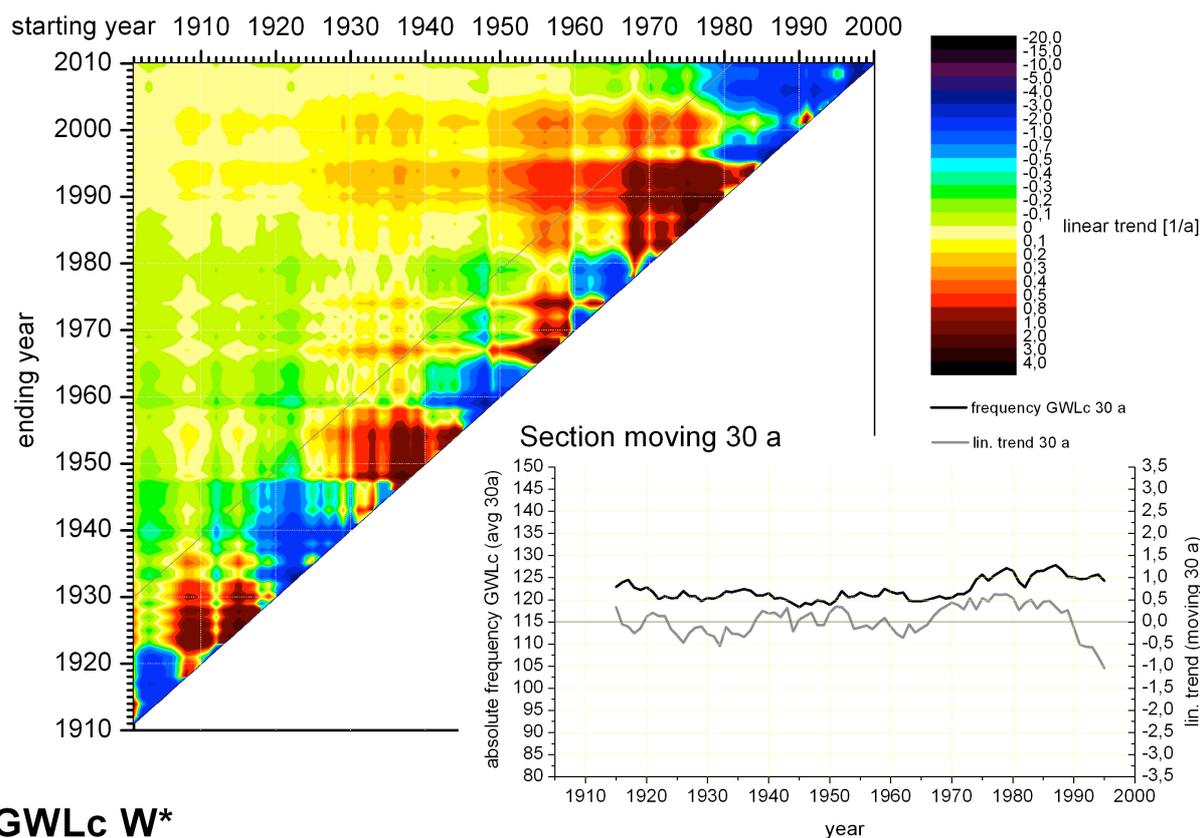


Figure 1: VGc W+ (1901-2010); a) variable trend analysis: depicted are all possible trend combinations for periods from 10 to 110 years (upper left); b) absolute frequency/ linear trend (30 year moving average) (lower right); the thin black line in the upper left picture depicts 30 year trends and is illustrated as linear trend line in the lower right picture



GWLc W*

Figure 2: As in figure 5, but for GWLc W*

1) Applying a variable trend analysis (Rapp 2000) allows a thorough, yet manual (and subjective) investigation of trend behaviour. All possible combinations of linear trends during 1901-2010 are illustrated for periods lasting from 10 to 110 years in one matrix (figures 1 and 2; upper left). The trend matrixes illustrate complex pictures with high fluctuations of trend direction and magnitude in shorter time frames up to approximately 30 years, especially for W*. Here trends are generally weak, but more stable in longer periods. Relatively strong positive trends for W* are visible starting from the 1950s and ending in the 1990s. W+, on the other hand, shows very strong and unusually stable signals. Until the 1960s trends of most time scales were almost completely negative, while frequencies showed almost undisturbed, very strong increasing trends afterwards. It gets visible that trends over 110 years do not easily get disturbed by short- and medium term fluctuations. Their temporal location, however, is always subjectively chosen and only allows robust conclusions for the chosen time frame, without the possibility of analysing fluctuations within that period. Given the time series of W+, it gets clear that long term linear trends do not yield much value given such pronounced opposing trend values within a time frame. On the other hand, a variable trend analysis depicts the trend behaviour with maximum completeness, but the involved complexity often impedes the observer from drawing clear conclusions of trend characteristics within an investigation period. The problem of complexity further multiplies when comparing a number of different circulation forms.

2) Analysing moving trend variables of a single length (e.g., 30 years) is therefore a method to reduce complexity, while still showing fluctuations in trend direction and magnitude over time (figures 1 and 2; lower right). Given the predominantly clear trend behaviour of W+ an interpretation of the trend line is relatively easy. This task gets more complicated, if the magnitude of fluctuations is smaller, but a higher number of changes in trend direction are visible over time, like for W*. Hence, while this method allows identifying periods of clear trend behaviour without varying temporal complexity, it still lacks an easy and clear way to detect and interpret frequency changes.

3) Finally, illustrating a smoothed time series of moving (e.g., 30 years) frequency values is a classical way of analysing fluctuations in time series (figures 1 and 2; lower right). Here a very clear and easily interpretable picture is given for W^+ , with a bisection of frequencies until the 1970s and a following strong increase. It also gets clear that no relevant trend is present for W^* . Given the straightforward goal of interpreting changes in time series this common way of analysing time series is the clearest of the presented methods. It will be therefore used in the following section to investigate frequency changes in more detail compared to the inspection of linear trends. Shorter periods lasting 11 years (compared to 30 years in this chapter) are used to obtain a more detailed picture of frequency changes over time while still removing the noise of annual fluctuations.

5.3.9 Strukturorientierte Zeitreihenzerlegung, Maximum Likelihood Methode

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse
Verfahren	strukturorientierte Zeitreihenzerlegung, Maximum Likelihood Methode
Beschreibung + Literatur	Die Gauss, Gumbel und Weibull Wahrscheinlichkeitsdichte Funktion werden durch 2 zeitlich abhängige Parameter (Mittelwert und Standardabweichung) beschrieben. <i>Trömel, S. (2004): Statistische Modellierung von Klimazeitreihen, Dissertation, J.W. Goethe Universität Frankfurt am Main, 2004.</i>
Geeignet für (Parameter, zeitl. Auflösung)	Monatsmitteltemperatur und Monatsniederschlagssummen
Voraussetzungen für Anwendung	Lange vollständige Zeitreihe von min. 100 Jahren
Ergebnis / Interpretation	Trendbestimmung des Mittelwerts und der Standardabweichung
Bewertung	Die Methode ist nur möglich, wenn sich die Zeitreihe durch eine Verteilungsfunktion beschreiben lässt, Kolmogoroff Smirnow Test
Beispiel / Publikation	<i>Bülow, K. (2010): Zeitreihenanalyse von regionalen Temperatur- und Niederschlagssimulationen in Deutschland, Dissertation, Uni-Hamburg, Berichte zur Erdsystem Forschung 75, 2010.</i> <i>Trömel, S. und C.-D. Schönwiese (2007): Probability change of extreme precipitation observed from 1901 to 2000 in Germany, Theor. Appl. Climatol., 87, 29--39, doi:10.1007/s00704-005-0230-4.</i>
Kontakt / Projekt	Katharina Bülow Bundesamt für Seeschifffahrt und Hydrographie katharina.buelow@bsh.de KLIWAS

5.3.10 Varianzanalyse (ANOVA)

Übergeordnetes Ziel (Kategorie)	Zeitreihenanalyse
Verfahren	Varianzanalyse (ANOVA)
Beschreibung +Literatur	<p>Zerlegung der Variabilität einer Variable in Abhängigkeit von verschiedenen Klassen. Dafür wird die zu untersuchende Variable in verschiedene Klassen eingeteilt (abhängig von gewählten Faktoren). Sofern die Faktoren die Variabilität der Variable beeinflussen, ist dies in unterschiedlichen Mittelwerten der einzelnen Faktoren erkennbar. Zudem lässt sich damit auch entscheiden, ob die Variabilität durch bekannte Gründe (die Faktoren) oder unerklärte Gründe verursacht werden. Es gibt mehrere Unterarten der Varianzanalyse. Gemein ist ihnen jedoch, dass für jede Gruppe an Faktoren eine Teststatistik berechnet wird, die das Verhältnis von erklärter zu unerklärter Varianz beschreibt. Diese folgt einer zentrierten F-Verteilung mit 2 Freiheitsgraden. Unter den gewählten Null Hypothesen (in der Regel, dass es keinen Unterschied zwischen den Untergruppen der einzelnen Faktoren gibt) nutzt man die Teststatistik um sie mit dieser F-Verteilung zu vergleichen und erhält die Wahrscheinlichkeit P ein Varianzverhältnis zu finden, das mindestens genauso hoch ist wie die berechnete Teststatistik. Wenn P sehr klein ist (kleiner als das gewählte Signifikanzlevel), wird die einzelne Nullhypothese abgelehnt.</p> <p>Siehe dazu z.B.: von Storch and Zwiers (1999) Generell ist dieses Thema ausführlich in Literatur über die Einführung in die Statistik behandelt.</p>
Geeignet für (Parameter, zeitl.Auflösung)	Variablen, die von anderen Variablen abhängig sind, welche aber faktorisiert sind. Die Varianzanalyse beschreibt diese Abhängigkeit.
Voraussetzungen für Anwendung	<p>Faktorisierte/kategorisierte Variablen! Die einzelnen Gruppen sollten zudem gleiche Gruppengrößen haben.</p> <p>Es wird angenommen, dass die untersuchte Variable einer Normalverteilung folgt mit identischer Varianz. Zudem wird angenommen, dass die einzelnen Realisationen unabhängig voneinander sind.</p>
Ergebnis Interpretation	Bestimmung, ob es signifikante Differenzen zwischen den einzelnen Gruppen einer kategorisierten Variable gibt.
Beispiel	z.B. http://journals.ametsoc.org/doi/abs/10.1175/2011JCLI3913.1
Kontakt / Projekt	Oliver Krüger Helmholtz-Zentrum Geesthacht Institut für Küstenforschung, Oliver.krueger@hzg.de

5.4 Bias-Korrektur

In der Klimamodellierung bezeichnet ein Bias die systematische Abweichung einer Klimamodellvariablen von ihrem beobachteten Gegenstück. So ist beispielweise bei einer Reihe von Klimamodellen ein positiver Bias des Niederschlags für die Zeitspanne von 1951 bis heute in der Region Zentraleuropa - Skandinavien zu beobachten. Dies bedeutet, dass die Klimamodelle den Niederschlag in dieser Zeit und Region überschätzen (Goodess et al. 2009). Der Bias wird typischerweise unzureichenden Modellformulierungen zugeschrieben, die ihren Ursprung in den Grenzen unseres Verständnisses der Prozesse im Klimasystem sowie in der limitierten Rechenleistung unserer Computer haben.

Selbstverständlich besteht die langfristige Lösung dieser Situation darin, verbesserte Klimamodelle zu konstruieren, woran kontinuierlich von vielen Modellierungsgruppen gearbeitet wird; diese Entwicklungsprozesse erfordern jedoch eine Menge Zeit. Kurzfristige Abhilfe schaffen daher so genannte Bias-Korrekturmethode, bei denen die Klimamodellergebnisse so korrigiert werden, dass der Bias verschwindet. Der Erfolg einer solchen Korrektur hängt kritisch von folgenden Faktoren ab: (1) eine angemessene stochastische Beschreibung der Art des Bias (z.B. additiv/multiplikativ oder konstant/zeitabhängig) und (2) die Verfügbarkeit von genauen und in Zeit wie Raum hochaufgelösten Beobachtungsdaten. Ein weiterer kritischer Aspekt ist die Gefahr von Inkonsistenzen zwischen Bias-korrigierten und nicht-korrigierten Klimamodellvariablen. Als Beispiel sei hier der Zusammenhang zwischen der Lufttemperatur und der Art des Niederschlags (Regen oder Schnee) genannt. Das Feld der Bias-Korrektur ist eines der neueren in der Klimamodellierung, was uns vielversprechende Entwicklungen für die Zukunft erwarten lässt.

Die ausgewählten Bias-Korrekturverfahren, die in der Klimawissenschaft zurzeit genutzt wird, ist das Quantile Mapping (QM). Darin wird eine Beziehung zwischen der Verteilungsfunktion der modellierten Variablen und der der beobachteten Variablen hergestellt. Die zwei vorgestellten Verfahren (Abschnitt 5.4.1 und 5.4.2) geben weitere Informationen. Dies Verfahren arbeitet gut, wenn mittlere Klimazustände analysiert werden sollen und eine gute Beobachtungsdatenbasis vorliegt. QM ist für die Analyse extremer und instationärer Klimazustände weniger geeignet (Kallache et al., 2011). Eine wesentliche Annahme des QM ist die Stationarität des Biasverlaufs, die für zukünftige Klimaanalysen verletzt sein könnte.

Literatur. Eine kurze Übersicht über die Bias-Korrektur in der Klimamodellierung mit zahlreichen Beispielen findet sich in Mudelsee et al. (2010). Das QM wird beschrieben durch Piani et al. (2010). Weitere Korrekturen, inklusive nicht-stationärer Methoden, werden in Mudelsee (2010: Abschnitt 9.4.4) aufgegriffen. Kallache et al. (2011) analysieren nicht-stationäres probabilistisches Downscaling von Extremniederschlägen.

Goodess CM, Jacob D, Déqué M, Gutiérrez JM, Huth R, Kendon E, Leckebusch GC, Lorenz P, Pavan V (2009) Downscaling methods, data and tools for input to impacts assessments. In: van der Linden P, Mitchell JFB (Eds.) ENSEMBLES: Climate change and its impacts at seasonal, decadal and centennial timescales. Met Office Hadley Centre, Exeter, 59–78.

Kallache M, Vrac M, Naveau P, Michelangeli P-A (2011) Nonstationary probabilistic downscaling of extreme precipitation. *Journal of Geophysical Research* 116:D05113 (doi:10.1029/2010JD014892).

Maraun (2013) *J. Climate*, DOI: 10.1175/JCLI-D-12-00821.1

Mudelsee M, Chirila D, Deutschländer T, Döring C, Haerter J, Hagemann S, Hoffmann H, Jacob D, Krahe P, Lohmann G, Moseley C, Nilson E, Panferov O, Rath T, Tinz B (2010) Climate model bias correction und die Deutsche Anpassungsstrategie. *Mitteilungen Deutsche Meteorologische Gesellschaft* 3:2–7.

Mudelsee M (2010) *Climate Time Series Analysis: Classical Statistical and Bootstrap Methods*. Springer, Dordrecht, 474 pp.

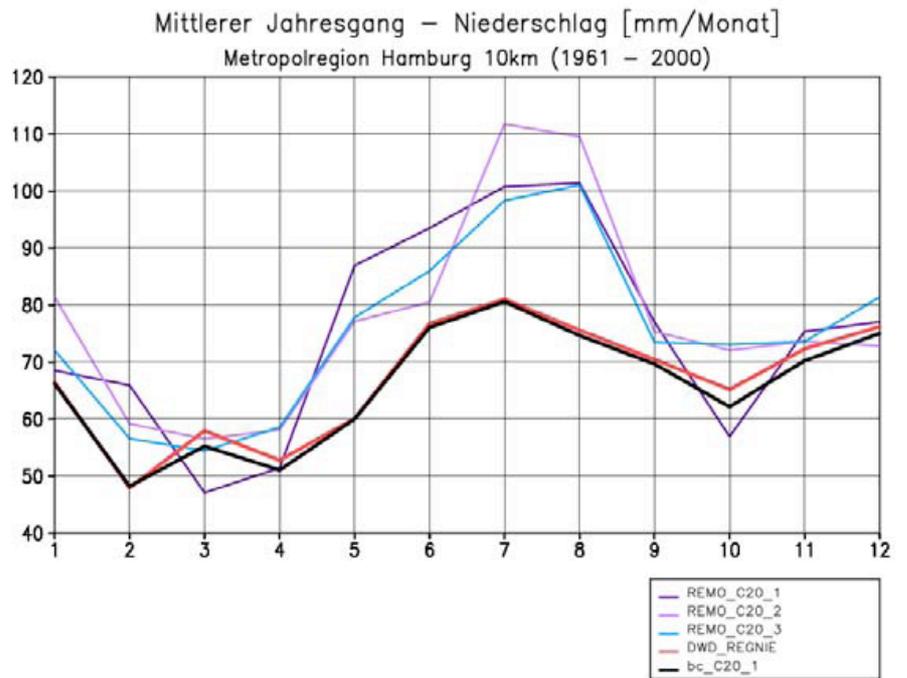
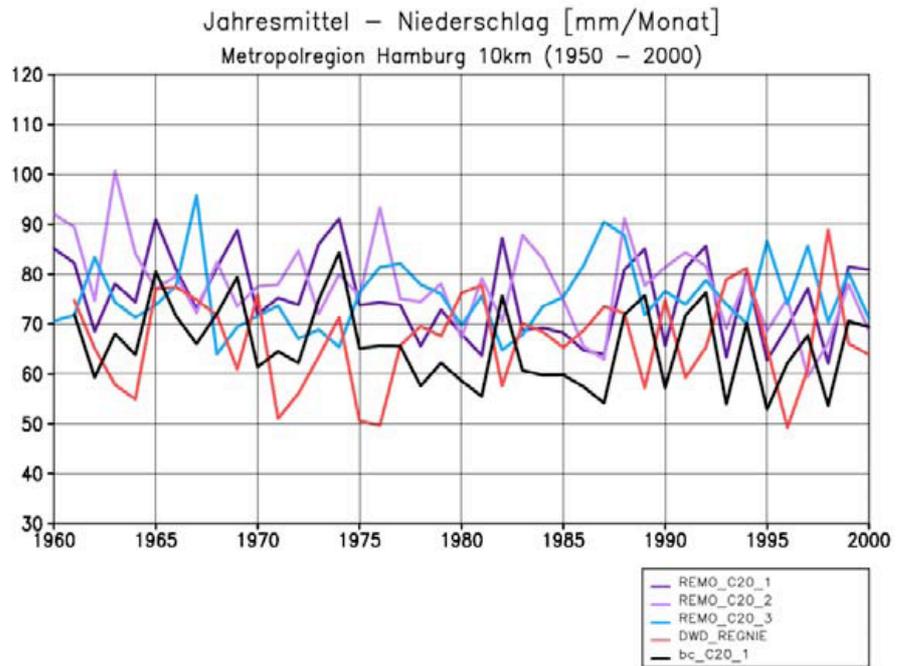
Piani C, Haerter JO, Coppola E (2010) Statistical bias correction for daily precipitation in regional climate models over Europe. *Theoretical and Applied Climatology* 99:187–192.

Kommentar von Douglas Maraun:

Die Methode der Wahl für viele Klimamodellierer ist derzeit das so genannte „Quantilmapping“ (QM), bei dem die Verteilungsfunktionen einer modellierten und der entsprechenden beobachteten Variablen in Beziehung gesetzt werden; mehr Details geben die beiden präsentierten Methoden. Das QM funktioniert vor allem dann gut, wenn der Fokus der Analyse auf dem mittleren Klima liegt und die Beobachtungsdatenbasis gut ist. Für extreme Klimate, die in einem nicht-stationären Zusammenhang analysiert werden, ist die Methode allerdings weniger gut geeignet (Kallache et al. 2011). Eine wichtige Voraussetzung für die Anwendung von QM ist die Stationarität der Art des Bias, was insbesondere bei Analysen des zukünftigen Klimas verletzt sein könnte. Weiterhin sollte vermerkt werden, dass QM im Allgemeinen nicht für das Downscaling geeignet ist, da es eine deterministische Transformation darstellt, die jedem simulierten Wert aus dem Modell genau einen korrigierten Wert zuweist und daher keine kleinskalige Variabilität erzeugen kann, sondern nur systematisch falsche Variabilität auf der gleichen Flächenskala umskalieren kann. QM sollte daher nur für Klimamodellergebnisse und Beobachtungsdaten verwendet werden, die auf der gleichen Raum-Zeit-Skala vorliegen (Maraun, 2013)

5.4.1 Quantile-Mapping mit Transferfunktion

Übergeordnetes Ziel (Kategorie)	Bias-Korrektur
Verfahren	"Quantile-Mapping mit Transferfunktion"
Beschreibung + Literatur	<p>Statistische Korrektur systematischer Abweichungen von Klimamodelldaten mit beobachteten Klimadaten der Vergangenheit zur Anwendung in prozessbasierten Klimaimpaktmodellen</p> <p><i>PIANI, C., G.P. WEEDON, M. BEST, S.M. GOMES, P. VITERBO, S. HAGEMANN, J.O. HAERTER, 2010: Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models. Journal of Hydrology. 395, 199-215</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	z. B. Niederschlag, bodennahe Lufttemperatur, Globalstrahlung
Voraussetzungen für Anwendung	Ausreichend guter Beobachtungsdatensatz in täglicher Auflösung und entsprechend hoher räumlicher Auflösung. Zudem sollte der Beobachtungsdatensatz von ausreichender Länge sein, um sicherzustellen, dass der Modell-Bias nicht durch kurzfristige Variabilität zustande kommt.
Ergebnis / Interpretation	Täglich korrigierte Klimaparameter aus REMO- und CLM-Simulationen. Bei der Anwendung auf für die Zukunft projizierte Parameter ist zu beachten, dass das Klimaänderungssignal der Bias-korrigierten Daten von unkorrigierten Daten abweichen kann. Ob dies realistischer ist, kann nicht ausgesagt werden.
Bewertung	Bei der Anwendung Bias-Korrigierter Klimadaten ist zu beachten: 1. Verlust der "modell-internen" Konsistenz verschiedener Klimavariablen untereinander, 2. Mögliche Veränderung des Klimaänderungssignals durch die Bias-Korrektur, 3. Unsicherheiten durch Beobachtungsdaten und Methode (Gegenstand aktueller Forschungen).
Beispiel / Publikation	<p>Bias-Korrektur von Temperatur, Niederschlag, Globalstrahlung, Gefühlte Temperatur und Abfluss im Rahmen von KLIFF und KLIWAS (Mudelsee, M., D. Chirila, T. Deutschländer, C. Döring, J.O. Haerter, S. Hagemann, H. Hoffmann, D. Jacob, P. Krahe, G. Lohmann, C. Moseley, E. Nilson, O. Panferov, T. Rath, B. Tinz, 2010: Climate Model Bias Correction und die Deutsche Anpassungsstrategie. Mitteilungen der Deutschen Meteorologischen Gesellschaft 03/2010.</p> <p>Beispiel Metropolregion Hamburg: Jahreswerte (oben) und Klimatologie (unten) des Niederschlags simuliert mit REMO in den 3 Realisierungen des Kontrollklimas 1961-2000 sowie Bias korrigierter Niederschlag der 1. Realisierung des Kontrollklimas (bc_C20_1) mit REGNIE-Daten des DWD:</p>



Kontakt / Projekt

Diana Rechid; Christopher Moseley
MPI für Meteorologie
diana.rechid@zmaw.de, christopher.moseley@zmaw.de
KLIMZUG NORD; KLIFF

5.4.2 Modifiziertes Quantile-Mapping

Übergeordnetes Ziel (Kategorie)	Bias-Korrektur
Verfahren	Modifiziertes Quantile Mapping
Beschreibung + Literatur	<i>Basis: Quantile Mapping nach Piani C., Haerter J. O and Coppala E. (2010). Statistical bias correction for daily precipitation in regional climate models over Europe. Theor. Appl. Climatol. 99, 187-192;</i> <i>Themeßl, M.J., Gobiet, A., Leuprecht, A. (2011): Empirical-statistical downscaling and error correction of daily precipitation from regional climate models. Int. J. Climatol., 31, 1530-1544.</i>
Geeignet für (Parameter, zeitl. Auflösung)	Niederschlag, Tageswerte; Anwendungen in der Wasser- und Siedlungswasserwirtschaft
Voraussetzungen für Anwendung	Für einen Referenzzeitraum müssen neben den Modelldaten auch Messdaten vorliegen
Ergebnis / Interpretation	Es erfolgt für Tageswerte eine Anpassung an folgende wasserwirtschaftlich relevante Parameter / Kenngrößen: Trockentage / -phasen, Monats- und Jahresniederschlagssummen, Verteilung der Niederschlagsklassen (Tageswerte), Starkregentage. Es erfolgt eine differenzierte Betrachtung für Tagesniederschlagssummen unterhalb und oberhalb des 97%-Quantils. Bis 97%-Quantil: Quantile Mapping, differenziert nach Kalendermonaten; ab 97%-Quantil: Bereichsweise lineare Regression für hydrologische Halbjahre. Für den Gesamtdatensatz gilt: Korrektur um einen „Trockenwert“ zur Unterdrückung sehr kleiner Tagessummen; Zusammenfassung räumlich benachbarter Rasterfelder mit ähnlichen Eigenschaften; gemeinsame Betrachtung von beiden CLM-Realisierungen. Die funktionalen Zusammenhänge des Referenzzeitraum werden auf zukünftige Untersuchungszeiträume übertragen
Bewertung	Im Referenzzeitraum werden alle genannten Parameter / Kenngrößen realitätsnah angepasst. Durch die Anpassung an Punktdaten sind die korrigierten CLM-Daten ebenfalls wie Punktdaten zu interpretieren. Im Hinblick auf die Anwendungen ist dies sinnvoll, da die wasserwirtschaftlichen Modelle bei Messdaten auch auf Punktdaten zurückgreifen. Der räumliche Bezug ist so zu interpretieren, dass die korrigierten CLM-Daten an jedem Punkt innerhalb des CLM-Rasterfeldes auftreten können (vergleichbare Interpretation wie bei KOSTRA-DWD-2000).
Beispiel / Publikation	<i>Quirnbach, M., Freistühler, E., Papadakis, I. (2012): „Bias-Korrektur der Niederschlagsdaten aus dem Regionalen Klimamodell CLM in der Emscher-Lippe-Region“, dynaklim-Publikation, No. 21, März 2012, http://www.dynaklim.de;</i> <i>Quirnbach, M.; Freistühler, E.; Papadakis, I., Pfister, A. (2012): „Analyse und Korrektur des systematischen Fehlers (Bias) in den Niederschlagsdaten des Regionalen Klimamodells CLM in der Emscher-Lippe-Region“, KW Korrespondenz Wasserwirtschaft, Jahrgang 5 (2012), Nr. 10, S. 544-555</i>
Kontakt / Projekt	Markus Quirnbach, dr. papadakis GmbH, Hattingen m.quirnbach@drpapadakis.de, KLIMZUG-Projekt <i>dynaklim</i>

5.5 Signifikanztests

Grundlage statistischer Schlussfolgerungen sind zwei wesentliche Konzepte: die Schätzung und der Signifikanztest. Letzterer, auch Hypothesentest genannt, bezeichnet im Zusammenhang dieser Broschüre die Untersuchung, ob eine Aussage über das Klimasystem der Wahrheit entspricht.

Allen Hypothesentests gemein ist eine etablierte statistische Prozedur. Nach Mudelsee (2010): Eine Nullhypothese, H_0 , wird formuliert. H_0 wird gegen eine alternative Hypothese H_1 getestet. Dabei schließen die Hypothesen H_0 und H_1 sich gegenseitig aus. Als nächstes wird eine Teststatistik, u , aus den Daten berechnet. Die Größe u ist eine Realisierung einer Zufallsvariablen mit Verteilungsfunktion $F_0(u)$, wobei „0“ bedeutet, dass u „gegeben H_0 “ berechnet wird, d.h. als ob H_0 wahr wäre. $F_0(u)$ wird Nullverteilung genannt. Der P-Wert ist die Wahrscheinlichkeit, dass, gegeben H_0 , ein Wert der Teststatistik existiert, der größer oder gleich dem beobachteten Wert u ist (einseitiger Test). Falls P klein ist, wird H_0 verworfen und H_1 akzeptiert, ansonsten kann H_0 nicht gegen H_1 verworfen werden. Bei einem zweiseitigen Test untersucht man die Absolutwerte für das beobachtete u und seine Verteilung gegeben H_0 . Die Wahl zwischen ein- und zweiseitigen Tests hängt von der jeweiligen Fragestellung ab. So würde sich beispielsweise im Falle eines Vergleichs der Mittelwerte zweier Stichproben ein einseitiger Test auf H_0 „gleiche Mittelwerte“ und H_1 „Mittelwert der ersten Stichprobe ist größer als der der zweiten“ beziehen und ein zweiseitiger Test auf die gleiche H_0 , aber H_1 „ungleiche Mittelwerte“.

Das vorgestellte Bootstrap-Verfahren zum Testen der Signifikanz (Abschnitt 5.5.5) leitet $F_0(u)$ mithilfe einer rechnergestützten Resampling-Methode her, statt Annahmen zu treffen (z.B. zur Form der Verteilung), die in der klimatologischen Praxis verletzt sein könnten. Das Verhältnis zwischen Trend und Rauschen (z.B. eines Klimaveränderungssignals) stellt eine intuitive Testmethode aus der Physik dar (Abschnitt 5.5.1). Das zweite vorgestellte Verfahren ist ein nicht-parametrischer Test für den Trend nach Mann und Kendall (Abschnitt 5.5.2), der häufig in den Klimawissenschaften sowie in anderen Disziplinen Anwendung findet. Weitere Tests werden beschrieben (Abschnitte 5.5.3, 5.5.4 und 5.5.6).

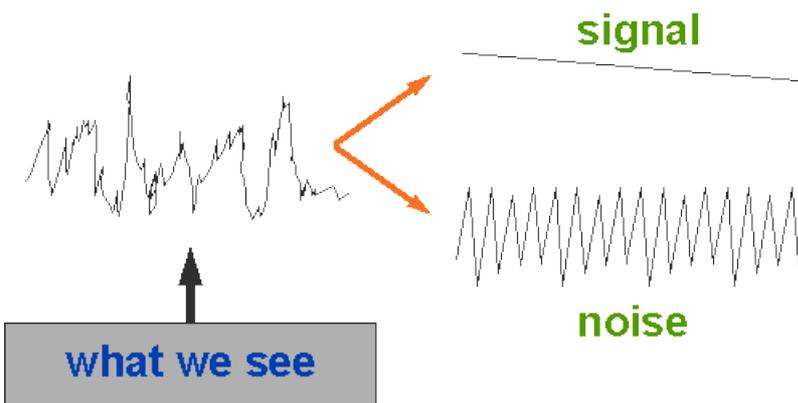
Literatur. Ein Klassiker der Statistik ist das Buch von Lehmann und Romano (2005). Wenn das Niveau hierin etwas zu anspruchsvoll ist, sollte man von Storch und Zwiers (1999) heranziehen. Das Buch von Mudelsee (2010) enthält einen Abschnitt über Bootstrap-Hypothesentests.

Lehmann EL, Romano JP (2005) Testing Statistical Hypotheses. 3 edn., Springer, New York, 784 pp.

Mudelsee M (2010) Climate Time Series Analysis: Classical Statistical and Bootstrap Methods. Springer, Dordrecht, 474 pp.

von Storch H, Zwiers FW (1999) Statistical Analysis in Climate Research. Cambridge University Press, Cambridge, 484 pp.

5.5.1 Trend-Rauschverhältnis

Übergeordnetes Ziel (Kategorie)	Signifikanztest (für lineare Trends)
Verfahren	Trend-Rauschverhältnis – T/R
Beschreibung + Literatur	Prüfung auf Signifikanz durch die Analyse der Stärke des Trendsignals Trend (T) / Standardabweichung(Rauschen) (R) Trend > Standardabweichung(Rauschen) d.h. $T/R > 1$ <i>Schönwiese (2006⁴): Praktische Methoden für Meteorologen und Geowissenschaftler, 232-234. Stuttgart</i>
Geeignet für (Parameter, zeitl. Auflösung)	Daten/Zeitreihen mit einem linearen Trend
Voraussetzungen für Anwendung	(annähernd) normalverteilte Daten linearer Trend lange Zeitreihen (http://www.kliwa.de/download/Verfahren.pdf)
Ergebnis / Interpretation	$T/R > 1$ d.h. signifikanter Trend von $p = \text{mind. } 70\%$ p bzw. α werden aus Tabelle abgelesen <i>Schönwiese (2006⁴): Praktische Methoden für Meteorologen und Geowissenschaftler, 98. Stuttgart</i>
Bewertung	einfacher & unkomplizierter Signifikanztest für lineare Trends schwacher Entscheidungstest (http://www.kliwa.de/download/Verfahren.pdf)
Beispiel	<p>What we observe can be divided into:</p>  <p>http://www.socialresearchmethods.net/kb/Assets/images/expclas1.gif</p> <p><i>Schableger (1996): Statistische Analysen klimatologischer Zeitreihen. Historical Social Research, 21, 3, 4-33.</i> http://hsr-trans.zhsf.uni-koeln.de/hsrretro/docs/artikel/hsr/hsr1996_395.pdf</p> <p><i>Kabas (2005): Das Klima in Südosterreich 1961-2004.</i></p>

	<i>Wissenschaftlicher Bericht Nr.4-2005.</i> <i>http://www.uni-graz.at/igam7www_wcv-wissber-nr4-tkabas-okt2005.pdf</i>
Kontakt / Projekt	Andreas Kochanowski Andreas_kochanowski@gmx.de

5.5.2 Mann-Kendall-Test

Übergeordnetes Ziel (Kategorie)	Signifikanz von Trends
Verfahren	Mann-Kendall-Test
Beschreibung + Literatur	Verteilungsunabhängiger Trendtest, bei dem die positive/negative Entwicklung aufeinander folgender Werte betrachtet wird
Geeignet für (Parameter, zeitl. Auflösung)	Grundsätzlich alle Dauerstufen des Niederschlages; Kennwerte des Niederschlages und der Temperatur
Voraussetzungen für Anwendung	Es müssen mindestens 10 Werte vorliegen
Ergebnis / Interpretation	Änderung eines Parameters über die Zeit mit Angabe der Signifikanz möglich
Bewertung	Die Änderungen können über die Signifikanz oder relativ über den Vergleich mehrerer Untersuchungen (z. B. an verschiedenen Niederschlagsstationen) bewertet werden. Eine praktisch vorstellbare Änderung (z. B. mm/a) liefert dieses Verfahren nicht.
Beispiel / Publikation	ExUS – Studie des Landes NRW (LANUV NRW)
Kontakt / Projekt	Markus Quirnbach dr. papadakis GmbH, Hattingen M.Quirnbach@drpapadakis.de KLIMZUG-Projekt DYNAKLIM, ExUS

5.5.3 Cox-Lewis Test

Übergeordnetes Ziel (Kategorie)	Signifikanztests
Verfahren	Cox–Lewis-Test
Beschreibung + Literatur	<p>Der Cox–Lewis-Test gehört zum Bereich Extremwertanalyse (ABSCHNITT ANALYSE VON EXTREMWERTEN). Er betrifft die zeitabhängige Auftrittsratenkurve $\lambda(T)$, worin T die Zeit ist, für einen nichthomogenen Poisson-Punktprozess (ABSCHNITT NICHTSTATIONÄRE EXTREMWERTANALYSE AUF BASIS EINES NICHTHOMOGENEN POISSON-PUNKTPROZESSES).</p> <p>Die getestete Nullhypothese basiert auf einem logistischen Modell für $\lambda(T)$ und ist gegeben durch H_0: “$\lambda(T)$ ist konstant.” Die Statistik U, um dies zu testen (Cox und Lewis 1966), ist gegeben durch</p> $U = \frac{\sum_{j=1}^m T_{\text{out}}(j) / m - [T(n) + T(1)] / 2}{[T(n) - T(1)] (12m)^{-1/2}},$ <p>worin j ein Index ist, m die Anzahl von Extremereignissen, T_{out} das Datum eines Ereignisses, n die Gesamtdatenanzahl und $[T(1); T(n)]$ das Beobachtungsintervall. Es kann gezeigt werden, dass unter H_0 die Größe U mit wachsendem m rasch standardnormalverteilt wird, was eine einfache Berechnung des P-Wertes erlaubt.</p> <p>Cox DR, Lewis PAW (1966) The Statistical Analysis of Series of Events. Methuen, London, 285 pp.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Alle Parameter bei beliebiger Zeitauflösung.
Voraussetzungen für Anwendung	Unabhängige Ereignis-Zeitpunkte.
Ergebnis/Interpretation	Signifikanz des Hypothesentests (welcher hilft, die Nullhypothese zu akzeptieren oder nicht).
Bewertung	Einfacher Test. Monte-Carlo-Experimente (Mudelsee 2010) zeigten die Überlegenheit (Power) des Cox–Lewis-Tests gegenüber dem Mann–Kendall-Test (ABSCHNITT MANN–KENDALL-TEST), um Nichtstationaritäten im Auftreten von Extremereignissen zu untersuchen.
Beispiel/Publikation	<p>Der Cox–Lewis-Test wurde von Mudelsee et al. (2003) verwendet, um Trends im Auftreten extremer Flusshochwasser zu bekräftigen (SIEHE AUCH ABSCHNITT NICHTSTATIONÄRE EXTREMWERTANALYSE AUF BASIS EINES NICHTHOMOGENEN POISSON-PUNKTPROZESSES).</p> <p><i>Mudelsee M (2010) Climate Time Series Analysis: Classical Statistical and Bootstrap Methods. Springer, Dordrecht, 474 pp.</i></p> <p><i>Mudelsee M, Börngen M, Tetzlaff G, Grünewald U (2003) No upward trends in the occurrence of extreme floods in central Europe. Nature 425:166–169.</i></p>

Kontakt/Projekt	Manfred Mudelsee Climate Risk Analysis, Hannover, Germany; mudelsee@climate-risk-analysis.com www.climate-risk-analysis.com
-----------------	--

5.5.4 Kolmogoroff-Smirnoff Test

Übergeordnetes Ziel (Kategorie)	Signifikanztests (Bestimmung der passenden Verteilung)
Verfahren	Kolmogoroff-Smirnoff Test
Beschreibung + Literatur	<p>Der Kolmogoroff-Smirnoff-Test ist statistischer Test, der eine empirische Verteilungsfunktion $S_n(x)$ mit einer spezifischen Verteilungsfunktion $P(x)$ vergleicht. Es wird getestet, ob die Abweichung der beiden Verteilungen voneinander signifikant ist.</p> <p>Von Storch und Zwiers (1999): Statistical Analysis in Climate Research, Cambridge University Press.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Prinzipiell sämtliche Parameter, z.B. hydrographische oder meteorologische Daten.
Voraussetzungen für Anwendung	Eine unabhängige Folge von identisch verteilten Zufallsvariablen mit stetiger Verteilungsfunktion $S(x)$.
Ergebnis / Interpretation	<p>Die Kolmogoroff-Smirnoff Test-Statistik $D = \max S_n(x) - P(x)$, für alle $-\infty < x < \infty$</p> <p>Bestimmt die maximale absolute Differenz zwischen der empirischen und der spezifischen kumulativen Verteilung. Die Vermutung das $P(x)$ die richtige (als Beschreibung geeignete) Verteilungsfunktion ist, wird als wiederlegt betrachtet, wenn D zu groß ist.</p> <p>Für genügend großes n ergibt sich aus der Kolmogoroffschen Verteilungsfunktion K für $\sqrt{n} * d = 1.36$ der Funktionswert 0.95, also: $P(D_n(X_1, \dots, X_n) > 1.36/\sqrt{n}) \approx 0.05$.</p> <p>Bei richtiger Vermutung treten Abweichungen $> 1.36/\sqrt{n}$ nur mit einer Wahrscheinlichkeit von ungefähr 0.05 auf.</p>
Bewertung	Der Kologoroff-Smirnoff-Test ist einfach anzuwenden und wird häufig von Software angeboten.
Beispiel	<p>Ein sehr gutes Beispiel auf Deutsch: Jürgen Lehn und Helmut Wegmann (2004): Einführung in die Statistik, 4. Auflage, Teubner, Seiten: 98-105, Teubner</p> <p>Auf Englisch mit Abbildungen und Fortran Code: Press, W. H., S.A. Teukolsky, W.T. Vettering und B.P. Flannery (1992): Numerical recipes in Fortran 77, Cambridge University Press. Seiten 617-622.</p>
Kontakt / Projekt	Katharina Bülow, KLIWAS, Bundesamt für Seeschifffahrt und Hydrographie, katharina.buelow@bsh.de.
ggf. Software	Der Fortran Code des Kolmogoroff-Smirnoff-Tests ist kurz und übersichtlich. Er wird häufig in Software angeboten, z.B. Matlab und R-Project bieten auch den kstest an.

5.5.5 Bootstrap-Hypothesis Test

Übergeordnetes Ziel (Kategorie)	Signifikanztestst
Verfahren	Bootstrap-Hypothesis Test
Beschreibung +Literatur	<p>Bootstrapping ist in der Statistik eine Methode des Resampling. Dabei werden wiederholt Statistiken auf der Grundlage lediglich einer Stichprobe parametrisch oder nicht-parametrisch berechnet und eine Verteilung dieser erstellt (die sogenannte Nullverteilung).</p> <p>In der Regel wird dabei eine statistische Kennzahl eines Samples mit einer durch Resampling gewonnenen Verteilung der Statistiken verglichen. Dabei wird Signifikanz festgestellt, indem die sample-Statistik mit besonderen Quantilen (je nach Signifikanzlevel) der durch Bootstrapping erstellten Verteilung verglichen wird.</p> <p><i>Climate Time Series Analysis, Mudelsee, 2010, pp 74-77</i></p>
Geeignet für (Parameter, zeitl.Auflösung)	Verwendung finden Bootstrap-Methoden, wenn die theoretische Verteilung der interessierenden Statistik unbekannt ist, oder parametrische Verfahren nicht erwünscht sind.
Voraussetzungen für Anwendung	Erstellung einer Nullverteilung ist abhängig von Problemstellung. Im Allgemeinen entspricht die Nullverteilung der Nullhypothese. Es muss darauf geachtet werden, dass bei Erstellung der Nullverteilung die ursprünglichen Eigenschaften der Daten nicht zerstört werden. Beispielsweise muss Autokorrelation berücksichtigt werden. Dafür bieten sich speziellere Formen des Bootstrappings, wie der Block-Bootstrap, an.
Ergebnis Interpretation	Signifikanz einer Statistik kann festgestellt werden (also die Nullhypothese des Signifikanztestes abgelehnt werden), wenn die Teststatistik größer als das Quantil der Nullverteilung ist, das dem Signifikanzlevel entspricht.
Bewertung	Zwar liefert dieses Verfahren Ergebnisse, die wünschenswerterweise unabhängig von teilweise zwingenden Voraussetzungen sind, aber kann auch kompliziert in der Anwendung sein. Zudem kann, je nach Konzept und Umfang der benutzten Bootstrapping-Methode, dieses Verfahren sehr rechenintensiv sein.
Beispiel	Signifikanztest von Korrelationen
Kontakt / Projekt	Oliver Krüger Helmholtz-Zentrum Geesthacht Institut für Küstenforschung Oliver.krueger@hzg.de

5.5.6 Parametrischer Test (z-Test)

Übergeordnetes Ziel (Kategorie)	Signifikanztest
Verfahren	Parametrischer Test (z-Test)
Beschreibung + Literatur	<p>Parametrische Tests (z-, t- und F-Test) gehören zu statistischen Testverfahren, die der Entscheidung von statistischen Hypothesen dienen und eine bestimmte Verteilung (z.B. Normalverteilung) der zu prüfenden Variablen voraussetzen. Durch einen Hypothesentest kann z.B. die Signifikanz eines Unterschieds zwischen zu vergleichenden Maßzahlen (z.B. Mittelwerte, Häufigkeiten, Varianzen) zweier Stichproben geprüft werden. Für die Prüfung auf Signifikanz eines Unterschieds zwischen z.B. Mittelwerten und Häufigkeiten eignen sich der z- bzw. t-Test, während der F-Test für den Vergleich von Varianzen eingesetzt wird. Bei allen parametrischen Testverfahren gilt, dass ein signifikanter Unterschied unter der Annahme einer bestimmten Irrtumswahrscheinlichkeit α besteht, wenn die berechnete Testgröße größer oder gleich dem zugehörigen Tafelwert ist. Allgemeines Vorgehen bei einem Hypothesen-/Signifikanztest:</p> <ol style="list-style-type: none"> Formulierung von Null- (H_0) und Alternativhypothese (H_1) Auswahl der statistischen Prüfgröße (Teststatistik) Festlegung des Signifikanzniveaus Berechnung der Teststatistik und Entscheidung über Akzeptanz oder Ablehnung der Nullhypothese (H_0) <p>Literatur (Auszug): Butler, C. (1985): Statistics in Linguistics. Web-Edition, http://www.uwe.ac.uk/hlss/llas/statistics-in-linguistics/bkindex.shtml (zuletzt abgerufen am 27.06.2013), University of West England, Bristol.</p>
Geeignet für (Parameter, zeitl. Auflösung)	beliebige Parameter, z.B. Seegangsdaten oder meteorologische Daten (Wind)
Voraussetzungen für Anwendung	Normalverteilung der Variable (hier Differenzen der relativen Häufigkeiten) sowie unabhängige und große Stichprobe ($N > 30$).
Ergebnis / Interpretation	Entscheidung der statistischen Hypothese (Ablehnung oder Akzeptanz der Nullhypothese) und damit Bestätigung bzw. Ablehnung der Signifikanz des Unterschieds zwischen z.B. den relativen Häufigkeiten (oder auch Mittelwerten).
Bewertung	Einfache, robuste Methode für einen klassischen Signifikanztest. Der Test sagt jedoch nichts über die Stärke des Unterschieds/Zusammenhangs aus. Bei kleinem Standardfehler (z.B. geringe Streuung der Daten und/oder großer Stichprobenumfang; wie es z.B. bei numerischen Modellergebnissen der Fall ist) wird die Signifikanz unabhängig vom Test fast immer nachgewiesen.
Beispiel	Anwendung des z-Tests zum Testen auf Signifikanz des Unterschieds zwischen zwei relativen Häufigkeiten p_A und p_B : a) Formulierung von Null- (H_0) und Alternativhypothese

(H_1)

$$H_0: p_A = p_B \quad H_1: p_A \neq p_B$$

b) Empirischen z-Wert berechnen

$$z_{calc} = \frac{p_A - p_B}{Stderr_{A,B}}$$

$$Stderr_{A,B} = \sqrt{\frac{p_A(1-p_A)}{N_A} + \frac{p_B(1-p_B)}{N_B}}$$

mit N = Anzahl der Elemente der Stichprobe

c) Irrtumswahrscheinlichkeit/Signifikanzniveau festlegen:

$$\alpha = 0.05$$

c) Ablesen des kritischen z-Wertes (Tafelwert aus Tabelle der Normalverteilung) und Entscheidung über Akzeptanz oder Ablehnung der Nullhypothese (H_0)

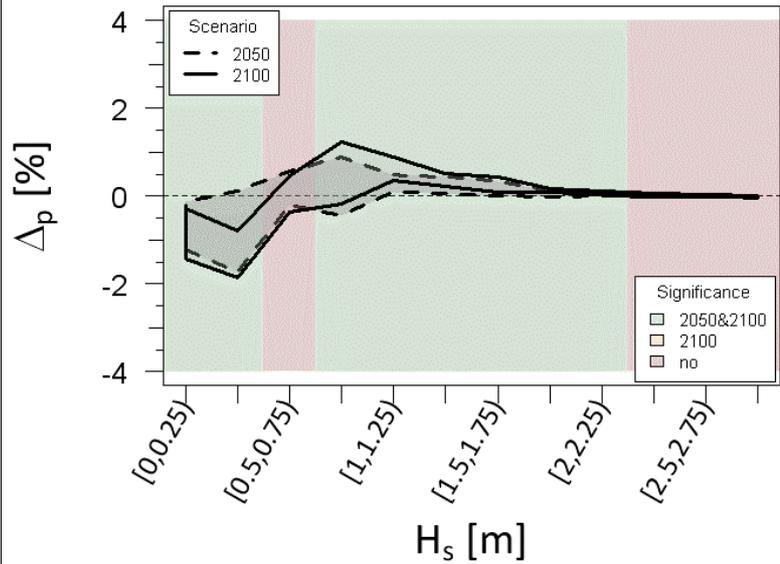
$$z_{crit} = q.\text{norm}(\alpha) \approx 1.65$$

$$z_{calc} \geq z_{crit} \quad \text{Ablehnung der Null-Hypothese } (H_0) \text{ und Annahme der Alternativhy. } (H_1)$$

$$z_{calc} < z_{crit} \quad \text{Bestätigung der Null-Hypothese } (H_0)$$

Beispiel:

Statistische Bewertung der Veränderung relativer Häufigkeiten ($\Delta p[\%]$) von berechneten signifikanten Wellenhöhen ($H_s[\text{m}]$) an der Küste von Warnemünde für zwei Szenarien 2050 (2001-2050) & 2100 (2071-2100) auf Grundlage von Daten des regionalen Klimamodells Cosmo-CLM, für die IPCC Emissionsszenarien A1B und B1, verglichen mit aktuellen Bedingungen (C20 im Zeitraum 1971-2000).



Interpretation der Ergebnisse:

In den grün markierten Bereichen ist die relative Veränderung der Häufigkeiten für Wellenhöhen $H_s < 0,5\text{m}$ und $0,75\text{m} \leq H_s < 2,25\text{m}$ zur Mitte (2021-2050) und zum Ende des 21. Jh. (2071-2100) signifikant (unter Annahme einer Irrtumswahrscheinlichkeit von 5%) im Vergleich zur Vergangenheit (1971-2000). In den roten Bereichen konnte demgegenüber keine statistische Signifikanz nachgewiesen werden.

Kontakt / Projekt

Norman Dreier, Institut für Wasserbau, Technische Universität Hamburg-Harburg, norman.dreier@tuhh.de,
 Christian Schlamkow, Geotechnik und Küstenwasserbau, Universität Rostock, christian.schlamkow@uni-rostock.de

5.6 Regionalisierung

Die Verfeinerung räumlicher Information von Ergebnissen grob aufgelöster Klimamodelle wird Downscaling genannt. Dazu gibt es zwei verschiedene Arten von Methoden: das dynamische Downscaling mithilfe regionaler Klimamodelle mit höherer räumlicher Auflösung und das statistische Downscaling, bei dem statistische Modelle zwischen Globalmodell-ergebnissen und Beobachtungsdaten geschaltet werden. Zudem besteht oft die Notwendigkeit, dass die Ergebnisse von Regionalmodellen für Impactmodellierung weiter verfeinert werden müssen. Es werden zwei Verfahren zum statistischen Downscaling vorgeschlagen (Abschnitte 5.6.1.1 und 5.6.1.2). Bei der vorgestellten Methode (5.6.1.1) wird statistisches Downscaling mit linearen Modellen angewendet.

Angenommen, man hat Datenwerte einer Variablen an einigen Punkten einer bestimmten Dimension und möchte die Werte an den fehlenden Punkten wissen. Die mathematischen Methoden zur Bestimmung der fehlenden Werte nennt man Interpolationsverfahren.

Die hier vorgestellten Verfahren behandeln den zweidimensionalen geographischen Raum (geographische Länge und Breite), der das Feld der Geostatistik charakterisiert. Diese Methoden haben eine große Relevanz für die Analyse von räumlichen Klimamodell-ergebnissen.

Auch in einer zweidimensionalen Situation ist die einfachste Methode die lineare Interpolation (Abschnitt 5.6.2). Interpolation kann als datenbasiertes Schätzproblem angesehen werden. Dabei ist es ratsam, eine Gewichtung des Beitrags der Datenpunkte zu der Schätzung vorzunehmen, die invers proportional ist zu der Distanz zwischen dem zu untersuchenden Punkt und einem Datenpunkt (5.6.2.2 und 5.6.2.3). Die interpolierte Kurve (z.B. in der zweidimensionalen Ebene) könnte Einschränkungen bezüglich der Differenzierbarkeit der Daten unterworfen sein, was durch die Spline-Interpolation gelöst wird (5.6.2.4). Eine weitere, fortgeschrittene, Methode ist das so genannte Kriging, bei dem räumliche Abhängigkeiten berücksichtigt werden (Abschnitt 5.6.2.5).

Literatur. Die beiden IPCC-Reports und (Christensen et al. 2007) und das ENSEMBLES EU-Projekt (van der Linden and Mitchell 2009) sind umfassend und frei zugänglich; sie sind als Einführung geeignet. Ein leicht zugängliches Buch zur Interpolation und Geostatistik aus der Perspektive von Geologen wurde von Davis (1986) verfasst. Eine aus statistischer Sicht detailliertere, aber immer noch lesbare Perspektive findet sich in Diggle und Ribeiro (2007) sowie Cressie und Wikle (2011).

Christensen JH, Hewitson B, Busuioc A, Chen A, Gao X, Held I, Jones R, Kolli RK, Kwon W-T, Laprise R, Magaña Rueda V, Mearns L, Menéndez CG, Räisänen J, Rinke A, Sarr A, Whetton P (2007) Regional climate projections. In: Solomon S, Qin D, Manning M, Marquis M, Averyt K, Tignor MMB, Miller HLeR Jr, Chen Z (Eds.) *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 University Press, Cambridge, 847–940.

Cressie N, Wikle CK (2011) *Statistics for Spatio-Temporal Data*. Wiley, Hoboken, NJ, 588 pp.

Davis JC (1986) *Statistics and Data Analysis in Geology*. 2 edn., Wiley, New York., 646 pp.

Diggle PJ, Ribeiro Jr PJ (2007) *Model-based Geostatistics*. Springer, New York, 228 pp.

van der Linden P, Mitchell JFB (Eds.) *ENSEMBLES: Climate change and its impacts at seasonal, decadal and centennial timescales*. Met Office Hadley Centre, Exeter, 160 pp.

5.6.1 Downscaling

5.6.1.1 Statistisches Downscaling mit linearen statistischen Modellen

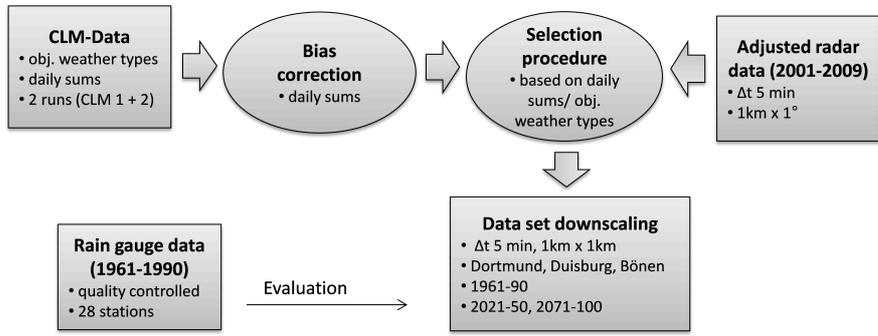
Übergeordnetes Ziel (Kategorie)	Regionalisierung
Verfahren	Statistisches Downscaling von Klimaprognosen mit Hilfe von linearen statistischen Modellen
Beschreibung + Literatur	Ein statistisches Modell für eine Zielgröße wird erstellt. Diese basiert auf den statistischen Zusammenhang zwischen der Zielgrößen (Predictand) und von der Zielgröße unabhängigen meteorologischen Größen (Predictoren). Die Modellparameter können mit multipler linearer Regression berechnet werden. Hierfür gibt es verschiedene Verfahren (z.B. generalized least squares). Als Datengrundlage dienen dabei Messungen der jeweiligen Größen. Um die Zielgröße in der Zukunft zu bestimmen müssen die unabhängigen Größen aus den Klimamodellen bestimmt werden. Anschließend können diese dann in das statistische Modell eingesetzt werden um die Änderung der Zielgröße durch den Klimawandel zu bestimmen.
Geeignet für (Parameter, zeitl. Auflösung)	Wärmeinselintensität, Luftqualität, Mortalität
Voraussetzungen für Anwendung	Statistischer Zusammenhang zwischen der Zielgröße und den unabhängigen Größen; es wird angenommen, dass sich dieser Zusammenhang in einen zukünftigen Klima nicht ändert, was oftmals nicht erfüllt sein könnte; Modellparameter müssen mit Beobachtungsdaten bestimmt und wenn möglich auch getestet werden
Ergebnis / Interpretation	Man erhält ein statistisches Modell für die eine Zielgröße. Durch Einsetzen der Klimamodelldaten in die Modellgleichungen kann die Änderung der Zielgröße aufgrund der Klimaänderung bestimmt werden. Da aber das statistische Modell meist nur zum Teil das Verhalten der Zielgröße beschreiben kann, sind die Änderungssignale nur mit Vorsicht zu betrachten.
Bewertung	
Beispiel / Publikation	<i>Hoffmann et al. (2011) für die städtische Wärmeinsel von Hamburg, Muthers et al. (2010) für Mortalität in Wien, Wilby (2008) städtische Wärmeinsel und Luftqualität in London</i>
Kontakt / Projekt	Peter Hoffmann Universität Hamburg, Meteorologisches Institut peter.hoffmann@zmaw.de KLIMZUG NORD

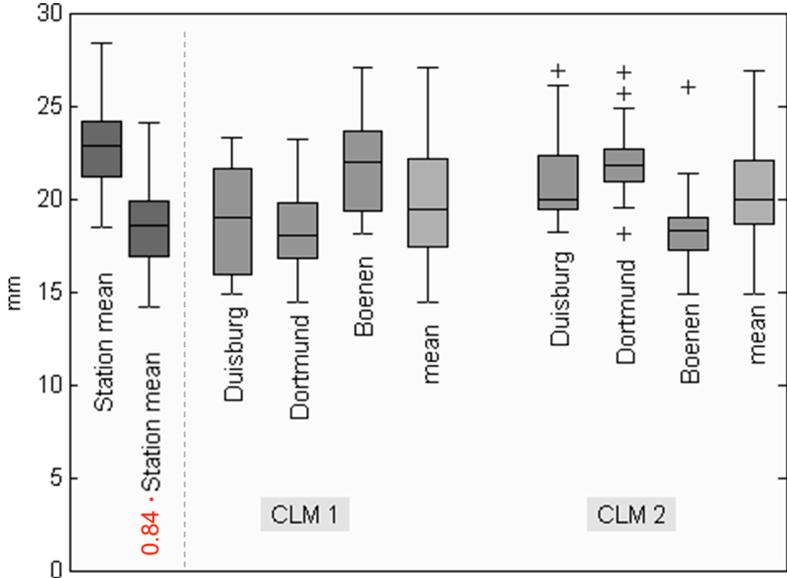
Hoffmann P., Krueger O., Schlünzen K.H. (2011): A statistical model for the urban heat island and its application to a climate change scenario. International Journal of Climatology (accepted)

Muthers, S.; Matzarakis, A.; Koch, E (2010). Climate Change and Mortality in Vienna—A Human Biometeorological Analysis Based on Regional Climate Modeling. Int. J. Environ. Res. Public Health, 7, 2965-2977

Wilby, R.L. (2008): Constructing climate change scenarios of urban heat island intensity and air quality. Environment and Planning B: Planning and Design, 35, 902-919.

5.6.1.2 Statistisches Downscaling von Niederschlägen

Übergeordnetes Ziel (Kategorie)	Regionalisierung Statistisches Downscaling von Niederschlägen
Verfahren	Analogverfahren/ Resampling von Niederschlagsdaten aus regionalen Klimamodellen unter Verwendung von Radardaten
Beschreibung	<p>Empirisches statistisches Downscaling-Verfahren: Auf Basis von Niederschlags-Tagessummen (räuml. Mittel über den RCM-Gitterpunkt) und objektiven Wetterlagenklassen (DWD) werden zu jedem Tag in den RCM-Daten ähnliche Tage im Beobachtungszeitraum ausgewählt. Die Messdaten der ausgewählten Tage werden zu synthetischen Zeitreihen zusammengesetzt. Die so erzeugten Zeitreihen bestehen abschnittsweise aus räumlich und zeitlich konsistenten Beobachtungsdaten. Übergänge von einem Zeitabschnitt zum nächsten sind hingegen nicht konsistent, so dass mehrtägige oder längere Ereignisse nicht abgebildet werden.</p> <p>Um die Auswahl der möglichen Ereignisse im Beobachtungszeitraum zu erhöhen, werden innerhalb des Untersuchungsgebietes Ereignisse räumlich verschoben. Damit werden kleinräumige orographische Effekte vernachlässigt. Wenn einzelne Ereignisse so hoch sind, dass es keine ähnlichen Ereignisse im Beobachtungszeitraum gibt, werden vorhandene niedrigere Ereignisse verwendet, die mit einem Faktor erhöht werden.</p> 
Geeignet für (Parameter, zeitl. Auflösung)	Niederschlagsdaten aus regionalen Klimamodellen, Auflösung z.B. 0.2°x0.2°, Tageswerte
Voraussetzungen für Anwendung	Beobachtungsdaten mit hoher räumlicher und zeitlicher Auflösung, z.B. korrigierte und angeeichte Radarmessungen über mindestens 10 Jahre (Auflösung 5 Min., 1km x 1km)
Ergebnis / Interpretation	Niederschlags-Zeitreihen bzw. Ereignisseries mit hoher räumlicher und zeitlicher Auflösung. Die zeitlich und räumlich aggregierten Werte entsprechen den Tageswerten aus dem RCM.
Bewertung	Empirisches statistisches Downscaling - für vorgegebene Ereignisdauern (hier < 1 Tag) werden Niederschläge mit einer natürlichen räumlichen und zeitlichen Struktur erzeugt. Die Daten können direkt als Input für hydrologische Modelle genutzt werden. Im Beispiel wurden realistische Extremwerte

	<p>(Wiederkehrzeit 5 Jahre) im Vergleich zu Beobachtungen produziert. Die Höhe von Niederschlagstrends wird im Wesentlichen durch Trends der Tageswerte im RCM bestimmt. Eine Kombination mit einer Bias-Korrektur der Tagessummen aus dem RCM (Piani et al., 2010) ist sinnvoll.</p>
<p>Beispiel / Literatur</p>	<p>Jasper-Tönnies, A., Einfalt, T., Quirnbach, M., Jessen, M. (2012). Statistical downscaling of CLM precipitation using adjusted radar data and objective weather types. 9th International Workshop on Precipitation in Urban Areas. 2012, St. Moritz, Switzerland.</p> <p>Beispiel: Downscaling von Niederschlagsdaten aus dem CLM Modell für drei Einzugsgebiete in Nordrhein-Westfalen</p>  <p>Validation: extreme precipitation [mm] for duration 1h, return period 5 years in the reference period (1961-1990) from downscaling results (3 catchments, 2 CLM runs), 28 quality-controlled rain gauge stations and rain gauge results multiplied by 0.84 to account for the different characteristic between radar and rain gauge data.</p>
<p>Kontakt / Projekt</p>	<p>Alrun Jasper-Tönnies (jasper-toennies@hydrometeo.de), Projekt dynaklim Thomas Einfalt (einfalt@hydrometeo.de), Projekt dynaklim</p>
<p>ggf. Software</p>	

5.6.2 Interpolation

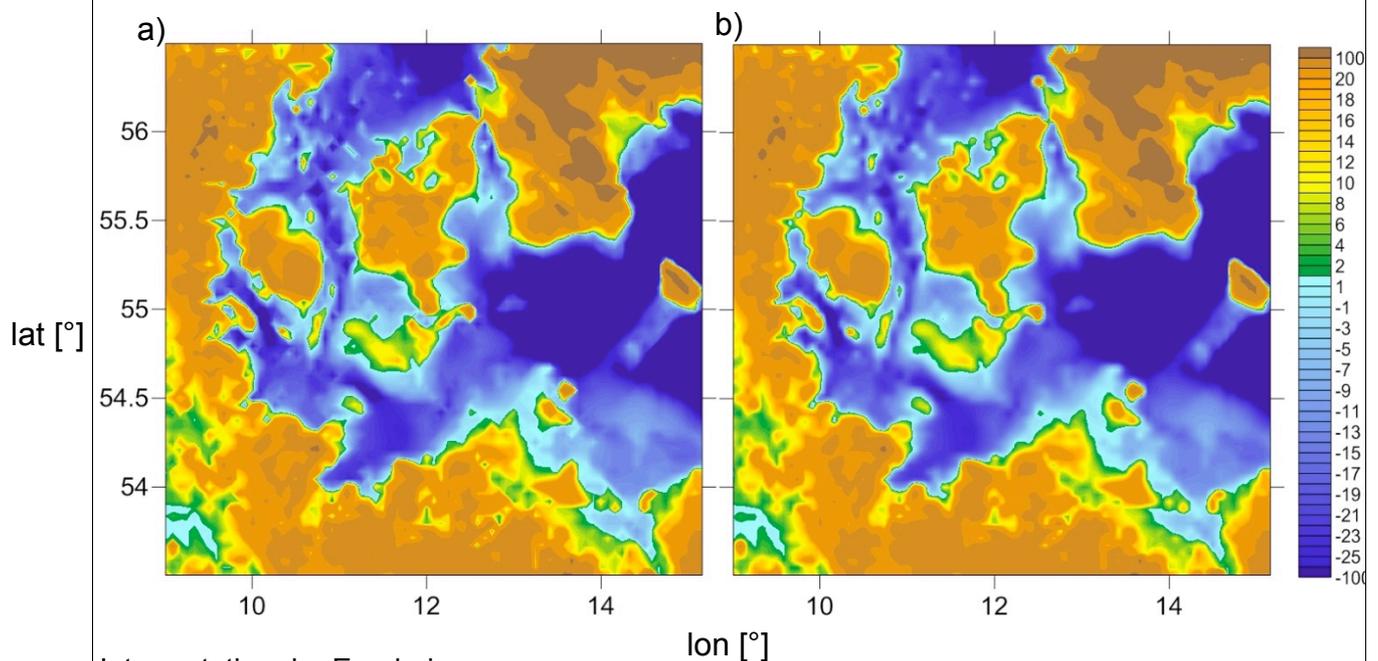
5.6.2.1 Bilineare Interpolation im Rastermodell

Übergeordnetes Ziel (Kategorie)	Regionalisierung
Verfahren	Bilineare Interpolation im Rastermodell
Beschreibung + Literatur	<p>Die Bilineare Interpolation (4 Stützstellen) ist eine in der Bildverarbeitung weit verbreitete Methode der zweidimensionalen Interpolation wie auch z.B. die Nearest-Neighbor- (1 Stützstelle) oder die Bikubische-Interpolation (16 Stützstellen). Das Verfahren beruht auf einer Hintereinander Ausführung von zwei linearen Interpolationen. Die Anzahl der Stützstellen ist ungefähr proportional zum Rechenaufwand. Eine Stützstellenminimierung durch z.B. lineare Interpolation durch Dreiecke (3 Stützstellen) in regelmäßigen, quadratischen Gittern ist möglich.</p> <p><i>Rosiuta, A. A. (2003.) Minimierung der Stützstellen zur Interpolation in dreidimensionalen Texturen, Studienarbeit, Fakultät für Informatik, Institut für Visualisierung und Interaktive Systeme, Universität Stuttgart, http://elib.uni-stuttgart.de/opus/volltexte/2003/1451/</i></p> <p>Zwischen den Punkten des Rasters (Spaltenindex j, Zeilenindex i) werden nach einer festgelegten Startrichtung (in Richtung j bzw. i) die erforderlichen Zwischenwerte durch lineare Interpolation bestimmt. Anschließend erfolgt die Bestimmung der Zwischenwerte in der entgegen gesetzten Richtung (i bzw. j) nach der gleichen Methode.</p> <p>Speziell: Halbiert man die Rasterweite des Ausgangsgitters, entsprechen die Zwischenwerte dem arithmetischen Mittel der Nachbarwerte.</p> <p>Bei der Interpolation von mehreren Punkten innerhalb einer Rasterzelle/Masche, muss jede Interpolationsgleichung erneut gelöst werden. Es existieren beschleunigte, effizientere Verfahren/Algorithmen zur bilinearen Interpolation, wie z.B. die flächenhafte bilineare Interpolation, dargestellt in:</p> <p><i>Behr, F. J. & Lutz, S. (1989): Ein schneller Algorithmus zur bilinearen Interpolation in Ankerpunktnetzen. Zeitschrift für Photogrammetrie und Fernerkundung, Bildmessung und Luftbildwesen, Heft 6, 57/1989, 222-229.</i></p> <p>weitere Literatur (Auszug):</p> <p><i>Streit, U.: Vorlesungen zur Geoinformatik, Kap. 7.4.4 Zweidimensionale räumliche Interpolation im Rastermodell, Institut für Geoinformatik der Universität Münster, http://ifgivor.uni-muenster.de/vorlesungen/Geoinformatik/kap/kap7/k07_4.htm</i></p> <p><i>Umbaugh S. E. (2010). Digital Image Processing and Analysis: Human and Computer Vision Applications with Cviptools. 2nd edition, Crc Pr Inc, 2010. 977p.</i></p>
Geeignet für	beliebige Parameter, wie z.B. meteorologische Daten (Wind,

(Parameter, zeitl. Auflösung)	Temperatur etc.), geografische Informationen (Höhendaten)
Voraussetzungen für Anwendung	zweidimensionales, reguläres Raster keine starken (nichtlinearen) Änderungen der interpolierten Größe im Interpolationsraum, z.B. bei Bathymetriedaten keine Steilwände oder Vorsprünge
Ergebnis / Interpretation	Es entsteht ein räumlich verfeinertes (alternativ auch gröberes) Raster der betrachteten Größe. Infolge der Interpolation kommt es jedoch zu keinem Informationsgewinn sondern lediglich Verfeinerung zu einer verbesserten optischen Darstellung. Weiterhin wird die Methode dazu angewendet, Daten auf unterschiedliche Gitterweiten abzubilden, um diese für numerische Simulationen nutzen zu können.
Bewertung	Einfach und schnelle Berechnung da nur arithmetische Grundoperationen verwendet werden. Am Rand des Gitters werden die Daten nur in eine Richtung interpoliert, was jedoch keinen Nachteil darstellt.

Beispiel:

Räumlich interpolierte Höheninformationen: Am Bsp. der Bathymetrie (Topografie des Meeresbodens) für die südwestliche Ostsee (IOW) wurde die Rasterweite des Originalgitters mit 75 Spalten x 73 Zeilen (vgl. Abb. a, $dx=5'$, $dy=5/2'$) durch bilineare Interpolation halbiert auf 150 Spalten x 146 Zeilen (vgl. Abb. b, $dx=5/2'$, $dy=5/4'$).



Interpretation der Ergebnisse:

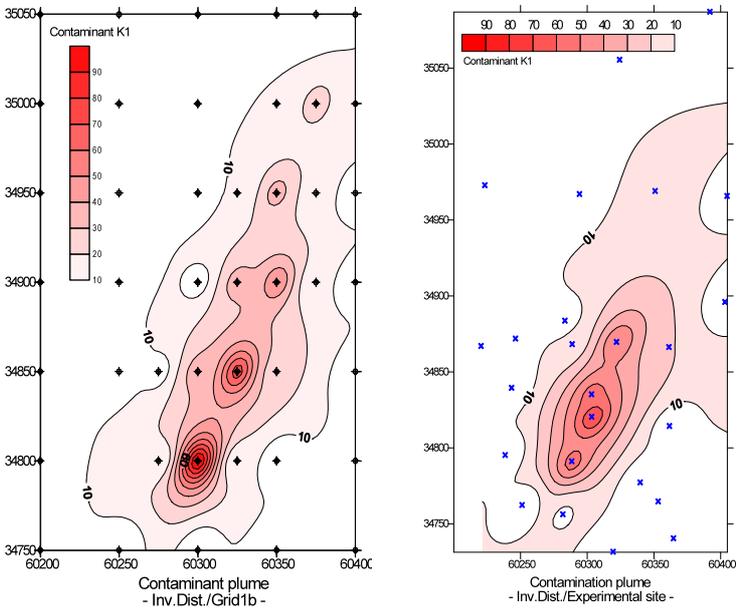
Abb. b) zeigt ein optisch geglättetes Bild, welches im vgl. zu Abb. a) weniger scharfe Konturen (Kanten) enthält.

Kontakt / Projekt

Norman Dreier, Institut für Wasserbau, Technische Universität Hamburg-Harburg, norman.dreier@tuhh.de

5.6.2.2 Inverse Distance Weighting

Übergeordnetes Ziel (Kategorie)	Regionalisierung
Verfahren	Inverse Distanzen Methode (räumliche Interpolation)
Beschreibung + Literatur	<p>Schätzung von Werten zwischen bekannten Datenpunkten (Messwerten). Jeder Messwert wird in Abhängigkeit von Abstand zur Lage des gesuchten Punktes gewichtet. Dabei entsteht ein größeres Gewicht, wenn der Messwert näher an dem gesuchten Punkt liegt. Die Interpolation ist mit einem Suchradius oder mit einer konstanten Anzahl nächstgelegener Nachbarn (nearest neighbours) möglich. Die Werte sowie die Lage der Messpunkte bleiben erhalten.</p> $w_i = \frac{1}{d_i^2}$ <p>w_i = Gewicht des Punkte: d_i^2 = Distanz zu x</p> $z(x) = \frac{\sum_i w_i z_i}{\sum_i w_i}$ <p>$z(x)$ = <i>der zu interpolierende Punkt im Raum</i> z_i = <i>bekannte Wert (z.B. Niederschlagsmenge) an Punkt i</i> w_i = <i>Gewicht</i></p> <p>Bonham-Carter, G. F. 1994. Geographic Information Systems for Geoscientists: Modeling with GIS. Pergamon/Elsevier Science Publications. 398 S. Bill, R. & D. Fritsch (1991): Grundlagen der Geo-Informationssysteme. Wichmann, Karlsruhe; Bd. 1: Hardware, Software und Daten. 429 S. Hartkamp et al. (1999): Interpolation Techniques for Climate Variables. Geographic Information Systems. Series 99-01.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Georeferenzierte Punktinformationen Angewendet auf verschiedene physikochemische Parameter: T, pH, eC, Wasserinhaltsstoffe
Voraussetzungen für Anwendung	Ausreichend Datenpunkte. Da das Verfahren nur den Abstand der Messdaten berücksichtigt, müssen relevante Kollektiveigenschaften (wasserundurchlässige Störungen, Wasserscheiden, verschiedene Grundwasserleiter etc.) im Vorfeld berücksichtigt werden, d.h. die Kollektive ggf. getrennt werden. Die Distanzen zwischen den Messwerten sollte nicht zu unterschiedlich sein, da ansonsten „bulls-eyes“-Strukturen entstehen
Ergebnis / Interpretation	Interpolierte Flächenverteilung. Ermöglicht eine einfache räumliche Darstellung der Messwerte, ohne Berücksichtigung von Heterogenitätseinflüssen.

	<p>Extremwerte werden nicht geglättet und bieten somit die Möglichkeit raumbezogene Einflüsse optisch zu erkennen.</p>
<p>Bewertung</p>	<p>Einfaches und schnelles Verfahren, mit dem man leicht Heterogenitäten (unterschiedliche Wassertypen, Stoffeinträge, etc.), erkennen kann. Ermöglicht auch bei ungünstiger Datengrundlage, bei dem statistische Interpolationsverfahren nicht einsetzbar sind, einen interpretierbaren räumlichen Überblick. Allerdings ist keine richtungsabhängige Gewichtung möglich, da gerichtete Zusammenhänge ignoriert werden. Von Vorteil für die Nutzung des Verfahrens ist eine hohe Messwertedichte mit homogener räumlicher Verteilung.</p>
<p>Beispiel</p>	<p>Nachfolgende Abbildungen zeigen regionalisierte Schadstoffverteilungen sog. Schadstoffplumen auf Basis eines Messstellenrasters (links) bzw. eines „normalen“ Messstellennetzes</p> <div style="display: flex; justify-content: space-around;">  </div> <p>BENDER, S. (2007): Die Aussageunschärfe bei der Verwendung heterogener Datensätze im Rahmen wasserwirtschaftlicher Fragestellungen. – Bochumer Geowissenschaftliche Arbeiten, Heft 8, 99 S.</p>
<p>Kontakt / Projekt</p>	<p>Steffen Bender Helmholtz-Zentrum Geesthacht, Climate Service Center Steffen.Bender@hzg.de Andreas Kochanowski andreas_kochanowski@gmx.de,</p>
<p>ggf. Software</p>	<p>In der Software Surfer (Golden Software, http://www.goldensoftware.com) als Verfahren integriert, mit der Möglichkeit verschiedene Einstellungen zu ändern.</p>

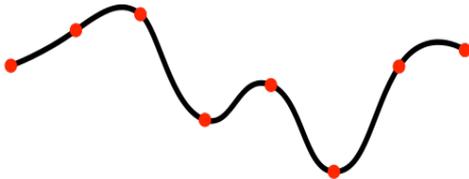
5.6.2.3 Lineare Regression mit Residueninterpolation mittels Inverse Distance Weighting

Übergeordnetes Ziel (Kategorie)	Regionalisierung (Interpolationsverfahren)
Verfahren	Lineare Regression mit Residueninterpolation mittels (IDW) (Inverse Distance Weighting)
Beschreibung + Literatur	<p>Unter Verwendung eines digitalen Höhenmodells wird für jede Rasterzelle der Schätzwert (Ergebnisfeld A) aus einer für den entsprechenden Zeitraum gültigen Höhenregression berechnet. Diese leitet sich aus den Messwerten der Messstationen und deren zugehörige Seehöhe ab.</p> <p>Zur Erhöhung der Erwartungstreue des Ergebnisses wurden die Residuen (rasterfeldbezogene Differenz aus Messwert der Stützstelle und Ergebnisfeld A) mittels IDW interpoliert (Ergebnisfeld B). Der resultierende Schätzwert errechnet sich durch eine rasterfeldbezogene Addition der korrespondierenden Ergebnisfelder A und B.</p>
Geeignet für (Parameter, zeitl. Auflösung)	angewendet auf verschiedene Klimaelemente, z. B. Temperatur, Niederschlag, Strahlung...
Voraussetzungen für Anwendung	hohe Stationsdichte und digitales Höhenmodell
Ergebnis / Interpretation	Für die entsprechenden stationsbasierten Klimaelemente Raster in der räumlichen Auflösung des Höhenmodells
Bewertung	Vorteil der Berücksichtigung verteilungsrelevanter Abhängigkeiten der Klimaelemente, z. B. Höhenabhängigkeit der Temperatur.
Beispiel	REGKLAM Heft 1 und 2 (Bernhofer et al., 2009 und 2011)
Kontakt / Projekt	Johannes Franke Technische Universität Dresden johannes.franke@tu-dresden.de KLIMZUG-Projekt: REGKLAM

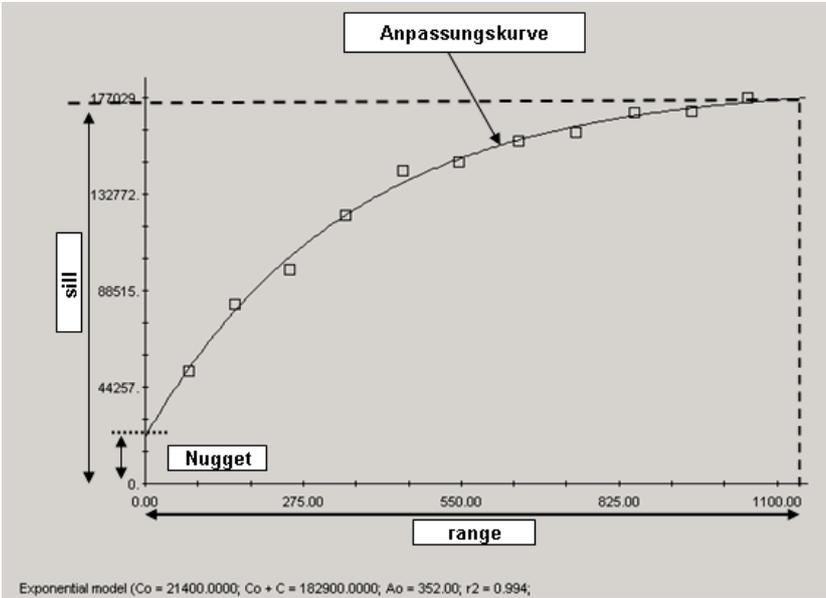
Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden

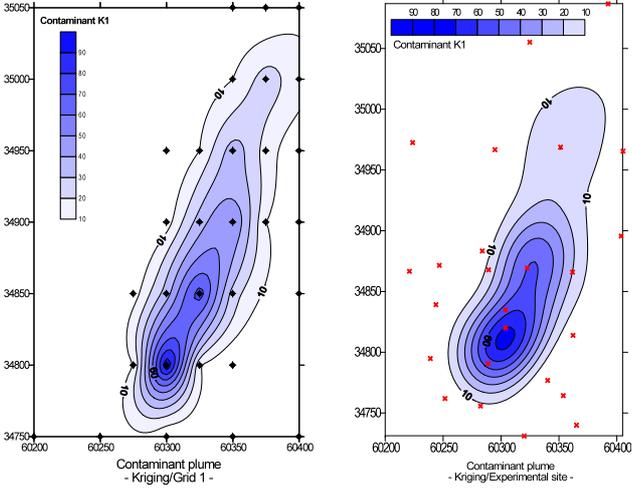
Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2009): Das Klima in der REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 1, Rhombos-Verlag Dresden

5.6.2.4 Splines

Übergeordnetes Ziel (Kategorie)	Regionalisierung (Interpolationsverfahren)
Verfahren	Splines
Beschreibung + Literatur	Erstellung einer Oberfläche mit minimaler Krümmung Interpolation durch Verwendung einer Serie unterschiedlicher Polynome (meist ≥ 3 . Ordnung) zwischen den einzelnen Datenpunkten <i>Burrough & McDonnell (2004): Principles of Geographical Information Systems. Oxford.</i> <i>Schumacher (2007³): Spline Functions: Basic Theory. New York.</i>
Geeignet für (Parameter, zeitl. Auflösung)	punktuell vorliegende Daten im Raum
Voraussetzungen für Anwendung	„ausreichend“ Datenpunkte (auch außerhalb des Betrachtungsgebietes – um Randgebiete zu interpolieren) W. Tobler „Erstes Gesetz der Geographie“ (siehe Inverse Distance Weighting - Steckbrief)
Ergebnis / Interpretation	Änderung des Funktionswertes einer Stützstelle hat nur lokale Auswirkungen Erhaltung kleinräumiger Eigenschaften durch stückweise Berechnung Problem bei scharfen Übergängen/Wechseln z.B. Temperaturinversion, Regenschatteneffekt Validierung über „Jack- Knife“ bzw. „Cross Validation“ Methode
Bewertung	keine Aussage über Qualität der Interpolation möglich
Beispiel	Splines mit 8 Knoten  <p>Beispielrechnung: http://www.arndt-bruenner.de/mathe/scripts/kubspline.htm#rechner gibt mehrere Abwandlungen z.B. Thin Plate Spline, Cubic Splines findet bei der Erstellung von digitalen Geländemodellen (DGM/DEM) Anwendung</p> <i>Tait et al. (2006): Thin plate smoothing spline interpolation of daily rainfall for New Zealand using a climatological rainfall surface. In: International Journal of Climatology, Vol. 26, 2097-2115.</i> <i>Hong et al. (2005): Spatial interpolation of monthly mean climate data for china. In: International Journal of Climatology, Vol. 25, 1369-1379.</i>
Kontakt / Projekt	Andreas Kochanowski Andreas_kochanowski@gmx.de

5.6.2.5 Kriging

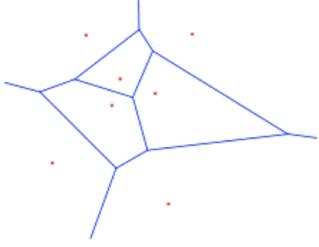
Übergeordnetes Ziel (Kategorie)	Regionalisierung (Interpolationsverfahren)
Verfahren	Ordinary Kriging (räumliche Interpolation)
Beschreibung + Literatur	<p>Geostatistisches Verfahren basierend auf der räumlichen Zusammengehörigkeit von Messpunkten; Schätzverfahren auf Basis kleinster Fehlerquadrate. Wichtung/Gewichtung erfolgt nicht ausschließlich über Distanz, sondern auch die Verteilung im Raum wird berücksichtigt</p> <p>Anwendung liefert die Semivarianz $\gamma(h)$, die den Grad der räumlichen Abhängigkeit zwischen Stichproben einer bestimmten Serie beschreibt. Werden die Semivarianzen für verschiedene Proben ermittelt, können diese als ein Semivariogramm dargestellt werden.</p> $\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} (Z(x_i) - Z(x_i + h))^2$ <p>$\gamma(h)$: Semivarianz zwischen x_i und x_i+h h: Abstand zwischen x_i und x_i+h $N(h)$ Anzahl Probenpaare im Abstand h $Z(x_i)$ Messwert am Punkt x_i $Z(x_i+h)$ Messwert am Punkt x_i+h</p>  <p>Aus: www.spatialanalysisonline.com</p> <p>Anpassung eines theoretischen Variogramms an das empirische Variogramm (Variogramm aus den errechneten Varianten). Kenngrößen sind hierbei: Sill (Maß für die Varianz der Messwerte), Range (Aussagereichweite, innerhalb dieses Bereichs ist die Interpolation sinnvoll) und Nugget(-Effekt) (Streuung des Signals im Nahbereich aufgrund kleinräumiger Heterogenitäten).</p>

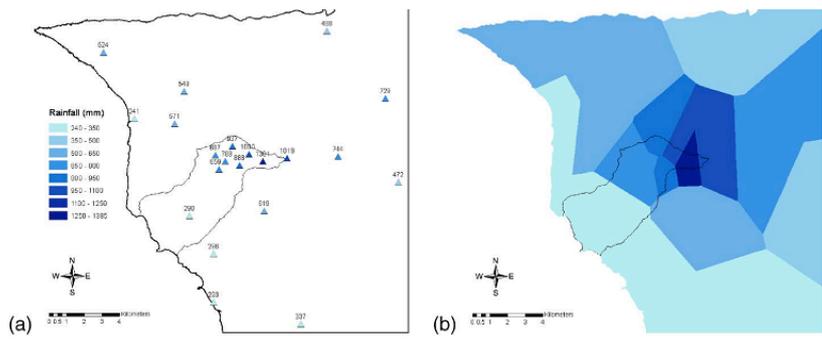
	<p>M.-T. Schafmeister(1999): Geostatistik für die hydrogeologische Praxis, 172 S. Webster & Oliver (2007²): Geostatistics for Environmental Scientists. Chichester. Stein (1999): Interpolation of Spatial Data: some theory for kriging. New York.</p>
Geeignet für (Parameter, zeitl. Auflösung)	<p>Georeferenzierte Punktinformationen Angewendet auf verschiedene physikochemische Parameter: T, pH, eC, Wasserinhaltsstoffe</p>
Voraussetzungen für Anwendung	<p>Ausreichend großer Datensatz Messwerte sind zufällig und räumlich festgelegt, d.h. die Schätzung der statistischen Parameter ist ortsunabhängig</p>
Ergebnis / Interpretation	<p>Semivariogramm liefert Informationen über den räumlichen Zusammenhang von Messpunkten. Da das Semivariogramm eine Entfernungsfunktion ist, ändern sich die Gewichtungen der Variablen mit der Distanz zu anderen Probepunkten. Durch die Nutzung von raumbezogenen Suchellipsen kann zusätzlich eine Richtungsabhängigkeit integriert werden.</p>
Bewertung	<p>Die Kenntnis der räumlichen Verteilung einer Variablen wird in das Verfahren miteinbezogen, dadurch wird die Schätzung optimiert und die Schätzfehlervarianz wird möglichst gering.</p> <p>Berücksichtigung von räumlichen Anisotropien möglich</p>
Beispiel	<p>Nachfolgende Abbildungen zeigen regionalisierte Schadstoffverteilungen sog. Schadstofffahnen auf Basis eines Messstellenrasters (links) bzw. eines „realen“ Messstellennetzes</p> <div style="display: flex; justify-content: space-around;">  </div> <p>BENDER, S. (2007): Die Aussageunschärfe bei der Verwendung heterogener Datensätze im Rahmen wasserwirtschaftlicher Fragestellungen. – Bochumer Geowissenschaftliche Arbeiten, Heft 8, 99 S.</p>
Kontakt / Projekt	<p>Steffen Bender Helmholtz-Zentrum Geesthacht, Climate Service Center Steffen.Bender@hzg.de, Andreas Kochanowski Andreas_kochanowski@gmx.de</p>

ggf. Software

In der Software Surfer (Golden Software, <http://www.goldensoftware.com>) als Verfahren integriert, mit vielen Auswahloptionen (Punkt- bzw. Block-Kriging, verschiedene Anpassungsoptionen, „Detrend-Option“, individuelle Suchellipsenparametrisierung)

5.6.2.6 Polygonmethode

Übergeordnetes Ziel (Kategorie)	Regionalisierung (Interpolationsverfahren)
Verfahren	Thiessen-Polygonmethode auch Voroni-Diagramm oder Dirchlet-Zerlegung
Beschreibung + Literatur	<p>Einfaches Interpolationsverfahren zur Darstellung georeferenzierter Messdaten. Basiert auf der Annahme: Daten sind umso ähnlicher je näher sie beisammen liegen</p> <p>Über eine Mittelsenkrechten-Konstruktion wird die Gesamtfläche in einzelne Polygonflächen (Regionen) eingeteilt, die durch einen Messort (Zentrum) bestimmt werden. Im Ergebnis liegt jeder Punkt in seinem Polygon dem zugehörigen Referenzpunkt (Zentrum) näher, als jedem anderen Zentrum.</p> <div style="text-align: center;"> $P = 1 / A_T \cdot \sum A_i P_i$  </div> <p>wobei A_i = Fläche eines Thiessen-Polygons um die Station i A_T = Gesamtfläche des Gebietes</p> <p>R. Klein (2005): <i>Algorithmische Geometrie</i>, Grundlagen, Methoden, Anwendungen, Springer, 426 S.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Das Verfahren eignet sich gut, um ein flächige Verteilung von diskreten Daten und nominalen Daten (Risiko: ja/nein) darzustellen. Bsp.: Im Flachland: Zuordnung von repräsentativen Flächen zu Niederschlagsmessern
Voraussetzungen für Anwendung	Messwertbeeinflussende Größen werden bei dem Verfahren nicht berücksichtigt. Bsp.: Bei der Zuweisung von repräsentativen Flächen auf Niederschlagsmessungen bleibt der Einfluss der Geländemorphologie unberücksichtigt.
Ergebnis / Interpretation	Gewichtetes Ergebnis unter Berücksichtigung einer ungleichmäßigen Stationsverteilung.
Bewertung	Das Verfahren bietet eine schlechte Näherung an Beobachtungsdaten. Da an den Polygongrenzen deutliche Wertesprünge auftreten, ist die Darstellung von kontinuierlichen Übergängen nicht möglich.
Beispiel	Nachfolgende Abbildungen zeigen Lage und Messwerte von Niederschlagsmessstationen (a) sowie eine Karte der räumlichen Niederschlagsverteilung basierend auf der Thiessen-Polygon-Methode (b) (Mair & Fares 2011)



Mair, A. & Fares, A. (2011): Comparison of Rainfall Interpolation Methods in a Mountainous Region of a Tropical Island. – Journal of hydrologic engineering, 371-383

Kontakt / Projekt	Steffen Bender Helmholtz-Zentrum Geesthacht, Climate Service Center Steffen.Bender@hzg.de
ggf. Software	In der Software Surfer (Golden Software, http://www.goldensoftware.com) als Verfahren integriert.

5.7 Analyse von Extremwerten

In bestimmten Fällen ist man an den extremen Werten einer klimatischen Zeitreihe aus Klimamodellsimulationen oder Beobachtungsdaten interessiert. Grundsätzlich gibt es zwei verschiedene Arten, diese zu bestimmen: Bei der ersten Methode (Abschnitt 5.7.1.1) nimmt man aus den Daten jeweils die Maxima von Zeitblöcken festgelegter Länge und untersucht anschließend nur diese Maxima. Bei der anderen Methode wird ein hoher Grenzwert gewählt und alle Daten oberhalb hiervon zur Analyse herangezogen. In Abschnitt 5.7.1.2 wird letzteres Verfahren, genannt "Peaks-over-threshold" (POT), für den Fall eines zeitlich konstanten Grenzwerts erläutert, in Abschnitt 5.7.1.3 für einen zeitlich variierenden Grenzwert. Dieser Fall ist auch empfehlenswert für die Analyse von nichtstationären Klimaprozessen.

Block Maxima folgen, unter bestimmten mathematischen Voraussetzungen, einer Generalisierten Extremwertverteilung (GEV), während Grenzwertüberschreitungen unter ähnlichen Annahmen einer Generalisierten Paretoverteilung (GPD) folgen. Augenscheinlich können selbige Methoden auch zur Analyse von extrem kleinen Werten einer Zeitreihe herangezogen werden, z.B. wenn man an Trockenperioden mit sehr wenig Niederschlag interessiert ist.

Die Mehrheit der wissenschaftlichen Artikel zu klimatischen Extremen nutzen Blockmaxima und die GEV, was sich auch in den hier vorgestellten Methoden widerspiegelt (Abschnitte 5.7.2 und 5.7.4). Dennoch finden sich auch einige Beispiele zum POT-Verfahren (Abschnitt 5.7.3).

Im Zusammenhang mit Klimaveränderungen ist es wichtig von stationären zu nichtstationären (zeitabhängigen) Methoden überzugehen, da mit dem Klimawandel auch Veränderungen im Risiko und Charakter der Extreme einhergehen können. Nichtstationäre Extremwertanalyse mit zeitabhängigen Parametern der GEV wird in Abschnitt 5.7.4.2 dargestellt. Eine robuste Alternative hierzu ist die Beschreibung durch einen inhomogenen Poisson-Punktprozess (Abschnitte 5.7.4.3).

Eine Kovariate, Y , enthält Information über das Extremwertverhalten einer zu untersuchenden klimatischen Variable, X . Die Simulation von Y mittels Klimamodelldaten, kann so die Risikoanalyse für X verbessern (Abschnitt 5.7.4.6). Von gesteigertem sozio-ökonomischen Interesse sind besonders die Fälle, in denen Extreme mehrerer Variablen zur gleichen Zeit auftreten (z.B. Springflut und Sturm), was theoretisch und mathematisch schwierig zu analysieren ist: Kopulas (Abschnitt 5.7.4.4) sind eine Option zur Lösung dieses Problems.

Literatur. Ein kurzes und lesbares Buch (Coles 2001) behandelt die GEV und die GPD, ihre Anpassung an Daten sowie diagnostische Darstellungen; auch die nichtstationären statistischen Modelle werden abgedeckt. Die theoretischen Konzepte sind mit mathematischer Genauigkeit bei Leadbetter et al. (1983) und Embrechts et al. (1997) beschrieben. In dem Buch von Mudelsee (2010) behandelt Kapitel 6 die stationäre und nichtstationäre Extremwertstatistik; dabei wird auch der Poisson-Punktprozess aus praktisch-analytischer Sicht beleuchtet und in Beispielen erläutert.

Coles S (2001) An Introduction to Statistical Modeling of Extreme Values. Springer, London, 208 pp.

Embrechts P, Klüppelberg C, Mikosch T (1997) Modelling Extremal Events for Insurance and Finance. Springer, Berlin, 648 pp.

Leadbetter MR, Lindgren G, Rootzén H (1983) Extremes and Related Properties of Random Sequences and Processes. Springer, New York, 336 pp.

Mudelsee M (2010) Climate Time Series Analysis: Classical Statistical and Bootstrap Methods. Springer, Dordrecht, 474 pp.

5.7.1 Auswahlverfahren

5.7.1.1 Block Maxima

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Auswahlverfahren (Block-Maxima)
Beschreibung + Literatur	<p>Verfahren zur Auswahl einer Stichprobe für die Extremwertanalyse von Zeitreihen. Bei der Methode werden Maximalwerte in zeitlichen Abschnitten (z.B. Jahre, Monate, Wochen), den sogenannten Blöcken, ausgewählt und zu einer Stichprobe zusammengefügt. An die Stichprobe können dann Extremwertverteilungen (wie z.B. GEV - generalisierte Extremwertverteilung, Log-Normal-, Gumbel- oder Weibullverteilung etc.) angepasst werden.</p> <p>Eine Erweiterung des Verfahrens besteht darin, mehrere (r-) Maxima innerhalb eines Blocks auszuwählen.</p> <p>Literatur (Auszug): <i>Embrechts, P., Klüppelberg, C. & Mikosch, T. (1997). Modelling Extremal Events. Vol. 33 of Applications in Mathematics. Springer-Verlag, New York.</i></p> <p><i>Coles, S. (2001). An Introduction to Statistical Modelling of Extreme Values. Springer Series in Statistics. Springer Verlag, London, 2001, 208p.</i></p> <p><i>Soukissian, T.H., Kalantzi, G. (2009). A new method for applying the r-largest maxima model for design sea-state prediction. International Journal of Offshore and Polar Engineering, Vol. 19, No. 3, September 2009, ISSN 1053-5381, 176–182.</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	Alle Parameter mit zeitlich konstanter Auflösung. Bei langen Zeitreihen können längere Abschnitte (und somit weniger Blöcke) zur Ermittlung der Maxima herangezogen werden, wie z.B. Jahresmaxima. Bei kurzen Zeitreihen empfehlen sich kürzere Abschnitte (und somit mehrere Blöcke), wie z.B. Monatsmaxima.
Voraussetzungen für Anwendung	Gleichwertigkeit, Homogenität, Unabhängigkeit und Repräsentanz der Daten
Ergebnis / Interpretation	Stichprobe für die extremwertstatistische Auswertung.
Bewertung	Die Wahl der Blockgröße sowie die Anzahl der Maxima innerhalb eines Blocks (z.B. absolutes Maximum oder die r -größten Maxima) beeinflussen die Anpassung der Extremwertverteilungsfunktionen an die erzeugte Stichprobe. Bei kleiner Blockgröße (und somit großem Stichprobenumfang) ist die Unsicherheit bei der Parameterschätzung zwar geringer, die Abbildung der Maximalwerte durch die Extremwertverteilungsfunktion kann jedoch schlechter sein, da Daten ausgewählt werden, die in Wirklichkeit nicht extrem sind. Weiterhin ist darauf zu achten, dass die Daten der erzeugten Stichprobe unabhängig voneinander sind. Dies gilt besonders wenn mehrere (r -) Maxima innerhalb eines Blocks ausgewählt werden. Zur Gewährleistung der Unabhängigkeit kann z.B. ein zeitlicher Mindestabstand zwischen zwei Maxima definiert werden, der bei der Auswahl eingehalten werden muss.

Beispiel	<p>Angaben über z.B. Jahresmaxima von Wasserständen (entspricht per Definition dem Block-Maxima-Verfahren) in der Literatur, z.B.</p> <p><i>Deutsches Gewässerkundliches Jahrbuch (DGJ), Küstengebiet der Nordsee, Landesamt für Natur und Umwelt Schleswig-Holstein, Flintbek, ISSN 0340-5184.</i></p> <p><i>Deutsches Gewässerkundliches Jahrbuch (DGJ), Küstengebiet der Ostsee, Landesamt für Umwelt, Naturschutz und Geologie Mecklenburg-Vorpommern, Güstrow, ISSN 1434-2448.</i></p> <p>Für weitere Beispiele aus der Finanzwirtschaft siehe z.B.: <i>Woeste B. (2010). Eine Anwendung der Block Maxima Methode im Risikomanagement. Diplomarbeit, Mathematisches Institut für Statistik, Fachbereich Mathematik und Informatik, Westfälische Wilhelms-Universität Münster.</i></p>
Kontakt / Projekt	<p>Dörte Salecker & Norman Dreier, Institut für Wasserbau, Technische Universität Hamburg-Harburg, doerte.salecker@tuhh.de, norman.dreier@tuhh.de</p>

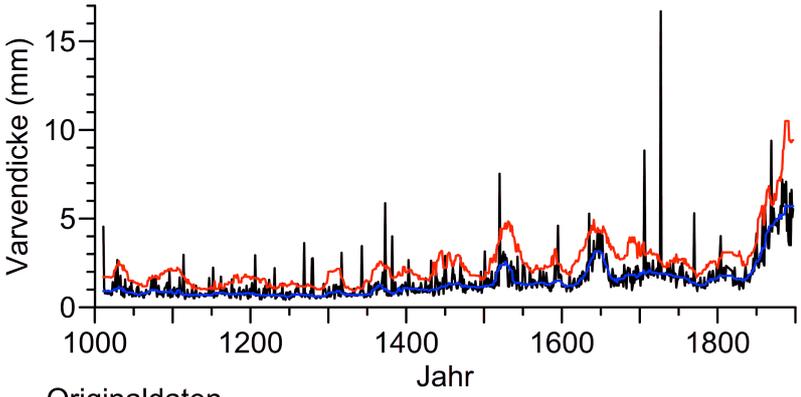
5.7.1.2 Peak over Threshold

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Auswahlverfahren (POT: Peak over Threshold)
Beschreibung + Literatur	<p>Verfahren zur Auswahl einer Stichprobe für die Extremwertanalyse. Bei der Methode werden Maximalwerte über einer Schwelle betrachtet. Der Schwellwert wird problemabhängig definiert und kann z.B. mittels Mean Excess Plot oder der Kolmogorov-Smirnov-Test (Siehe Abschnitt 5.5.4) bestimmt werden. An die Stichprobe können dann Extremwertverteilungen (wie z.B. GPD - die generalisierte Paretoverteilung, Log-Normal-, Gumbel- oder Weibullverteilung etc.) angepasst werden.</p> <p>Literatur (Auszug): <i>Embrechts, P., Klüppelberg, C. & Mikosch, T. (1997). Modelling Extremal Events. Vol. 33 of Applications in Mathematics. Springer-Verlag, New York.</i></p> <p><i>Coles, S. (2001.) An Introduction to Statistical Modelling of Extreme Values. Springer Series in Statistics. Springer Verlag, London, 2001, 208p</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	Alle Parameter mit zeitlich konstanter Auflösung
Voraussetzungen für Anwendung	Gleichwertigkeit, Homogenität, Unabhängigkeit und Repräsentanz der Daten
Ergebnis / Interpretation	Stichprobe für die extremwertstatistische Auswertung.
Bewertung	Die Schwierigkeit bei der Methode besteht in der Wahl des Schwellwerts. Dies entspricht in etwa der Problematik bei der Wahl der Blockgröße für die Block-Maxima-Methode. Auch hier gilt es die Unabhängigkeit der Daten der Stichprobe zu gewährleisten. Hierzu kann beispielsweise ein erforderlicher Zeitabstand oder eine untere Schwelle zwischen zwei Extremereignissen eingeführt werden, die unterschritten werden muss.
Beispiel	<p>Die Anwendung des Verfahrens in der Extremwertanalyse am Bsp. von Wasserständen wird im Abschnitt 5.7.4.5 (Extremwertstatistische Analyse univariater Datensätze mithilfe der Peak Over Threshold (POT) Methode) beschrieben. Definitionsmöglichkeiten von POT-Ereignissen am Beispiel von Seegangdaten finden sich z.B. in:</p> <p><i>Kuratorium für Forschung im Küsteningenieurwesen (2002): Die Küste - EAK 2002: Empfehlungen für die Ausführung von Küstenschutzwerken, Bd. 65, Westholsteinische Verlagsanstalt Boyens und Co., Heide i. Holstein. S. 283.</i></p> <p><i>Van Vledder, G., Goda, Y., Hawkes, P. J., Mansard, E., Martin, M. J., Mathiesen, M., Peltier, E. and Thompson, E. 1993. A case study of extreme wave analysis : a comparative analysis. WAVES'93, pp. 978-992.</i></p>

	<p><i>Piscopia, R., Inghilesi, R., Panizzo, A., Corsini, S. and Franco, L. (2002): Analysis of 12-year wave measurements by the italian wave network. In: Smith, J. Mckee. COASTAL ENGINEERING 2002: Solving Coastal Conundrums. Proceedings of the 28th International Conference, Cardiff, Wales, July 2002, pp 121-133.</i></p>
Kontakt / Projekt	<p>Dörte Salecker & Norman Dreier, Institut für Wasserbau, Technische Universität Hamburg-Harburg, doerte.salecker@tuhh.de, norman.dreier@tuhh.de</p>

5.7.1.3 Nichtstationäre Peaks over Threshold

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Nichtstationäre Peaks over Threshold
Beschreibung + Literatur	<p>Die Auswahl von Extremen mag in der Klimatologie manchmal realistischer durchgeführt werden, indem man einen zeitabhängigen "Hintergrund" einführt, dem eine zeitabhängige Variabilität überlagert ist. Diese nichtstationäre Situation führt dann natürlicherweise zu einem zeitabhängigen Schwellenwert, im Gegensatz zu einer stationären Situation mit einem konstanten Schwellenwert (Abschnitt 5.7.1.2).</p> <p>Die Methode sollte die Schätzung des zeitabhängigen Hintergrundes robust durchführen, das heißt unbeeinflusst durch das Vorhandensein der angenommenen Extreme. Deshalb verwendet man den gleitenden Median (berechnet über die Punkte innerhalb eines gleitenden Fensters) für eine nichtparametrische Hintergrund- oder Trendschätzung und nicht das gleitende Mittel. Analog hierzu verwendet man den gleitenden Median der Absolutdifferenzen zum Median (MAD) und nicht die gleitende Standardabweichung zur Variabilitätsschätzung. Kreuzvalidierungstechniken stellen eine Leitlinie zur Verfügung zur Wahl der Anzahl der Fenster-Punkte, indem sie die systematischen und statistischen Fehler optimal ausgleichen.</p> <p><i>Mudelsee M (2006) CLIM-X-DETECT: A Fortran 90 program for robust detection of extremes against a time-dependent background in climate records. Computers and Geosciences 32:141–144.</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	<p>Alle Parameter bei beliebiger Zeitauflösung.</p> <p>Es ist zu beachten, dass eine hohe Zeitauflösung eine starke Autokorrelation bewirken kann, was bei der Wahl der Anzahl der Fenster-Punkte zu berücksichtigen ist (d.h.: mehr Punkte sind dann heranzuziehen als bei Nicht-Autokorrelation).</p>
Voraussetzungen für Anwendung	Homogenität und Repräsentanz der Daten. Im Falle von Autokorrelation mag die Richtlinie durch Kreuzvalidierung weniger informativ sein, und es sollte mit unterschiedlichen Anzahlen von Fenster-Punkte gearbeitet werden.
Ergebnis/Interpretation	Stichprobe zur Analyse von Extremwerten (Generalized Pareto distribution, nichthomogener Poisson-Prozess)
Bewertung	Die Herausforderung der nichtstationären POT-Methode besteht in der Auswahl des Schwellenwertes und der Anzahl der Fenster-Punkte. Kreuzvalidierungs-Richtlinien mögen hilfreich sein, es ist jedoch unerlässlich, mit den Daten und Einstellungen zu "spielen" und die Sensitivität des Ergebnisses in Abhängigkeit von den gewählten Analyseparametern zu studieren (Schwellenwert, Anzahl Fenster-Punkte).

<p>Beispiel/Publikation</p>	 <p>— Originaldaten — Gleitender Median (17 Fenster-Punkte) — Gleitender Median + 5.2 x gleitender MAD (17 Fenster-Punkte)</p> <p>[Abbildung geändert nach Mudelsee (2010: Abb. 4.17); siehe auch Besonen et al. (2008)]</p> <p>Der Originalartikel (Mudelsee 2006) erläutert die Methode und beschreibt die Fortran-90-Software CLIM-X-DETECT. Diese Analyseverfahren ist in einer Reihe von Klimawandelanalysen eingesetzt worden, zum Beispiel beobachtete und modellierte Waldbrände im Zeitraum 1769–2100 (Girardin und Mudelsee 2008) oder Hurrikan-Proxydaten im Zeitraum 1000–1900 von einem Seesedimentkern (Besonen et al. 2008).</p> <p><i>Besonen MR, Bradley RS, Mudelsee M, Abbott MB, Francus P (2008) A 1,000-year, annually-resolved record of hurricane activity from Boston, Massachusetts. Geophysical Research Letters 35:L14705 (doi:10.1029/2008GL033950).</i></p> <p><i>Girardin MP, Mudelsee M (2008) Past and future changes in Canadian boreal wildfire activity. Ecological Applications 18:391–406.</i></p> <p><i>Mudelsee M (2010) Climate Time Series Analysis: Classical Statistical and Bootstrap Methods. Springer, Dordrecht, 474 pp.</i></p>
<p>Kontakt/Projekt</p>	<p>Manfred Mudelsee Climate Risk Analysis, Hannover, Germany; mudelsee@climate-risk-analysis.com www.climate-risk-analysis.com</p>

5.7.2 Parameterschätzung

5.7.2.1 Anpassung von extremwertstatistischen Verteilungsfunktionen mittels Maximum-Likelihood- oder Momenten-Methode

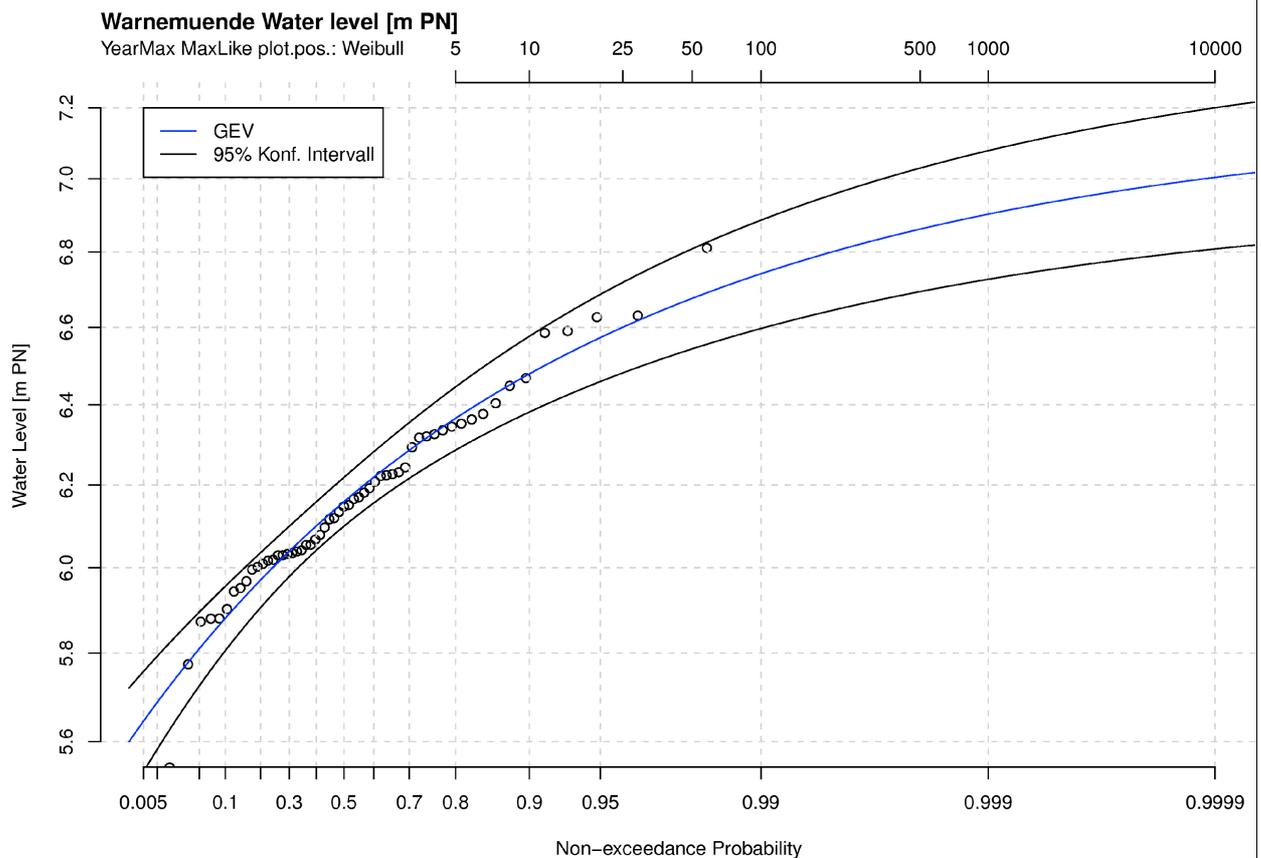
Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Extremwertanalyseverfahren: Parameterschätzung mittels Maximum-Likelihood-(MLE: maximum likelihood estimation) oder Momenten-Methode (MM: method of moments)
Beschreibung + Literatur	<p>Schätzung der Parameter von Extremwertverteilungen (z.B. GEV - generalisierte Extremwertverteilung, Log-Normal-, Gumbel- oder Weibullverteilung etc.) einer Stichprobe von Extremwerten (siehe Steckbriefe zu Auswahlverfahren Abschnitt 5.7.1).</p> <p><i>Momenten-Methode:</i> Die Momente der Stichprobe werden den entsprechenden Momenten der Verteilungsfunktion gleichgesetzt. Durch Umformung erhält man Schätzwerte der Parameter der Verteilungsfunktion.</p> <p><i>Maximum-Likelihood-Methode:</i> Die Likelihood-Funktion bzw. die Log-Likelihood-Funktion der Verteilungsfunktion wird aufgestellt, nach dem zu schätzenden Parameter abgeleitet und gleich Null gesetzt, damit die Likelihood-Funktion maximiert wird.</p> <p>Weitere Methoden zur Parameterschätzung sind z.B. Methode der wahrscheinlichen gewichteten Momente (PWM: probability weighted moments) oder L-Momente (LM: L-moments).</p> <p>Literatur (Auszug): <i>Kuratorium für Forschung im Küsteningenieurwesen (2002): Die Küste - EAK 2002: Empfehlungen für die Ausführung von Küstenschutzwerken, Bd. 65, Westholsteinische Verlagsanstalt Boyens und Co., Heide i. Holstein. S. 285-291.</i> <i>Coles, S. (2001). An Introduction to Statistical Modelling of Extreme Values. Springer Series in Statistics. Springer Verlag, London, 2001, 208p.</i> <i>Plate E.-J.: Statistik und angewandte Wahrscheinlichkeitslehre für Bauingenieure, Ernst & Sohn Verlag für Architektur und technische Wissenschaften, Berlin, 1993, ISBN 3-433-01073-0, S.20-22.</i> <i>Carter, D. J. T. & Challenor, P.G. Methods of Fitting the Fisher-Tippett Type 1 Extreme Value Distribution, Ocean Engineering (10), 1983, 191-199.</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	Stichprobe mit Extremwerten einer beliebigen Variable, die zuvor z.B. nach einem Auswahlverfahren (siehe Steckbriefe zu Auswahlverfahren XX) ermittelt wurden.
Voraussetzungen für Anwendung	Gleichwertigkeit, Homogenität, Unabhängigkeit und Repräsentanz der Daten
Ergebnis / Interpretation	Anpassungsparameter der jeweiligen Verteilungsfunktion

Bewertung

Die Momenten-Methode liefert gute Schätzwerte für die Verteilungsparameter, kann aber bei kleinen Stichproben und schiefen Verteilungen zu großen Schätzfehlern (BIAS) führen. Die Maximum- Likelihood-Methode führt zu kleinen Schätzfehlern für die Verteilungsfunktion. Oftmals ist die Berechnung nur numerisch zu lösen.

Beispiel:

Anpassung der generalisierten Extremwertverteilung (GEV, blaue Linie) an die jährlichen maximalen Wasserstände (dargestellt auf der Ordinate in Metern und bezogen auf den Pegel-Nullpunkt) mittels *Maximum- Likelihood-Methode* am Pegel Warnemünde. Weiterhin sind das obere und unter 95%-Konfidenzintervall (schwarze Linien) dargestellt.



Kontakt / Projekt

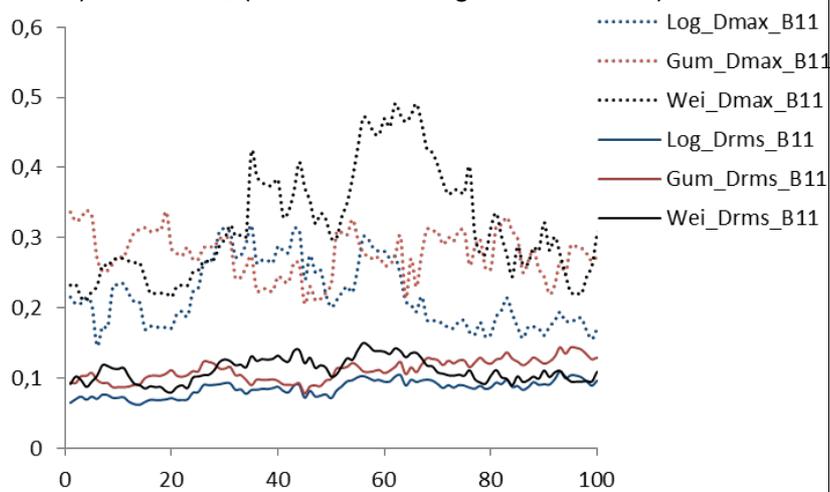
Dörte Salecker & Norman Dreier, Institut für Wasserbau,
Technische Universität Hamburg-Harburg,
doerte.salecker@tuhh.de, norman.dreier@tuhh.de

5.7.2.2 *R*-largest in Kombination mit einer GEV

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten Analyse von Sturmflut-Wasserständen
Verfahren	<i>R</i> -largest in Kombination mit einer GEV
Beschreibung + Literatur	Anwendung der Generalisierten Extremwert-Verteilung auf <i>r</i> Datenpunkte aus einem Block
Geeignet für (Parameter, zeitl. Auflösung)	Keine Einschränkungen
Voraussetzungen für Anwendung	1. Ereignisse sind unabhängig voneinander 2. die Anzahl (<i>r</i>) der Maxima innerhalb eines Blockes muss festgelegt werden
Ergebnis / Interpretation	
Bewertung	- Gut anzuwenden - robust - Es muss kein Grenzwert festgelegt werden
Beispiel / Publikation	<i>Smith, Richard L.: Extreme value theory based on the r largest annual events, Journal of Hydrology 86(1-2), 27–43, 1986</i> <i>Katz, Richard W, Parlange, Marc B, and Naveau, Philippe: Statistics of extremes in hydrology, Advances in Water Resources 25(8-12), 1287–1304, 2002</i> <i>Soares, C. G., and Scotto, M. G.: Application of the r largest-order statistics for long-term predictions of significant wave height, Coastal Engineering 51(5-6), 387–394, 2004</i>
Kontakt / Projekt	Ulf Gräwe Leibniz Institute for Baltic Sea Research Warnemuende ulf.graewe@io-warnemuende.de KLIMZUG-Projekt RADOST

5.7.2.3 Abstandsmaß zwischen empirischer und theoretischer Extremwert-Verteilungsfunktion (Kolmogorow-Smirnow-Lilliefors-Test)

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten (Goodness of fit/Anpassungstest)
Verfahren	Abstandsmaß (D-Value) zwischen empirischer und theoretischer Extremwertverteilungsfunktion (Kolmogorow-Smirnow-Lilliefors-Test)
Beschreibung + Literatur	<p>Das Konzept des Lilliefors-Tests basiert auf einem modifizierten Kolmogorow-Smirnow-(K-S)-Test (siehe Abschnitt 5.5.4). Anhand des Tests kann festgestellt werden, ob die Stichprobe einer an die Stichprobe angepassten Extremwertverteilung entspricht (Hypothesentest). Beim Lilliefors-Test werden für den Vergleich der berechneten Teststatistik mit einer Prüfgröße (kritische K-S-Werte KS_{crit}, die vom Signifikanzniveau / Irrtumswahrscheinlichkeit, der Anzahl der Daten sowie dem Formparameter der Verteilung abhängig sind) modifizierte Werte verwendet, welche z.B. durch Monte-Carlo-Simulationen ermittelt werden können. Für große Abstandsmaße ($D > KS_{crit}$) wird die Nullhypothese (dass die EDF der CDF entspricht) abgelehnt und die Daten entsprechen nicht der betrachteten Extremwert-Verteilung.</p> <p>An dieser Stelle wird der Test lediglich dazu verwendet, um die Anpassungsgüte mehrerer Extremwertverteilungsfunktionen an eine Stichprobe zu quantifizieren. Hierzu werden, wie beim K-S-Test, Abstandsmaße (z.B. maximaler Abstand D_{max} oder Root-Mean-Square-Abstand D_{rms}) zwischen der empirischen Verteilungsfunktion der Daten (EDF) und der an die Daten angepassten theoretischen Verteilungsfunktion (CDF, z.B. Log-Normal, Gumbel, Weibull-Verteilung etc.) bestimmt. Je kleiner das Abstandsmaß desto besser entspricht die angepasste Verteilungsfunktion der Stichprobe.</p> $D_{max} = \max_x F_n(x) - F(x) $ $D_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_n(x) - F(x))^2}$ $F_n(x_{(i)}) = i/n \quad i = 1, 2, \dots, n$ <p>$F_n(x)$: empirische Verteilungsfunktion (EDF) <i>i</i>: Rang der Daten der Stichprobe in aufsteigender Reihenfolge <i>n</i>: Anzahl der Elemente der Stichprobe $F(x)$: theoretische, angepasste Verteilungsfunktion (CDF)</p> <p>Literatur (Auszug): Chu, Pao-Shin, Jianxin Wang, 1998: Modeling Return Periods of Tropical Cyclone Intensities in the Vicinity of Hawaii*. J. Appl. Meteor., 37, 951–960.</p>

	<p>doi: <a href="http://dx.doi.org/10.1175/1520-0450(1998)037<0951:MRPOTC>2.0.CO;2">http://dx.doi.org/10.1175/1520-0450(1998)037<0951:MRPOTC>2.0.CO;2</p> <p>Wilks, Daniel S. Statistical methods in the atmospheric sciences / 3rd ed. (International geophysics series; v. 100). Academic Press, Elsevier, 2011, 151-154</p> <p>Lilliefors Test. In: Encyclopedia of Statistical Sciences. John Wiley & Sons, 2006, doi:10.1002/0471667196.ess1451.pub2</p>
Geeignet für (Parameter, zeitl. Auflösung)	beliebige Parameter, z.B. Seegangdaten (Wellenhöhen) oder meteorologische Daten (Windgeschwindigkeiten)
Voraussetzungen für Anwendung	Stichprobe unabhängiger Extremwerte einer Variable (siehe Steckbriefe zur Kategorie Extremwertstatistik/Auswahlverfahren: POT bzw. Block-Maxima) sowie an die Stichprobe angepasste Extremwertverteilungsfunktionen (siehe Steckbriefe zur Kategorie Extremwertstatistik/Parameterschätzung: z.B. Maximum-Likelihood oder Momenten-Methode)
Ergebnis / Interpretation	Abstandsmaß D_{rms} bzw. D_{max} und Entscheidung darüber, welche der Extremwertverteilungsfunktionen am besten an die Stichprobe angepasst ist (und somit das geringste Abstandsmaß aufweist).
Bewertung	Einfache, robuste Methode für den Vergleich unterschiedlicher angepasster Extremwert-Verteilungsfunktionen an die Stichprobe.
Beispiel	<p>Gleitende Auswahl von berechneten Wellenhöhen (Jahresmaxima in 40 Jahren) aus der Klima-Impaktmodellierung über einen Gesamtzeitraum von 100 Jahren (Abszisse) und Anpassung der Log-Normal-, Gumbel- und Weibull-Verteilungsfunktion an die Auswahl sowie Berechnung der Abstandsmaße D_{max} (Ordinate, gestrichelte Linien) sowie D_{rms} (Ordinate, durchgehende Linien).</p>  <p>Interpretation der Ergebnisse: Die Log-Normal-Verteilungsfunktion besitzt im Gesamtzeitraum von 100 Jahren meistens die geringsten Abstandsmaße (D_{max} sowie D_{rms}) und ist somit am besten an die jeweilige empirische Verteilungsfunktion angepasst.</p>

Kontakt / Projekt

Norman Dreier, Institut für Wasserbau, Technische Universität
Hamburg-Harburg, norman.dreier@tuhh.de
Zhen-shan Xu, College of Harbor, Coastal and Offshore
Engineering, Hohai University, Nanjing, P.R. China
xuzhenshanhhu@gmail.com

5.7.3 Empirische Methoden

5.7.3.1 Überschreitungswahrscheinlichkeit bzw. Wiederholungszeitspanne

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Überschreitungswahrscheinlichkeit bzw. Wiederholungszeitspanne von Hoch- und Niedrigwasserabflüssen in Fließgewässern bestimmen
Beschreibung + Literatur	<u>Hochwasserstatistiken:</u> Ermittlung von Hochwasserwahrscheinlichkeiten (August 2012); DWA-M 552 (2012), Statistische Analyse von Hochwasserabflüssen; DVWK Merkblatt 251 (1999), Empfehlung zur Berechnung der Hochwasserwahrscheinlichkeit, DVWK-Regel 101 (1976), DVWK Regel 121/1992: Niedrigwasseranalyse <u>Niederschlagsstatistiken:</u> ATV 121 1985: Starkniederschlagshöhen für Deutschland
Geeignet für (Parameter, zeitl. Auflösung)	Extremwerte von Hoch- und Niedrigwasserabflüssen mit möglichst hoher zeitlicher Auflösung Niederschlagsereignisse unterschiedlicher Dauerstufen
Voraussetzungen für Anwendung	Ereignisse müssen unabhängig voneinander sein (Einzelereignisse über einen Schwellenwert), zeitlich hochaufgelöste Niederschlagswerte für Spitzenabflusssimulationen: < 1h, Ausreichende Anzahl von Extremereignissen über einen möglichst langen Zeitraum
Ergebnis / Interpretation	Vergleich der Überschreitungswahrscheinlichkeit bzw. Wiederholungszeitspanne von Hoch- und Niedrigwasserereignissen in den Klimaszenarien Ermittlung von zeitlichen Trends im Auftreten von Hochwasserereignissen
Bewertung	Etabliertes Standardverfahren zur Berechnung von Hochwasserwahrscheinlichkeiten ermöglicht den Bezug zu anderen Projekten. Einfaches, praxisbewehrtes Verfahren.
Beispiel / Publikation	<i>Wasserbauschrift Band 13: S. Hellmers: Hydrological Impacts of Climate Change on Flood Probability in Small Urban Catchments and Possibilities of Flood Risk Mitigation, 2010 (Ebook) ISBN 978-3-937693-13-2</i>
Kontakt	Sandra Hellmers Technische Universität Hamburg-Harburg Institut für Wasserbau s.hellmers@tuhh.de KLIMZUG NORD

5.7.3.2 Schwellenwertstatistik, Empirische Überschreitungswahrscheinlichkeiten

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten (Verteilung, Extreme, Peak over Threshold – POT)
Verfahren	Schwellenwertstatistik, Empirische Überschreitungswahrscheinlichkeiten
Beschreibung + Literatur	Für ausgewählte Schwellenwerte wird innerhalb einer Zeitscheibe (z. B. 1961–1990, 2021–2050, 2071–2100) die Häufigkeit (empirische Wahrscheinlichkeit) seiner Erreichung bzw. Überschreitung berechnet. Anschließend können verschiedene Zeitscheiben hinsichtlich ihrer Überschreitungswahrscheinlichkeiten verglichen werden
Geeignet für (Parameter, zeitl. Auflösung)	verschiedene Klimaparameter wie Niederschlag, Temperatur, Wind, etc. sowie abgeleitete Kenngrößen z. B. Trockenperioden; verwendet für Tagesdaten (prinzipiell sind auch andere zeitliche Auflösungen wie h oder min denkbar)
Voraussetzungen für Anwendung	Als von der Verteilung der Daten unabhängiges Verfahren keinen besonderen Voraussetzungen unterliegend
Ergebnis / Interpretation	Sichtbarmachen von Veränderungen in der Verteilung der Daten sowie der Häufigkeit des Auftretens bestimmter Extremwerte
Bewertung	einfaches (geringer Rechenaufwand) empirisches Verfahren, v. a. im Hinblick auf die großen Unsicherheiten mit denen die Klimaprojektionen belegt sind sowie ihrer Schwierigkeiten die beobachteten Häufigkeitsverteilungen realistisch wiederzugeben
Beispiel	<i>REGKLAM Heft 1 und 2 (Bernhofer et al., 2009 und 2011)</i>
Kontakt / Projekt	Johannes Franke (TU Dresden), Stephanie Hänsel (TU BA Freiberg) johannes.franke@tu-dresden stephanie.haensel@ioez.tu-freiberg.de KLIMZUG-Projekt: REGKLAM

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2009): Das Klima in der REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 1, Rhombos-Verlag Dresden

5.7.4 Extremwertanalyseverfahren

5.7.4.1 Extremwertanalyse mit Allgemeiner Extremwertverteilung (GEV)

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Extremwertanalyse mit Allgemeiner Extremwertverteilung (GEV)
Beschreibung + Literatur	Bestimmung von der Überschreitungswahrscheinlichkeiten von Extremwerten (univariate Statistik)
Geeignet für (Parameter, zeitl. Auflösung)	Monats-/Jahres-Maxima bzw. –Minima, historische Extremereignisse
Voraussetzungen für Anwendung	Stationäre Zeitreihen (evtl. vorherige Trendkorrektur), voneinander unabhängige Daten
Ergebnis / Interpretation	Ergebnis ist eine univariate Wahrscheinlichkeitsverteilung, die eine Bestimmung der Eintrittswahrscheinlichkeiten von Extremereignissen ermöglicht.
Bewertung	Bei dem Verfahren ist darauf zu achten, dass die Daten stationäre sind oder zuvor in eine stationäre Zeitreihe überführt werden. Bei starken zeitlichen Trends ist die Aussagekraft der Ergebnisse eingeschränkt.
Beispiel / Publikation	<p><i>Mudersbach, Ch. and Jensen, J. (2009): Extremwertstatistische Analyse von historischen, beobachteten und modellierten Wasserständen an der Deutschen Ostseeküste, Die Küste, Heft 75, Sonderheft MUSTOK, S. 131-162, Boyens Medien GmbH, Heide i. Holstein</i></p> <p><i>Mudersbach, Ch. and Jensen, J. (2010): Non-stationary extreme value analysis of annual maximum water levels for designing coastal structures on the German North Sea coastline, Journal of Flood Risk Management, Vol. 3., Issue 1, pp. 52-62, DOI:10.1111/j.1753-318X.2009.01054.x</i></p>
Kontakt / Projekt	<p>Christoph Mudersbach Universität Siegen Forschungsinstitut Wasser und Umwelt christoph.mudersbach@uni-siegen.de</p>

5.7.4.2 Instationäre Extremwertanalyse mit Allgemeiner Extremwertverteilung

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Instationäre Extremwertanalyse mit Allgemeiner Extremwertverteilung (GEV)
Beschreibung + Literatur	Bestimmung der zeitlichen Entwicklung der Überschreitungswahrscheinlichkeiten (Trends) von Extremwerten (univariate Statistik)
Geeignet für (Parameter, zeitl. Auflösung)	Geeignet für Maxima bzw. –Minima aus Bezugszeiträumen (z.B. Monate oder Jahre), die einen Trend aufweisen
Voraussetzungen für Anwendung	voneinander unabhängige Daten
Ergebnis / Interpretation	Ergebnis ist eine univariate Wahrscheinlichkeitsverteilung, die sich über die Zeit ändert. Bei der Ergebnisdarstellung und -interpretation ist somit entscheidend, dass jeweils ein Zeitbezug mit angegeben wird.
Bewertung	Das Verfahren liefert für trendbehaftete Daten aussagekräftige Ergebnisse zu den zeitlichen Änderungen der Eintrittswahrscheinlichkeiten. Das zugrunde liegende Trendmodell (z.B. linear, exponentiell) muss auf seine Eignung hin untersucht werden.
Beispiel / Publikation	<i>Mudersbach, Ch. and Jensen, J. (2010): Non-stationary extreme value analysis of annual maximum water levels for designing coastal structures on the German North Sea coastline, Journal of Flood Risk Management , Vol. 3., Issue 1, pp. 52-62, DOI:10.1111/j.1753-318X.2009.01054.x</i>
Kontakt / Projekt	Christoph Mudersbach Universität Siegen Forschungsinstitut Wasser und Umwelt christoph.mudersbach@uni-siegen.de

5.7.4.3 Nichtstationäre Extremwertanalyse auf Basis eines nichthomogenen Poisson-Punktprozesses

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Nichtstationäre Extremwertanalyse auf Basis eines nichthomogenen Poisson-Punktprozesses
Beschreibung + Literatur	<p>Das Auftreten eines Extremereignisses wird beschrieben durch einen stochastischen Poisson-Punktprozess. Das Ziel der Schätzung ist die Intensität oder Auftrittsrates, welche gegeben ist durch die Anzahl Ereignisse pro Zeiteinheit. Ein nichthomogener Poisson-Prozess weist eine zeitabhängige Auftrittsrates auf. Die Schätzung wird mit Kernfunktionen (Glättung) durchgeführt, eine Kreuzvalidierungs-Richtlinie hilft bei der Wahl der Kern-Glättungsbandbreite. Randeffekte werden reduziert mit Hilfe von generierten Peudodaten. Punktweise Konfidenzbänder werden konstruiert mit Hilfe von Bootstrap-Resampling.</p> <p>Cowling A, Hall P, Phillips MJ (1996) Bootstrap confidence regions for the intensity of a Poisson point process. <i>Journal of the American Statistical Association</i> 91:1516–1524.</p>
Geeignet für (Parameter, zeitl. Auflösung)	<p>Alle Parameter bei beliebiger Zeitauflösung. Man kann drei Datentypen untersuchen:</p> <ol style="list-style-type: none"> (1) Zeitreihen, bei denen ein zeitabhängiger Schwellenwert angewendet wird, um POT-Daten zu erzeugen; (2) existierende POT-Daten und (3) eine Menge von Zeitpunkten, an denen ein Extremwert auftrat. <p>Die letztere Option gestattet es, die Methode auch auf historische Aufzeichnungen zu verwenden, bei denen häufig nur das Datum eines Ereignisses aufgezeichnet wurde, nicht jedoch seine Stärke.</p>
Voraussetzungen für Anwendung	Unabhängige Ereignis-Zeitpunkte.
Ergebnis/Interpretation	Das Resultat ist die zeitabhängige Auftrittsrates mit Konfidenzband. Dies gestattet es, die statistische Signifikanz von hohen oder niedrigen Werten des Klimarisikos einzuschätzen. Die Auftrittsrates kann weiterhin mit anderen Kurven verglichen werde, beispielsweise um die Rolle der globalen Erwärmung für das Auftreten von Hurrikane oder schweren Hochwassern zu beurteilen.
Bewertung	Robuste, nichtparametrische Methode, für die keine funktionale Form der Zeitabhängigkeit vorgeschrieben werden muss.
Beispiel/Publikation	Die Methode wurde durch Mudelsee et al. (2003, 2004) in die Hochwasser-Risikoanalyse eingeführt. Sie ist danach auf unterschiedliche Arten von Klimaextremen angewendet worden, wie etwa Hurrikane (Besonen et al. 2008), Bodenerosionsereignisse (Fleitmann et al. 2007) und Waldbrände (Girardin and Mudelsee 2008).

	<p>Elbe, Winter</p> <p>Auftrittsrate (a^{-1})</p> <p>Stärke</p> <p>Hochwasser, Elbe, Winter; unten: Ereignis-Daten (3 Stärke-Klassen); oben: Auftrettsrate (rote Linie) schwerer Hochwasser (Stärke 2–3) mit 90%-Konfidenzband (grau schattiert), konstruiert mit Hilfe einer Gaußschen Kernfunktion (Bandbreite 35 a) und 2000 Bootstrap-Simulationen [geändert nach Mudelsee et al. (2003)]</p> <p><i>Besonen MR, Bradley RS, Mudelsee M, Abbott MB, Francus P (2008) A 1,000-year, annually-resolved record of hurricane activity from Boston, Massachusetts. Geophysical Research Letters 35:L14705 (doi:10.1029/2008GL033950).</i> <i>Fleitmann D, Dunbar RB, McCulloch M, Mudelsee M, Vuille M, McClanahan TR, Cole JE, Eggins S (2007) East African soil erosion recorded in a 300 year old coral colony from Kenya. Geophysical Research Letters 34:L04401 (doi:10.1029/2006GL028525).</i> <i>Girardin MP, Mudelsee M (2008) Past and future changes in Canadian boreal wildfire activity. Ecological Applications 18:391–406.</i> Mudelsee M, Börngen M, Tetzlaff G, Grünwald U (2003) No upward trends in the occurrence of extreme floods in central Europe. <i>Nature</i> 425:166–169. Mudelsee M, Börngen M, Tetzlaff G, Grünwald U (2004) Extreme floods in central Europe over the past 500 years: Role of cyclone pathway “Zugstrasse Vb”. <i>Journal of Geophysical Research</i> 109:D23101 (doi:10.1029/2004JD005034).</p>
Kontakt/Projekt	Manfred Mudelsee Climate Risk Analysis, Hannover, Germany; mudelsee@climate-risk-analysis.com www.climate-risk-analysis.com
Software	

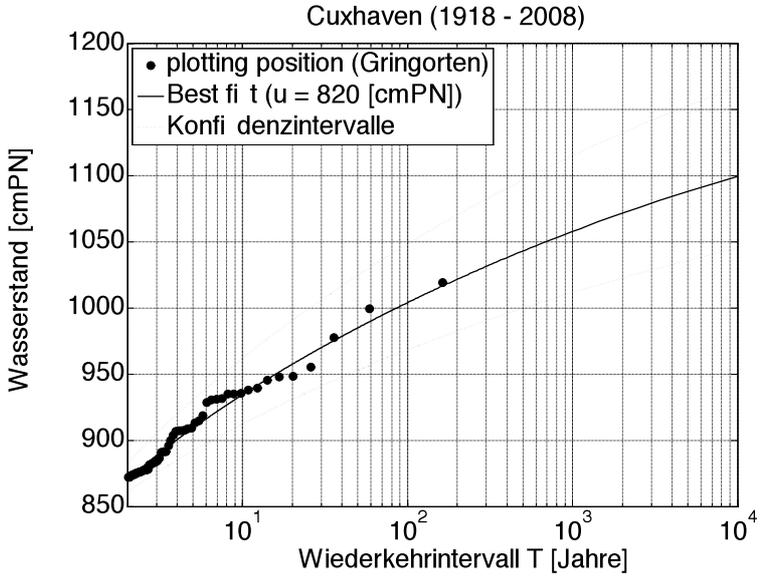
5.7.4.4 Statistische Analyse multivariater Datensätze mithilfe von Archimedischen Copula-Funktionen

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten
Verfahren	Statistische Analyse multivariater Datensätze mithilfe von Archimedischen Copula-Funktionen
Beschreibung + Literatur	<p>Die Copula-Theorie geht auf das Theorem von Sklar aus dem Jahr 1959 zurück, der den Zusammenhang zwischen einer Copula C und der bivariaten Verteilungsfunktion $F_{X,Y}(x,y)$, mit den univariaten Randverteilungen $F_X(x)$ und $F_Y(y)$, wie folgt beschreibt:</p> $F_{X,Y}(x,y) = C[F_X(x), F_Y(y)]$ <p>Für weitergehende Informationen zu dem Themenkomplex wird auf Nelsen (1999), Genest und Favre (2007) und Wahl et al. (2012), sowie die dort zitierten Literaturstellen verwiesen.</p> <p>Ähnlich wie bei der Anwendung univariater statistischer Verfahren, gibt es verschiedene Copula-Familien. In der Hydrologie (und auch in anderen Forschungsbereichen) werden häufig sogenannte Archimedische Copulas genutzt, da sie sehr flexibel und vergleichsweise einfach zu konstruieren sind. Asymmetrien in den Abhängigkeitsstrukturen der betrachteten Variablen können berücksichtigt werden. Sie werden über den Copula-Generator $\varphi(t)$ erzeugt, wobei folgender Zusammenhang zwischen dem Generator $\varphi(t)$ und einer einparametrischen Archimedischen Copula $C(u,v)$ mit dem Parameter θ besteht:</p> $C_\theta(u,v) = \varphi^{-1}[\varphi(u) + \varphi(v)]$ <p><i>Genest, C. and Favre, A-C.: Everything you always wanted to know about copula modeling but were afraid to ask, J. Hydrol. Eng., 12(4), 347–368, 2007.</i> <i>Nelsen, R.B. (1999): An introduction to copulas. Lecture Notes in Statistics, 139, Springer, New York.</i> <i>Wahl, T., Mudersbach, C., and Jensen, J.: Assessing the hydrodynamic boundary conditions for risk analyses in coastal areas: a multivariate statistical approach based on Copula functions, Nat. Hazards Earth Syst. Sci., 12, 495-510, 2012.</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	Parameter allgemein
Voraussetzungen für Anwendung	Ausreichend große Datenmenge zur Ermittlung der univariaten Randverteilungen und zur Erfassung der Abhängigkeitsstruktur (Rangkorrelation)
Ergebnis / Interpretation	Multivariate Eintrittswahrscheinlichkeiten bzw. Wiederkehrintervalle

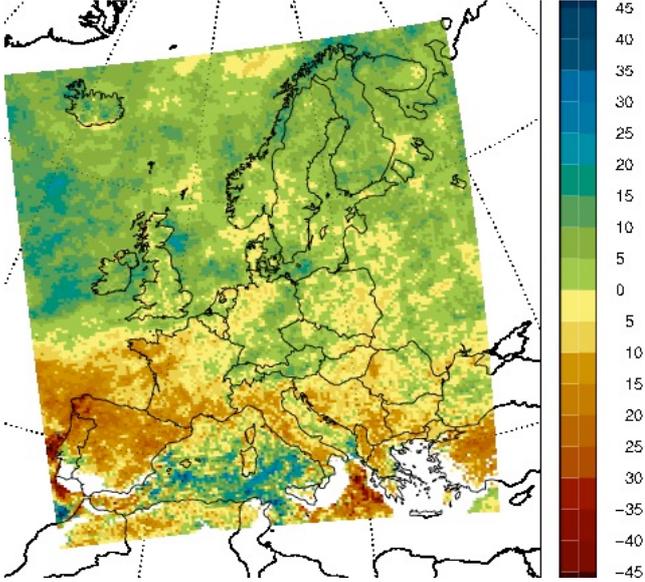
Bewertung	Flexibel einsetzbar zur Analyse multivariater Datensätze, bestehend aus voneinander abhängigen Parametern mit unterschiedlichen Randverteilungen
Beispiel	<p>Die folgende Abbildung zeigt das Ergebnis der gemeinsamen statistischen Analyse von Sturmflutschreiteln (S) und den wichtigen Seegangparametern signifikante Wellenhöhe (H_s) und Peakperiode (T_p) im Bereich Westerland vor Sylt. Die beobachteten Wertepaare sind als schwarze Kreise, die Ergebnisse der jeweils bivariaten statistischen Analyse als Konturlinien dargestellt. Die grauen Wertepaare sind direkt mithilfe der jeweiligen Copula-Funktionen (siehe Legende) simuliert worden, auch hierzu sind Copula-Modelle sehr gut geeignet.</p> <p>Marginal parameters (and distributions):</p> <ul style="list-style-type: none"> - Storm surge water level S (GPD) - Significant wave height H_s (GEV) - Peak period T_p (LogNormal) <p>Copula 1 (S H_s), Type: Gumbel $\theta_1 = 1.82$ [-]</p> <p>Copula 2 (S T_p), Type: Gumbel $\theta_2 = 1.65$ [-]</p> <p>Copula 3 (T_p H_s), Type: Frank $\theta_3 = 10.84$ [-]</p>
Kontakt / Projekt	<p>Thomas Wahl & Jens Bender, Forschungsinstitut Wasser und Umwelt (fwu) und Forschungskolleg Siegen (FoKoS), Universität Siegen, thomas.wahl@uni-siegen.de, jens.bender@uni-siegen.de</p> <p>BMBF- XtremRisk (www.xtremrisk.de)</p>
ggf. Software	

5.7.4.5 Verallgemeinerte Pareto Verteilung (GPD)

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten (Univariate Extremwertstatistik)
Verfahren	Univariate Extremwertanalyse mit Verallgemeinerter Pareto Verteilung (GPD) (1999)
Beschreibung + Literatur	<p>In der POT-Methode wird das Kollektiv aus allen Ereignissen gebildet, die einen definierten Schwellenwert (<i>engl. threshold</i>) überschreiten. Es wird angenommen, dass sich das gewählte Kollektiv durch die verallgemeinerte Pareto Verteilung (<i>engl. generalized Pareto distribution, (GPD)</i>) beschreiben lässt. Die GPD ist definiert als</p> $GPD = 1 - [1 + \xi \tilde{y} / \sigma]^{-1/\xi}, \text{ mit } \sigma = \sigma + \xi(u - \mu)$ <p>dabei entspricht μ dem Lageparameter, σ dem Streuungsparameter, ξ dem Formparameter und u dem Schwellenwert der zugrundeliegenden Verteilung (Coles, 2001).</p> <p>Die Wahl des Schwellenwertes erfolgt dabei i.d.R. subjektiv. In Arns et al. (in review) werden am Beispiel von Wasserstandszeitreihen diverse Vorgehensweisen zur Schwellenwertermittlung entlang der Deutschen Bucht untersucht; die Autoren zeigen, dass die Verwendung des 99,7-Perzentil in diesem konkreten Fall zu den stabilsten Resultaten führt. Zudem zeigen die Untersuchungen, dass konsistente Resultate nur dann erreicht werden, wenn die in weiten Teilen der Deutschen Bucht bis dato höchste gemessene Sturmflut von 1976 in den Kollektiven berücksichtigt wird.</p> <p>Im Hinblick auf andere Parameter und Standorte ist der Schwellenwert jedoch zu prüfen. Hierfür existieren unterschiedliche Vorgehensweisen (s. z.B. Coles, 2001; Arns et al., in review).</p> <p>Coles, S. (2001): An Introduction to Statistical Modeling of Extreme Values. Springer Verlag, London. Arns, A., Wahl, T., Haigh, I.D., Jensen, J., Pattiaratchi, C. (in review): Estimating extreme water level probabilities: a comparison of the direct methods and recommendations for best practise, submitted to: Coastal Engineering.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Parameter allgemein (z.B. Wasserstand, Wind, Abfluss)
Voraussetzungen für Anwendung	Ausreichend große Datenmenge; Wahl eines plausiblen Schwellenwertes (<i>engl. threshold</i>);
Ergebnis / Interpretation	Wasserstände zu definierten Eintrittswahrscheinlichkeiten bzw. Wiederkehrintervallen des betrachteten Parameters
Bewertung	Neben der GEV-Methode ist die Anwendung der GPD eine robuste Methode zur Ermittlung extremer Wasserstände bzw. dem zugehörigen Wiederkehrintervall. Die Wahl des Schwellenwertes erfolgt jedoch i.d.R. subjektiv, hierdurch können die Resultate beeinflusst werden.

<p>Beispiel</p>	<p>Die Abbildung zeigt die Anwendung des GPD-Verfahrens auf eine Wasserstandszeitreihe von 1918 bis 2008 am Standort Cuxhaven. Die empirischen Wahrscheinlichkeiten (<i>engl. plotting position</i>) sind als schwarze Kreise, die Ergebnisse der statistischen Analyse als schwarze Linie und die zugehörigen Konfidenzintervalle als schwarz gestrichelte Linien dargestellt.</p> 
<p>Kontakt / Projekt</p>	<p>Arne Arns & Christoph Mudersbach, Forschungsinstitut Wasser und Umwelt (fwu), Universität Siegen, arne.arns@uni-siegen.de, christoph.mudersbach@uni-siegen.de</p>
<p>ggf. Software</p>	

5.7.4.6 Extremwertanalyse mit Kovariate: Peaks-over-threshold modelliert mit nicht-stationärem Poisson-Punkt-Prozess

Übergeordnetes Ziel (Kategorie)	Analyse von Extremwerten (Zeitabhängige Extremwertanalyse von Starkniederschlagsereignissen)
Verfahren	Extremwertanalysemodell mit Kovariate: Peaks-over-threshold modelliert mit nicht-stationärem Poisson-Punkt-Prozess zur Bestimmung von zeitlichen Trends in Extremereignissen
Beschreibung + Literatur	Coles, S.: An Introduction to Statistical Modeling of Extreme Values, Springer, 2001, 208 pp. Katz et al.: Statistics of extremes in hydrology, Adv. Wat. Res., 2002, 25, 1287-1304
Geeignet für (Parameter, zeitl. Auflösung)	Punkt ereignisse, z.B. tägliche Starkniederschläge, die getrennt voneinander auftreten
Voraussetzungen für Anwendung	Ereignisse müssen unabhängig voneinander auftreten (keine Cluster) Zur Trendanalyse von Extremereignissen sollte die Zeitreihe entsprechend der Wiederkehrperiode der zu untersuchenden Ereignisse entsprechend lang sein
Ergebnis / Interpretation	<p>Ermittlung zeitlicher Trends von hohen Quantilen täglicher Niederschlagsereignisse (Starkniederschläge)</p>  <p>Ergebnis: Die Abbildung zeigt die relative Änderung [%] des 99,9%-Quantils täglicher Niederschläge in einer regionalen Klimamodellsimulation über Europa für die Sommermonate (JJA) von 1961-2099, geschätzt mit einem nicht-stationären Poisson-Punkt-Prozess. Während sich die Quantile über Nordeuropa leicht zum positiven verändern, nehmen die Werte über den Landmassen in Südeuropa bis zu 30% ab.</p>
Bewertung	Folgende Dinge sind bei der Anwendung zu beachten: Evtl. sollten die Daten vor der Anwendung der Methode von "Starkniederschlagsclustern" bereinigt werden, d.h. z.B. Starkniederschlagsereignisse, die höchstens einen Tag voneinander getrennt auftreten. Beschreibung des De-clustering in:

	<p>Davison, A. C. & Smith, R. L.: Models for exceedances over high thresholds J. R. Statist, Soc., 1990, 52, 393-442</p> <p>Bei der Trendanalyse sollte beachtet werden, dass entsprechend der Datengrundlage die Unsicherheit steigt je höher das untersuchte Quantil ist</p>
Beispiel/Publikation	<p>Radermacher, C. & Tomassini, L.: Thermodynamic causes for future trends in heavy precipitation over Europe based on an ensemble of regional climate model simulations, Journal of Climate, 2012, Early online release, doi: http://dx.doi.org/10.1175/JCLI-D-11-00304.1</p>
Kontakt / Projekt	<p>Christine Radermacher, Max-Planck-Institut für Meteorologie, Hamburg christine.radermacher@zmaw.de</p>
Software	<p>Eigene</p>

5.8 Kennzahlen

Klimamodelle geben elementare physikalische Größen wie Temperatur, Luftdruck und Niederschlag an bestimmten Gitterpunkten in Raum und Zeit aus. Die Einflüsse des Klimas auf weitere Komponenten des Systems wie die Menschheit oder die Landwirtschaft hängen typischerweise nur von einem Teil der Gitterpunktwerte, geglättet in Raum und Zeit, ab. Hitzewellen werden beispielsweise nur durch die Extreme der Temperaturverteilung beschrieben und tragen die zeitliche Dauer als weiteres Merkmal (Kürbis et al. 2009, Rahmstorf und Coumou, 2011).

Eine klimatische Kennzahl gibt auf elegante Weise die Ergebnisse hochdimensionaler Klimamodellsimulationen in einer einzigen Zahl wieder. Aufgrund der Vielzahl verschiedener Auswirkungen des Klimas und dank des Interesses der Wissenschaftler existiert eine große Zahl klimatischer Kennzahlen, die in der Praxis verwendet werden. Hier werden die folgenden vorgestellt: der Unterschied in der Transpiration (Abschnitt 5.8.1.4), die Häufigkeit von Frosttagen (Abschnitt 5.8.2.2) und die Vegetationsperiode (Abschnitt 5.8.2.3).

Beim Vergleich von Klimamodelldaten und Beobachtungen kann es oft hilfreich sein, das Ergebnis dieser Validierungsanalyse in einer Kennzahl zusammenzufassen, die eine bestimmte wissenschaftliche Fragestellung auf den Punkt bringt (z.B. welche Variablen bei welcher zeitlichen und räumlichen Auflösung). Hier werden die folgenden Kennzahlen vorgestellt: Die Nash–Sutcliffe Modelleffizienz (Abschnitt 5.8.1.1), der perzentuale Bias (Abschnitt 5.8.1.5), die Verwendung einer Referenzperiode (Abschnitt 5.8.1.2) und der Skill-Score in Kombination mit der Trefferquote (Abschnitt 5.8.1.3 und 5.8.1.4).

Literatur. Ein früher Beitrag zu Klimakennzahlen wurde von Easterling et al. (2003) verfasst. In den Berichten der Working Group II des IPCC zu Auswirkungen des Klimawandels (AR4 editiert von Parry et al. (2007)) werden viele der häufig verwendeten Kennzahlen beschrieben. Vergleichende Kennzahlen werden im Buch von Jolliffe and Stephenson (Hrsg., 2003) behandelt.

Easterling DR, Alexander LV, Mokssit A, Detemmerman V (2003) CCI/CLIVAR workshop to develop priority climate indices. *Bulletin of the American Meteorological Society* 84:1403–1407.

Jolliffe IT, Stephenson DB (2003) *Forecast Verification: A Practitioner's Guide in Atmospheric Science*. Wiley, Chichester, 240 pp.

Kürbis K, Mudelsee M, Tetzlaff G, Brázdil R (2009) Trends in extremes of temperature, dew point, and precipitation from long instrumental series from central Europe. *Theoretical and Applied Climatology* 98:187–195.

Parry M, Canziani O, Palutikof J, van der Linden P, Hanson C (2007) *Climate Change 2007: Impacts, Adaptation and Vulnerability*. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, 976 pp.

Rahmstorf S, Coumou D (2011) Increase of extreme events in a warming world. *Proceedings of the National Academy of Sciences of the United States of America* 108:17905–17909. [Correction: 109: 4708]

5.8.1 Modellevaluierungskennzahlen

5.8.1.1 Vergleich von Zeitreihen durch Berechnung der Nash-Sutcliffe Modell-Effizienz

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Vergleich zwischen simulierten und gemessenen Zeitreihen hydrologischer Größen durch Berechnung der Nash-Sutcliffe Modell-Effizienz (NSE)
Beschreibung + Literatur	Die Nash-Sutcliffe Modell-Effizienz (Nash und Sutcliffe, 1970) ist eine normierte dimensionslose statistische Kennzahl die angibt, wie gut Werte einer beobachteten hydrologischen Größe mit den von einem hydrologischen Modell simulierten Werten übereinstimmen. <i>Literatur: Nash, J.E.; Sutcliffe, J.V.: River flow forecasting through conceptual models: Part I - A discussion of principles. In: Journal of Hydrology 10 (1970), Nr. 3, S. 282- 290</i>
Geeignet für (Parameter, zeitl. Auflösung)	Abflüsse, Frachten Jahreswerte, Monatswerte, Tageswerte, Stundenwerte
Voraussetzungen für Anwendung	Vollständige (lückenlose) äquidistante Zeitreihen
Ergebnis / Interpretation	Werte kleiner als 0 zeigen an, dass der Mittelwert der beobachteten Größen das System besser kennzeichnet, als die simulierten Größen, was als nicht akzeptable Modell-Effizienz angesehen wird. Ein Wert von 1 bedeutet eine perfekte Abbildung der Realität im Modell. Bei hydrologischen Simulationen sollten Werte größer als 0,5 angestrebt werden.
Bewertung	NSE ist relativ empfindlich gegenüber extremen Modellfehlern. NSE wird als beste objektive Funktion angesehen, um die Anpassung an eine beobachtete Zeitreihe zu bewerten.
Beispiel / Publikation	<i>Moriasi, D. N.; Arnold, J. G.; Liew, M. W. V.; Bingner, R. L.; Harmel, R. D.; Veith, T. L.: Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. In: Transactions of the ASABE 50 (2007), Nr. 3, S. 885-900</i>
Kontakt / Projekt	Frank Herrmann Forschungszentrum Jülich GmbH Institut für Bio- und Geowissenschaften f.herrmann@fz-juelich.de KLIMZUG Nord

5.8.1.2 Quantitative Evaluierung von Klimamodellrechnungen in einem Referenzzeitraum

Übergeordnetes Ziel (Kategorie)	Kennzahlen: Quantitative Evaluierung von Klimamodellrechnungen in einem Referenzzeitraum
Verfahren	Berechnung von Kennzahlen zur Evaluierung der räumlichen Muster, der Varianz der Zeitreihen, und der klimatologisch gemittelten Jahresgänge einer meteorologischen Größe
Beschreibung + Literatur	Die Kennzahlen wurden für die Evaluierung von Klimamodellrechnungen entwickelt. Die Evaluierung beruht auf einem Vergleich von simulierter und beobachteter Klimatologie und nicht auf einem Vergleich von simulierten und beobachteten Zeitreihen. <u>Literatur:</u> Keuler, K., A. Block, W. Ahrens, D. Jacob, D. Rechied, L. Kotova, S. Kotlarski, D. Heimann, M. Zemsch, R. Knoche, E. Dittmann, A. Walter, F. Berger, and M. Sommer, 2006: <i>Quantification of uncertainties in regional climate and climate change simulations (QUIRCS)</i> .
Geeignet für (Parameter, zeitl. Auflösung)	Monatswerte von Temperatur, Niederschlag, Bedeckungsgrad, relative Feuchte, Windgeschwindigkeit.
Voraussetzungen für Anwendung	Verfügbarkeit von Beobachtungsdaten. Ausreichende Integrationszeit des zu evaluierenden Klimamodells (z.B. 30 Jahre Klimaperiode).
Ergebnis / Interpretation	Die Kennzahlen sind teilweise dimensionsbehaftet (z.B. BIAS), teilweise dimensionslos (z.B. Pattern Correlation). Die verschiedenen Kennzahlen haben unterschiedliche Wertebereiche.
Bewertung	Die Kennzahlen erlauben eine objektive Quantifizierung der Güte von Klimamodellrechnungen in einer Referenzperiode. Nicht alle Kennzahlen sind bei allen meteorologischen Größen sinnvoll in der Anwendung: Zum Beispiel ist der Jahresgang der Temperatur in den mittleren Breiten deutlich ausgeprägt. Aus diesem Grund zeigen die Kennzahlen zur Evaluierung des klimatologischen Jahresgangs der Temperatur allgemein gute Werte auf, auch wenn die Klimamodellergebnisse deutlich von den Beobachtungsdaten abweichen.
Beispiel / Publikation	
Kontakt / Projekt	Robert Schoetter Universität Hamburg, Meteorologisches Institut robert.schoetter@zmaw.de KLIMZUG NORD

5.8.1.3 **Evalierungskennzahlen für mesoskalige meteorologische Modelle sowie mesoskalige Ausbreitungsmodelle**

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Statistisches Verfahren	Evaluierungskennzahlen für mesoskalige meteorologische Modelle sowie mesoskalige Ausbreitungsmodelle.
Beschreibung + Literatur	Die Güte der Simulationen mesoskaliger Modelle wird durch die Berechnung einer Reihe von Evaluierungskennzahlen quantifiziert. Literatur: K.H. Schlünzen and R.S. Sokhi (editors), 2008.
Geeignet für (Parameter, zeitl. Auflösung)	Temperatur, Taupunkttemperatur, Bodendruck, Windgeschwindigkeit, Windrichtung, Wolkenbedeckungsgrad, Niederschlag, Stoffkonzentrationen. Die Evaluierung bezieht sich oft auf Stundenwerte, da zeitlich höher aufgelöste Messdaten meist nicht vorhanden sind und die Ergebnisse der Reynolds-gemittelten mesoskaligen Modelle nicht auf kürzeren Zeitskalen interpretiert werden sollten.
Voraussetzungen für Anwendung	Verfügbarkeit von qualitätsgeprüften und möglichst repräsentativen Messdaten. Manche Kennzahlen (z.B. Standardabweichung) sind nur dann wirklich aussagekräftig wenn die Abweichungen zwischen Modell und Beobachtung annähernd Normalverteilt sind.
Ergebnis / Interpretation	Die Kennzahlen erlauben eine objektive Quantifizierung der Güte der Simulationsergebnisse. Verschiedene Modelle sowie unterschiedliche Versionen eines Modells können miteinander verglichen werden.
Bewertung	Nicht alle Kennzahlen sind für alle meteorologische Größen gleich aussagekräftig. Zum Beispiel ist die Korrelation der Stundenwerte der Temperatur zwischen Modell und Beobachtung ist auf Grund des Tagesgangs oft sehr hoch. Manche meteorologische Größen erfordern ihre eigenen speziell zugeschnittenen Kennzahlen (z.B. Windrichtung) die nicht auf andere Größen anwendbar sind. Die meisten Kennzahlen sind nicht für die Evaluierung von Klimamodellergebnissen geeignet, da bei Klimamodellläufen keine Übereinstimmung der Zeitreihen gefordert werden darf.
Beispiel / Publikation	Schlünzen and Katzfey (2003).
Kontakt / Projekt	Robert Schoetter Meteorologisches Institut, Universität Hamburg KLIMZUG-NORD

Literatur:

K.H. Schlünzen and R.S. Sokhi (editors), 2008: Overview of tools and methods for meteorological and air pollution mesoscale model evaluation and user training. Joint Report of COST Action 728 (Enhancing mesoscale meteorological modeling capabilities for air pollution and dispersion applications) and GURME (GAW Urban Research Meteorology and Environment Project). World Meteorological Organisation, 2008, 116 pp.

K.H. Schlünzen and J.J. Katzfey, 2003: Relevance of sub-grid-scale land-use effects for mesoscale models. Tellus (2003), 55A, 232–246

5.8.1.4 Evaluierung der Häufigkeitsverteilung durch skill-score und hit-rate of the percentiles

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Evaluierung der Häufigkeitsverteilung von Tagesmittelwerten durch Berechnung der Kennzahlen SSC (skill-score) und HRP (hit-rate of the percentiles)
Beschreibung + Literatur	<p>Die Kennzahlen SSC und HRP quantifizieren wie gut simulierte und beobachtete Häufigkeitsverteilungen von Tagesmittelwerten übereinstimmen. Beide Kennzahlen sind dimensionslos und auf den Wertebereich 0-1 normiert.</p> <p><u>Literatur:</u> Perkins, S.E., A.J. Pitman, N.J. Holbrook, and J. McAneney, 2007: Evaluation of the AR4 climate models' simulated daily maximum temperature, minimum temperature, and precipitation over Australia using probability density functions. <i>J. Climate</i>, 20, 4356-4376. Schoetter, R., P.Hoffmann, D.Rechid, and K.H. Schlünzen, 2012: Evaluation and bias correction of regional climate model results using model evaluation measures. <i>J. Appl. Meteor. Climatol.</i>, 51, 1670–1684.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Temperatur, relative Feuchte, Wolkenbedeckungsgrad, Windgeschwindigkeit Tageswerte
Voraussetzungen für Anwendung	Belastbarer Beobachtungsdatensatz für das Gebiet in welchem die Modellevaluierung stattfinden soll, oder für HRP zumindest eine Abschätzung für die Unsicherheit der Beobachtungsdaten.
Ergebnis / Interpretation	SSC misst den Grad des Überlapps der Häufigkeitsverteilungen (0: Häufigkeitsverteilungen disjunkt, 1: Häufigkeitsverteilungen liegen perfekt übereinander), HRP den Anteil der Perzentile welcher innerhalb der Unsicherheit der Beobachtungsdaten liegt. HRP kann daher auch dann den Wert 1 annehmen wenn simulierte und beobachtete Häufigkeitsverteilungen nicht perfekt übereinstimmen
Bewertung	SSC ist sehr robust, der theoretische Wertebereich (0-1) wird in der Praxis aber nur selten ausgeschöpft. HRP ist deutlich empfindlicher.
Beispiel / Publikation	<u>Literatur:</u> Perkins, S.E., A.J. Pitman, N.J. Holbrook, and J. McAneney, 2007: Evaluation of the AR4 climate models' simulated daily maximum temperature, minimum temperature, and precipitation over Australia using probability density functions. <i>J. Climate</i> , 20, 4356-4376. Schoetter, R., P.Hoffmann, D.Rechid, and K.H. Schlünzen, 2011: Evaluation and bias correction of regional climate model results using model evaluation measures. Submitted to <i>Journal of Applied Meteorology and Climatology</i> .
Kontakt / Projekt	Robert Schoetter Meteorologisches Institut, Universität Hamburg robert.schoetter@zmaw.de KLIMZUG NORD

5.8.1.5 Vergleich von Zeitreihen hydrologischer Größen durch Percent Bias

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Vergleich zwischen simulierten und gemessenen Zeitreihen hydrologischer Größen durch Berechnung der Kennzahl Percent bias (PBIAS)
Beschreibung + Literatur	Misst die mittlere Tendenz einer simulierten Größe (Zeitreihe), größer oder kleiner als die entsprechende beobachtete Größe zu sein. Quantifiziert somit die Neigung eines Modells, die Beobachtungen systematisch zu über- oder unterschätzen. <u>Literatur:</u> Gupta, H. V.; Sorooshian, S.; Yapo, O. P.: Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. In: Journal of Hydraulic Engineering 4 (1999), Nr. 2, S. 135-143
Geeignet für (Parameter, zeitl. Auflösung)	Abflüsse, Frachten Jahreswerte, Monatswerte, Tageswerte, Stundenwerte
Voraussetzungen für Anwendung	Vollständige (lückenlose) äquidistante Zeitreihen
Ergebnis / Interpretation	Der Optimalwert von PBIAS ist 0. Positive Werte zeigen eine Neigung zur Unterschätzung der Beobachtungswerte an, negative Werte eine Überschätzung.
Bewertung	Mit PBIAS kann eine schlechte Leistung des Modells klar erkannt werden. PBIAS variiert innerhalb verschiedener Kalibrierungsperioden (nass, trocken) unterschiedlich stark.
Beispiel / Publikation	Moriasi, D. N.; Arnold, J. G.; Liew, M. W. V.; Bingner, R. L.; Harmel, R. D.; Veith, T. L.: Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. In: Transactions of the ASABE 50 (2007), Nr. 3, S. 885-900
Kontakt / Projekt	Frank Herrmann Forschungszentrum Jülich GmbH Institut für Bio- und Geowissenschaften f.herrmann@fz-juelich.de KLIMZUG Nord

5.8.1.6 Aikaikes Informationskriterium

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Aikaikes Informationskriterium
Beschreibung + Literatur	<p>Das optimale Modell aus einer Menge plausibler Modell kann mithilfe von Aikaikes Informationskriterium (AIC, Aikaike (1973))) bestimmt werden. Dieses ist gegeben durch $AIC = -2 \log L + 2k$, wobei k die Anzahl der Parameter und L die Likelihood beschreibt.</p> <p>Im Gegensatz zum Likelihood-Ratio-Test, kann AIC zum Vergleich nicht-genesteter Modelle verwendet werden.</p> <p>Aikaike, H., 1973: Information theory and an extension of the maximum likelihood principle. <i>2nd International Symposium on Information Theory</i>, B. Petrov and F. Csaki, Eds., Budapest, Akademie Kiade, 267-281.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Modellauswahl (auch nicht-genestete Modelle), z.B. um die beste Kombination von Kovariaten in einem Extremwertmodell zu bestimmen.
Voraussetzungen für Anwendung	<p>Für endliche (kleine) Stichproben sollte eine korrigierte Version des AIC verwendet werden:</p> $AICc = AIC + 2k(k+1)/(n-k-1),$ <p>wobei n die Stichprobengröße ist.</p>
Ergebnis / Interpretation	Das Modell mit dem minimalen AIC ist dasjenige, das sich am besten an die Daten anpasst.
Bewertung	Beachte, dass das AIC als relative Größe zum Modellvergleich geeignet ist; es stellt jedoch keinen Goodness-of-fit Test dar.
Beispiel / Publikation	Maraun et al. (2009), Synoptic airflow in UK daily precipitation extremes - Development and validation of a vector generalised linear model, <i>Extremes</i> , 13, 133-153
Kontakt / Projekt	Christine Radermacher, MPI für Meteorologie, Hamburg christine.radermacher@zmaw.de

5.8.1.7 Brier Skill Score

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Brier Skill Score
Beschreibung + Literatur	<p>Der Brier Score (BS, Brier (1950)) ist eine Methode zur Bewertung der Fähigkeit eines Modells, die Überschreitung eines bestimmten Grenzwerts vorherzusagen.</p> <p>Der Brier Skill Score (BSS) bestimmt die relative Verbesserung des Modells verglichen mit einem Referenzmodell und kann als Goodness-of-fit Test für das statistische Modell interpretiert werden.</p> <p>Das Referenzmodell kann beispielsweise die klimatologische Wahrscheinlichkeit der Grenzwertüberschreitung sein. Die Werte des BSS liegen zwischen $-\infty$ und 1 und beschreiben den Zugewinn der Vorhersagefähigkeit gegenüber dem Referenzmodell.</p> <p>Brier, G. W., 1950: Verification of forecasts expressed in terms of probability. <i>Mon. Wea. Rev.</i>, 78, 1-3.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Bewertung der Modellperformance, Modellauswahl
Voraussetzungen für Anwendung	-
Ergebnis / Interpretation	Je größer der BSS (je näher an 1), desto besser die Vorhersagefähigkeit des Modells.
Bewertung	Der Brier Skill Score ist vor allem für die Bewertung der Vorhersagefähigkeit binärer Ergebnisse ("Überschreitung" oder "Nicht-Überschreitung") geeignet. Um die Fähigkeit der Vorhersage von Absolutwerten zu testen, können andere Methoden besser geeignet sein.
Beispiel / Publikation	Friederichs et al. (2009), A probabilistic analysis of wind gusts using extreme value statistics, <i>Meteorologische Zeitschrift</i> , Vol. 18, No. 6, 615-629
Kontakt / Projekt	Christine Radermacher, MPI für Meteorologie, Hamburg christine.radermacher@zmaw.de

5.8.2 Statistische Klimakennzahlen

5.8.2.1 Transpirationsdifferenz als Maß für die Standorteignung

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Berechnung der Transpirationsdifferenz als Maß für die Standorteignung
Beschreibung + Literatur	Ermittlung der Differenz zwischen potenzieller und realer Transpiration als Maß für die Standorteignung. Sowohl räumliche als auch zeitliche Vergleiche (z. B. Szenarien) sind möglich. <u>Literatur:</u> Falk et al. (2008), Hammel und Kennel (2001), Schultze et al. (2005), Pöhler et al. (2010)
Geeignet für (Parameter, zeitl. Auflösung)	Potentielle und reale Transpiration Zeitliche Auflösung: 1 Tag, Vegetationsperiode, 1 Jahr
Voraussetzungen für Anwendung	Wasserhaushaltsmodell (Standortmodell oder Einzugsgebietsmodell), täglich aufgelöste meteorologische Eingangsdaten: Beobachtungsdaten oder Klimaszenarien
Ergebnis / Interpretation	Integraler Indikator für die Interaktion der Faktoren Klima, Boden, Baumart und Bestockungsdichte Überblick über räumliche Unterschiede Überblick über mögliche Veränderungen in Zukunft
Bewertung	Die Kennzahl ist gut geeignet, von irreführenden Ergebnissen ist nichts bekannt:
Beispiel / Publikation	Pöhler et al. (2010)
Kontakt / Projekt	Hannaleena Pöhler UDATA Umweltschutz und Datenanalyse Hydrologie, Klimafolgenforschung, Boden- und Grundwasserschutz poebler@udata.de KLIMZUG NORD

Falk, W., Dietz, E., Grünert, S., Schultze, B., Kölling, C. (2008): *Wo hat die Fichte genügend Wasser? - Neue überregional gültige Karten des Wasserhaushalts von Fichtenbeständen verbessern die Anbauentscheidung; LWF aktuell, 2008.*

Hammel, K. U. Kennel, M. (2001): *Charakterisierung und Analyse der Wasserverfügbarkeit und des Wasserhaushalts von Waldstandorten in Bayern mit dem Simulationsmodell BROOK90. Forstliche Forschungsberichte München, 185, 135 S.*

Pöhler, H., Schultze, B., Scherzer, J. (2010): *Auswirkungen des Klimawandels auf den Wasserhaushalt eines bewaldeten Kleineinzugsgebietes im Hochsauerland, Freiburger Forstliche Forschung, in Druck*

Schultze B., C. Kölling, C. Dittmar, T. Rötzer, W. Elling (2005): *Konzept für ein neues quantitatives Verfahren zur Kennzeichnung des Wasserhaushalts von Waldböden in Bayern: Modellierung - Regression - Regionalisierung; Forstarchiv 76, 155-163*

5.8.2.2 Häufigkeit von Frosttagen nach Vegetationsbeginn/ zeitlicher Abstand von Terminen des letzten Frosttages und des Vegetationsbeginns

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Zählen der Häufigkeit von Frosttagen nach Vegetationsbeginn/ zeitlicher Abstand von Terminen des letzten Frosttages und des Vegetationsbeginns
Beschreibung + Literatur	Landwirtschaftlicher Vegetationsbeginn = Blühbeginn Salweide gemäß Länderinitiative Klimaindikatoren (LIKI) bei Anwendung im Obstbau auch Termin für Beginn der Obstblüte möglich Frosttag = Tag mit Tagesminimumtemperatur <0°C Festlegung eines Beeinflussungszeitraumes nach Vegetationsbeginn, in Anlehnung an Obstblüte 10 d (<i>Chmielewski et al. 2009</i>) → Zählen der Häufigkeiten von Frosttagen. Ggf. Klasseneinteilung nach Froststärke (z.B. <-2 °C), da nicht alle Pflanzen gleich empfindlich
Geeignet für (Parameter, zeitl. Auflösung)	Abschätzung der zukünftigen Frostgefährdung in der Landwirtschaft
Voraussetzungen für Anwendung	vorliegende Informationen zum Blühbeginn Salweide, ansonsten Bestimmung des Vegetationsbeginns durch andere Methoden z.B. Temperaturschwellenkriterium
Ergebnis / Interpretation	Spätfrostgefährdung an einem Standort ist umso höher je größer Abstand zwischen Vegetationsbeginn und letztem Frosttag ist und je mehr Frosttage innerhalb eines definierten Zeitraumes nach Vegetationsbeginn auftreten.
Bewertung	liefert grobe Abschätzung auf regionaler Ebene, mikroklimatische Beeinflussung kann nicht erfasst werden, Aussagen zur Gefährdung einzelner Pflanzenarten erfordert genaue Kenntnis zur Frostempfindlichkeit in bestimmten Wachstumsabschnitten
Beispiel	<i>Abschätzung der Spätfrostgefährdung in der Modellregion Dresden (Kapitel Vegetationsperiode und Spätfrostgefährdung in Bernhofer et al. (2011))</i>
Kontakt / Projekt	Maria Foltyn (ehemals LfULG) Technische Universität Bergakademie Freiberg foltyn@mailserver.tu-freiberg.de KLIMZUG-Projekt: REGKLAM

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden

5.8.2.3 Abzählmethode zur Bestimmung der thermischen Vegetationsperiode

Übergeordnetes Ziel (Kategorie)	Kennzahlen
Verfahren	Temperaturschwellenkriterium (Abzählmethode) zur Bestimmung der thermischen Vegetationsperiode
Beschreibung + Literatur	<p>Temperaturschwellenkriterium nach Vogel angewandt, wie es u. a. in der sächsischen Klimadatenbank implementiert ist.</p> <p>Beginn: Tagesmitteltemperatur ≥ 5 °C für 7 aufeinanderfolgende Tage Ende: Tagesmitteltemperatur < 10 °C für 7 aufeinanderfolgende Tage</p> <p>Als Beginn/ Ende der thermischen Vegetationsperiode wird jeweils der letzte dieser aufeinanderfolgenden Tage festgelegt.</p> <p>Ungewöhnlich warme Perioden im Winter können zur Ausgabe eines unplausiblen, deutlich zu zeitigen Vegetationsbeginns führen. Um dem vorzubeugen, wird mit der Zählung erst begonnen, wenn drei aufeinander folgende Monatsmitteltemperaturen 5 °C übersteigen. Der Beginn des Monats vor Erfüllung dieses Zusatzkriteriums ist der Starttag für die Zählung.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Wasserhaushaltsbetrachtungen, Landwirtschaft, Bilanzierung C-Haushalt
Voraussetzungen für Anwendung	lückenlose Temperaturreihe
Ergebnis / Interpretation	sowohl in Beobachtungsdaten der letzten Jahre als auch in zukünftigen Projektionen besteht eine Vorverlagerung des Vegetationsbeginns und eine Verspätung des Vegetationsendes
Bewertung	relativ unkompliziert in Anwendung, da nur Tagesmitteltemperaturen benötigt, aber z. T. große zwischenjährliche Schwankungen
Beispiel	<i>Kapitel Vegetationsperiode in Bernhofer et al. (2009, 2011)</i>
Kontakt / Projekt	Majana Heidenreich (TU Dresden), Maria Foltyn (ehemals LfULG, jetzt TU BA Freiberg) majana.heidenreich@tu-dresden.de, foltyn@mailserver.tu-freiberg.de KLIMZUG-Projekt: REGKLAM, TP 2.1

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2009): Das Klima in der REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 1, Rhombos-Verlag Dresden

5.9 *Raum-Zeit-Verfahren*

Räumliche und zeitliche Daten sind in sowohl in Klimasimulationen als auch bei Beobachtungen reichlich vorhanden. Schon die vorangegangenen Abschnitte behandelten verschiedenste Verfahren, um diese Art von Daten zu untersuchen, so wie multivariate Extreme (5.7.4), physikalisches Downscaling und zweidimensionale Interpolation (5.6.1 und 5.6.2) und Kennzahlen (5.8). Im folgenden Abschnitt 5.9 werden weitere Methoden vorgestellt.

Statistische Modelle sind hilfreich, um objektiv immer wiederkehrende Wettersituationen zu klassifizieren und Muster in hochaufgelösten räumlichen und zeitlichen Daten zu erkennen (5.9.1); Temperatursummen (**Fehler! Verweisquelle konnte nicht gefunden werden.**) werden genutzt, um phänologische Daten zu projizieren. Offensichtlich sind diese Summen ebenfalls klimatische Kennzahlen wie sie im vorangegangenen Abschnitt beschrieben wurden. Räumliche Karten zeigen die Korrelationen zwischen einer klimatischen Variable und anderen Variablen im Raum-Zeit-Feld (5.9.3) und können ebenfalls verwendet werden, um räumliche Muster aufzudecken; man beachte außerdem die zahlreichen Korrelationsmethoden, die vielseitig angewendet werden können (5.1.1, 5.1.2 und 5.1.3).

Literatur. Siehe Literaturvorschläge in vorangegangenen Abschnitten.

5.9.1 Korrelation zweier Variablen (Korrelationskarten)

Übergeordnetes Ziel (Kategorie)	Raum-Zeit-Verfahren (Korrelationskarten)
Verfahren	Korrelation zweier Variablen
Beschreibung + Literatur	Korrelation von Zeitreihen atmosphärischer Zirkulation und atmosphärischen Parametern ; z.B. <i>Sepp M & Jaagus J (2002) Frequency of circulation patterns and air temperature variations in Europe. Bor Env Res 7, 3: 273-279</i>
Geeignet für (Parameter, zeitl. Auflösung)	Zeitreihen von Häufigkeiten atmosphärischer Zirkulation und mittlerem Wert von Klimaparametern (Luftdruck, Temperatur, Niederschlag usw.); zeitliche Auflösung: frei definierbar (eigene Verwendung: monatliche, jahreszeitliche, halbjährliche, jährliche Auflösung)
Voraussetzungen für Anwendung	Lückenlose und möglichst lange und homogene Zeitreihe
Ergebnis / Interpretation	Räumliche Karten diverser Zusammenhänge
Bewertung	Ermöglicht Interpretation von Zusammenhängen auf räumlicher Ebene; Rauschen durch Vergleich von Teilen der Periode (Häufigkeit) mit Mittelwert der kompletten Periode
Beispiel/ Publikation	<i>Sepp und Jaagus 2002; Hoy A, Jaagus J Sepp M, Matschullat J (eingereicht bei TAC): "Spatial response of two European atmospheric circulation classifications (data from 1901 to 2010)"</i>
Kontakt / Projekt	Andreas Hoy Technische Universität, Bergakademie Freiberg andreas.hoy@ioez.tu-freiberg.de KLIMZUG-Projekt: REGKLAM

5.9.2 Temperatursummenmethode zur Projektion phänologischer Eintrittstermine

Übergeordnetes Ziel (Kategorie)	Raum-Zeit-Verfahren
Verfahren	Temperatursummenmethode zur Projektion phänologischer Eintrittstermine
Beschreibung + Literatur	<p>Berechnung des Eintrittstermins t_2 [Tag im Jahr] einer phänologischen Phase durch Aufsummierung von Tagesmitteltemperaturen T_i nach einem Starttag t_1 (hier: 1. Januar, $T_{iJ} = 1$) bis pflanzenabhängige Temperatursumme F^* erreicht ist (Formel 1). Die einfachste Herangehensweise für R_f ist Formel 2. Je nach Untersuchungsgebiet und phänologischer Phase ergibt der nichtlineare Ansatz von Formel 3 geringere Abweichungen zur Beobachtung. T_B ist eine Basistemperatur, ab der ein Temperaturreiz wirksam wird.</p> $F(t) = \sum_{i=t_1}^t R_f(T_i) \quad \text{mit } F(t_2) = F^*$ <p>[1]</p> $R_f(T_i) = 0 \quad \text{wenn } T_i \leq T_B$ <p>[2]</p> $R_f(T_i) = T_i - T_B \quad \text{wenn } T_i > T_B$ $R_f(T_i) = 0 \quad \text{wenn } T_i \leq T_B$ <p>[3]</p> $R_f(T_i) = \frac{28,4}{1 + e^{-0,185 \cdot (T_i - T_B - 18,4)}} \quad \text{wenn } T_i > T_B$ <p>Die Parameter T_B, F^* und ggf. t_1, sollten gebietsbezogen iterativ angepasst werden (RMSE als Fehlermaß). Ferner ist eine Höhenkorrektur nötig.</p> <p><i>Methodik u. a. in Pöhler et al. (2007), Chmielewski et al. (2009)</i></p>
Geeignet für (Parameter, zeitl. Auflösung)	Übertragung punktueller phänologischer Eintrittstermine (Beobachtung) in die Fläche, ggf. Füllen von Lücken in phänologischen Zeitreihen, Projektion auf Grundlage von Klimamodellen
Voraussetzungen für Anwendung	Möglichst lückenlose, lange Reihen von Eingangsdaten mit guter räumlicher Abdeckung zur Optimierung der Parameter und der internen Validierung, Vorliegen von Temperaturdaten in Tagesauflösung Bei Nutzung von Modellparametern aus Literatur auf Ähnlichkeit zwischen Modellgebiet und Gebiet, für das Parametrisierung vorgenommen wurde
Ergebnis / Interpretation	Abschätzungen der zukünftigen Vegetationsentwicklung sind möglich; Fehlerwerte liegen innerhalb der Standardabweichungen der Beobachtungsdaten, also im akzeptablen Bereich
Bewertung	Bei hier verwendeten Grundgleichungen nur Temperatureingangsdaten benötigt (unaufwendig in Datengrundlage), aber: keine Dormanzbrechung (Erfüllung eines Kältebedürfnisses) berücksichtigt → zukünftige Eintrittstermine, die sehr zeitig im Jahr simuliert werden, sind

	u.U. pflanzenphysiologisch nicht möglich
Beispiel	<i>Projektion phänologischer Phasen wildwachsender Pflanzen in Modellregion Dresden (Kapitel Phänologie in Bernhofer et al. (2011))</i>
Kontakt / Projekt	Maria Foltyn (ehemals LfULG) Technische Universität Bergakademie Freiberg foltyn@mailserver.tu-freiberg.de KLIMZUG-Projekt REGKLAM

Chmielewski, F.-M.; Blümel, K.; Henniges, Y.; Müller, A. (2009): Klimawandel und Obstbau in Deutschland. Endbericht des BMBF-Verbundprojekts KliO., Eigenverlag, Humboldt-Universität zu Berlin, 237 S

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden

Pöhler H, Chmielewski F-M, Jasper, K, Henniges Y, Scherzer J (2007): KliWEP - Abschätzung der Auswirkungen der für Sachsen prognostizierten Klimaveränderungen auf den Wasser- und Stoffhaushalt im Einzugsgebiet der Parthe. Weiterentwicklung von WaSiM-ETH: Implikation dynamischer Vegetationszeiten und Durchführung von Testsimulationen für sächsische Klimaregionen. Abschlussbericht zum FuE-Vorhaben des Sächsischen Landesamtes für Umwelt und Geologie

5.9.3 Objektive Wetterlagenklassifikation mit statistischen Verfahren

Übergeordnetes Ziel (Kategorie)	Raum-Zeit-Verfahren
Verfahren	Objektive Wetterlagenklassifikation mit statistischen Verfahren
Beschreibung + Literatur	Mit Hilfe von statistischen Verfahren Daten (atmosphärische Felder) in Gruppen eingeteilt werden, ohne vorher über die Gruppen Bescheid zu wissen. Huth et al. (2008);
Geeignet für (Parameter, zeitl. Auflösung)	Bodendruck, Geopotentielle Höhen und andere Größen, wie relative Feuchte, Temperatur, Vorticity, Schichtdicke usw.
Voraussetzungen für Anwendung	Meteorologische Felder sollten auf einem Gitter vorliegen (Reanalysedaten, Klimamodelldaten); ausgewählte Region sollte groß genug sein, um großskalige Phänomene aufzulösen; die Zeitreihe der Felder sollte genügend lang sein (am besten mehr als 30 Jahre bei täglichen Werten)
Ergebnis / Interpretation	Man erhält räumliche Muster (Wetterlagen), sowie eine Zeitserie in der jeder Zeitschritt (häufig 1 Tag) jeweils der am nächsten liegenden Wetterlage zugeordnet wird.
Bewertung	
Beispiel / Publikation	Mit Hilfe der in COST733 Software können verschiedenste Methoden zur Bestimmung von Wetterlagen: http://geo21.geo.uni-augsburg.de/cost733wiki/Cost733Software Literatur: Huth et al. (2008); Philipp et al. (2010)
Kontakt / Projekt	Peter Hoffmann Universität Hamburg, Meteorologisches Institut peter.hoffmann@zmaw.de KLIMZUG NORD

Huth, R. and Beck, C. and Philipp, A. and Demuzere, M. and Ustrnul, Z. and Cahynova, M. and Kysely, J. and Tveito, O. E., (2008): *Classifications of Atmospheric Circulation Patterns, Recent Advances and Applications, Trends and Directions in Climate Research: Ann. N.Y. Acad. Sci. 1146: 105-152*

Philipp, A., J. Bartholy, C. Beck, M. Erpicum, P. Esteban, X. Fettweis, R. Huth, P. James, S. Jourdain, F. Kreienkamp, T. Krennert, S. Lykoudis, S. C. Michalides, K. Pianko-Kluczynska, P. Post, D. R. Álvarez, R. Schiemann, A. Spekat and F. S. Tymvios (2010): *Cost733cat – A database of weather and circulation type classification. Physics and Chemistry of the Earth, 35, 360-373.*

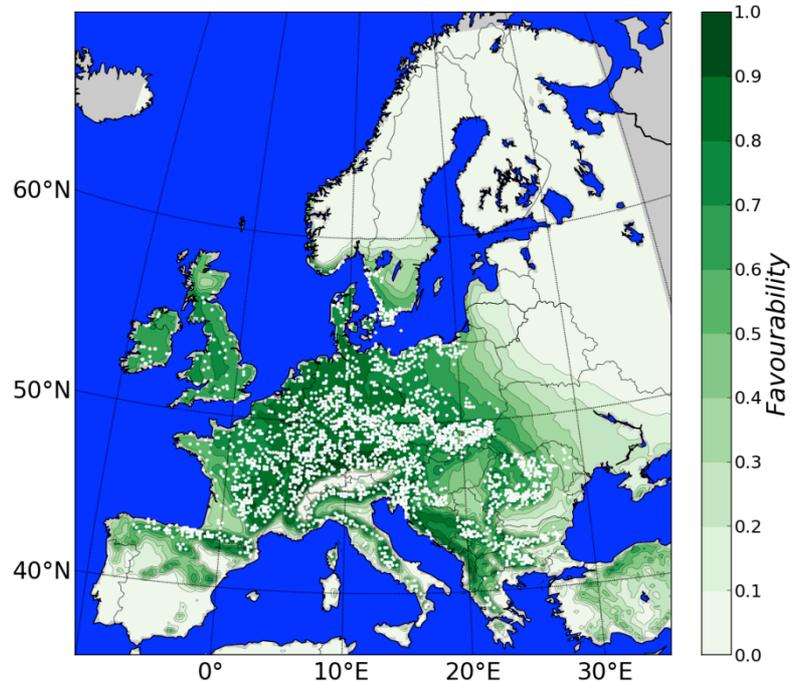
5.9.4 Generalisierte additive Modelle

Übergeordnetes Ziel (Kategorie)	Raum-Zeit-Verfahren
Verfahren	Generalisierte additive Modelle (GAM)
Beschreibung + Literatur	<p>GAMs sind semi-parametrische Erweiterungen von generalisierten linearen Modellen. Sie erlauben die Anpassung von Responsekurven durch eine nicht-parametrische Glättungsfunktion anstelle einer parametrischen. Das verbessert die Analyse des Reaktionsmusters von Arten auf Umweltveränderungen. GAMs können zur Analyse kontinuierlicher metrischer oder binomial verteilter Daten (0 und 1) genutzt werden. Ein GAM kann an eine Klimasimulation der nahen Vergangenheit mit Hilfe von Präsenz-Absenz-Daten der untersuchten Arten angepasst werden. Mit Hilfe der erzielten Modelle, visualisiert durch Responsekurven, kann eine räumliche Vorkommens-Wahrscheinlichkeit berechnet werden.</p>
Geeignet für (Parameter, zeitl. Auflösung)	Wahrscheinlichkeit von Artverbreitungen
Voraussetzungen für Anwendung	Präsenz-Absenz Daten geeigneter Arten. Gerasterte Daten von Klimaindices zur Beschreibung der Klimabedingungen.
Ergebnis / Interpretation	Das Ergebnis ist eine Zahl zwischen 0 (keine) und 1 (maximale Vorkommenswahrscheinlichkeit). Mit Hilfe einer Transformation in eine ‚Günstigkeit‘ (engl. Favourability, Real et al. 2006) wird die Umweltgünstigkeit oder Eignung des Standorts für die Art beschrieben.
Bewertung	Methode zur Erzeugung von Projektionen zukünftiger ‚favourabilities‘ von Standorten für Arten. Voraussetzung sind Präsenz-Absenz-Daten der Verbreitung einer Art.
Beispiel	S. Wood, Generalized additive models: an introduction with R, Vol. 66, CRC Press, 2006. S. Wood, Mixed GAM Computation Vehicle with GCV/AIC/REML

smoothness estimation (06 2012).

E. A. Freeman, G. Moisen, PresenceAbsence: An R package for presence absence analysis, *Journal of Statistical Software* 23 (11) (2008) 1 -31.

R. Real, A. M. Barbosa, J. M. Vargas, Obtaining environmental favourability functions from lo566 gistic regression, *Environmental and Ecological Statistics* 13 (2) (2006) 237{245.



,Günstigkeit' der Umweltbedingungen für *Fagus sylvatica* (Buche) in Europa auf Grundlage mittlerer Klimadaten der Periode 1971-2000.

Kontakt / Projekt	Nils Hempelmann, Helmholtz-Zentrum Geesthacht, Climate Service Center, Hamburg nils.hempelmann@hzg.de Wolfgang Falk, Bayerische Landesanstalt für Wald und Forstwirtschaft, Freising Wolfgang.Falk@lwf.bayern.de
ggf. Software	R package mgcv (Berechnung unterschiedlicher GAM) R package PresenceAbsence (Plausibilitätswerkzeuge)

5.10 Ensembleanalyse

Diese Rubrik bezieht sich auf ein Ensemble von Klimasimulationen. Eine Übertragung der Verfahren auf andere Bereiche, isb. auf ein Ensemble von Messreihen, wurde nicht geprüft.

Ein Ensemble von Modellsimulationen kann aus verschiedenen Modellen, aber nur einem Szenario (multi-model-ensemble), einem Modell und verschiedenen Szenarien (multi-scenario-ensemble), einem Modell und verschiedenen Parameterisierungsansätzen (multi-parameterisation-ensemble) oder einem Modell, einem Szenario und verschiedenen Realisierungen (multi-member-ensemble) bestehen und dient der Analyse unterschiedlicher Fragen.

Für die Auswertung und Anwendung der Modellergebnisse in Anpassungsprojekten sollte ein möglichst großes Ensemble genutzt werden, um Ergebnisse zu erzielen, die durch viele Modelle gestützt werden. Nur durch eine Ensembleanalyse können die jedem Modell inhärenten Unsicherheiten sinnvoll zur Bewertung der Ergebnisse genutzt werden. Handlungsoptionen und Interpretationshilfen findet man z.B. in Haensler et al. (2013).

Diese beruhen zum Teil auf den Empfehlungen des Weltklimarates (International Panel on Climate Change IPCC) zur Ensembleanalyse, die in Abschnitt 1.6 'The IPCC Assessments of Climate Change and Uncertainties' in Solomon et al. (2007) beschrieben werden. Dabei stehen vor allem die Unsicherheiten im Vordergrund, die eine Ensembleanalyse notwendig machen.

Die drei nachfolgenden Steckbriefe beschreiben die Perzentilanalyse (5.10.1), eine Wahrscheinlichkeitsaussage auf der Basis der IPCC-Vorgaben (5.10.2) und ein Beispiel für eine Robustheitsanalyse (5.10.3).

Literatur

Haensler, A., F. Saeed, D. Jacob, 2013: Assessing the robustness of projected precipitation changes over central Africa on the basis of a multitude of global and regional climate projections. Climatic Change, DOI: 10.1007/s10584-013-0863-8

Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.), 2007: Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change, Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.

Weiterführende Literatur:

Knutti, R., G. Abramowitz, M. Collins, V. Eyring, P. J. Gleckler, B. Hewitson, L. Mearns, 2010: Good Practice Guidance Paper on Assessing and Combining Multi Model Climate Projections, IPCC Expert Meeting on Assessing and Combining Multi Model Climate Projections, National Center for Atmospheric Research, Boulder, Colorado, USA, 25-27 January 2010.

Knutti, R., R. Furrer, C. Tebaldi, J. Cermak, G. A. Meehl, 2010: Challenges in Combining Projections from Multiple Climate Models, J.Climate, 23, 2739-2758.

5.10.1 Perzentilanalyse

Übergeordnetes Ziel (Kategorie)	Ensembleanalyse
Verfahren	Perzentilanalyse
Beschreibung + Literatur	Ein Ensemble von Klimasimulationen liefert für jeden Zeitschritt und jedes Zeitintervall eine Bandbreite von Ausgabegrößen pro Gitterbox. Aussagen daraus können durch verschiedene Techniken ermittelt werden. Eine Möglichkeit ist die Angabe von Perzentilen. Diese werden bestimmt durch Sortierung der Ensemblewerte des gewünschten Zeitintervalls nach ihrer Größe. Dann wird das X-te Perzentil ermittelt als der Wert, der einen Unterschreitungsanteil von X % besitzt. Das 95. Perzentil zum Beispiel hat den Wert, unterhalb dessen 95 % aller Werte liegen.
Geeignet für (Parameter, zeitl. Auflösung)	Jedes Ensemble von annähernd 100 und mehr Klimaparametern. Im Fall von weniger als 100 Daten müssen die Perzentile durch Interpolation zwischen den Werten bestimmt werden. Man erhält für jeden Zeitschritt der Simulationen und jede Gitterbox oder Station einen Satz an Perzentilwerten.
Voraussetzungen für Anwendung	mindestens 20 Ensemblemitglieder, besser mehr als 100.
Ergebnis / Interpretation	Meist wertet man das 15., 50. und 85. Perzentil aus, legt man weniger Wert auf die Randwerte auch das 25., 50. und 75. Perzentil.
Bewertung	50er Perzentil (Median) eignet sich besser als der Mittelwert zur Beschreibung der Ergebnisse von vielen Modellen, da einzelne Ausreißer diesen Wert nicht beeinflussen. Das Gleiche gilt für niedrige und hohe Perzentile.
Beispiel	Klimaatlas für Deutschland des Deutschen Wetterdienstes (www.dwd.de -> Klima + Umwelt -> Klima in der Zukunft -> Deutscher Klimaatlas)
Kontakt / Projekt	Barbara Hennemuth, HZG, Climate Service Center Barbara.hennemuth@hzg.de Diana Rechid, KLIMZUG-NORD, MPI für Meteorologie Diana.rechid@zmaw.de
ggf. Software	

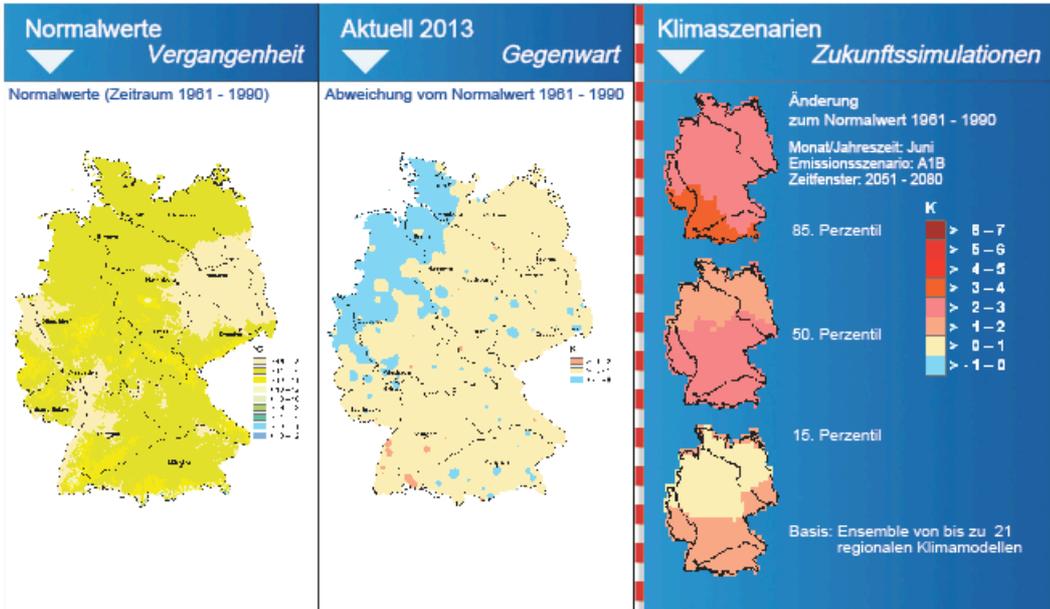
Deutscher Klimaatlas

Lufttemperatur

Juni 2013

Emissionsszenario: A1B

Zeitfenster: 2051 - 2080



Im Klimaatlas Deutschland zeigt der Deutsche Wetterdienst unser Klima von gestern, heute und morgen auf einen Blick. Dabei wird besonders anschaulich, wie sich die Mittelwerte der dargestellten Größen in Deutschland bis heute verändert haben und zukünftig verändern werden.

Zukünftige Klimazustände untersucht der DWD mit möglichst vielen regionalen Klimamodellen. Solche Ensemblerrechnungen führen zu einer großen Anzahl von möglichen Klimazuständen, die statistisch als Perzentile ausgewertet werden: Das 50. Perzentil gibt den Wert an, für den jeweils die Hälfte der Modellsimulationen höhere bzw. niedrigere Änderungen zeigen. 15 % aller Modellergebnisse liegen unterhalb des 15. Perzentils oder erreichen dieses gerade genau. Die übrigen 85 % der Modellsimulationen zeigen dagegen größere Änderungen. Entsprechend liegen 85 % unterhalb des 85. Perzentils oder erreichen dieses gerade genau. Zwischen das 15. und 85. Perzentil fallen somit insgesamt 70 % aller Modellergebnisse.

Die Modelleregebnisse werden dabei mathematisch aufsteigend sortiert. So ist z. B. der Wert -70 immer kleiner als der Wert -20. Die kleineren Werte werden immer dem kleineren Perzentil zugeordnet, die größeren Werte immer dem größeren Perzentil.

Perzentile sind nicht identisch mit Eintrittswahrscheinlichkeiten.

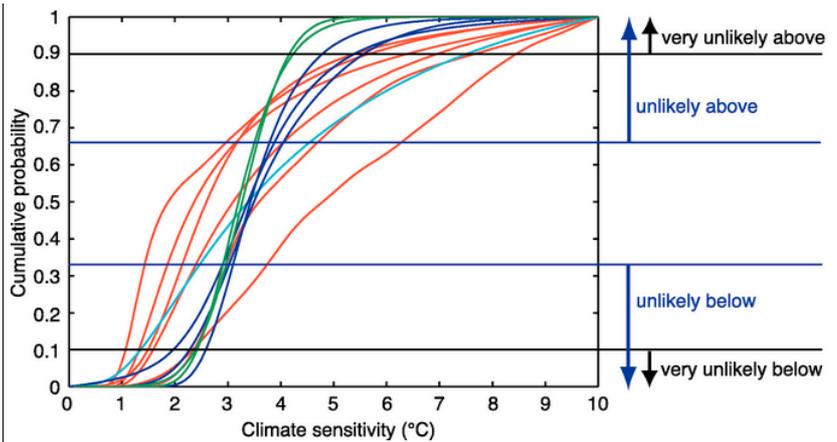
Weitere Informationen finden Sie in den Erläuterungen unter:

www.dwd.de/klimaatlas

Erzeugt am 16.07.2013
um 08:38 Uhr

5.10.2 Wahrscheinlichkeit der Ergebnisse / likelihood of outcome

Übergeordnetes Ziel (Kategorie)	Ensembleanalyse																				
Verfahren	Wahrscheinlichkeit der Ergebnisse / likelihood of outcome																				
Beschreibung + Literatur	<p>Ein einfaches Maß für eine standardisierte Bewertung von Ergebnissen eines Ensembles von Klimasimulationen ist der Grad der Übereinstimmung innerhalb des Ensembles. Nach Solomon et al. (Eds., 2007), Abschnitt 1.6 werden als Standardangaben festgelegt:</p> <p>Likelihood Terminology Likelihood of the occurrence/ outcome</p> <table> <tr> <td>Virtually certain</td> <td>> 99% probability</td> </tr> <tr> <td>Extremely likely</td> <td>> 95% probability</td> </tr> <tr> <td>Very likely</td> <td>> 90% probability</td> </tr> <tr> <td>Likely</td> <td>> 66% probability</td> </tr> <tr> <td>More likely than not</td> <td>> 50% probability</td> </tr> <tr> <td>About as likely as not</td> <td>33 to 66% probability</td> </tr> <tr> <td>Unlikely</td> <td>< 33% probability</td> </tr> <tr> <td>Very unlikely</td> <td>< 10% probability</td> </tr> <tr> <td>Extremely unlikely</td> <td>< 5% probability</td> </tr> <tr> <td>Exceptionally unlikely</td> <td>< 1% probability</td> </tr> </table>	Virtually certain	> 99% probability	Extremely likely	> 95% probability	Very likely	> 90% probability	Likely	> 66% probability	More likely than not	> 50% probability	About as likely as not	33 to 66% probability	Unlikely	< 33% probability	Very unlikely	< 10% probability	Extremely unlikely	< 5% probability	Exceptionally unlikely	< 1% probability
Virtually certain	> 99% probability																				
Extremely likely	> 95% probability																				
Very likely	> 90% probability																				
Likely	> 66% probability																				
More likely than not	> 50% probability																				
About as likely as not	33 to 66% probability																				
Unlikely	< 33% probability																				
Very unlikely	< 10% probability																				
Extremely unlikely	< 5% probability																				
Exceptionally unlikely	< 1% probability																				
Geeignet für (Parameter, zeitl. Auflösung)	Quantifizierbare Ergebnisse (z.B. Temperatur) eines ausreichend umfangreichen Ensembles von Klimasimulationen mit unterschiedlichen Klimamodellen, die in einer Häufigkeitsverteilung dargestellt werden																				
Voraussetzungen für Anwendung	Die Daten müssen probabilistisch auswertbar sein, d.h. in einer Häufigkeitsverteilung darstellbar sein und der Wert einer zu prüfenden Aussage muss vorgegeben werden (bspw. das Vorzeichen eines Klimaänderungssignals, die Überschreitung eines Schwellenwert durch einen Modellparameter).. Es muss eine quantifizierbare Aussage vorgegeben sein (s.o. in Beschreibung).																				
Ergebnis / Interpretation	Die Interpretation hängt von der Art des Ergebnisses ab. Wird das Vorzeichen eines Trends abgefragt, kann die Richtungssicherheit durch die Anzahl der Modelle mit einer Übereinstimmung des Vorzeichens des Änderungssignals bewertet werden. Wird die Temperaturzunahme ermittelt, kann die Wahrscheinlichkeit einer Zunahme der Temperatur bspw. größer als 3 K bewertet werden.																				
Bewertung	Einfache Bestimmung. In Übereinstimmung mit den Vorgaben des IPCC.																				
Beispiel																					



©IPCC 2007: WG1-AR4

Cumulative distributions of climate sensitivity derived from observed 20th-century warming (red), model climatology (blue), proxy evidence (cyan) and from climate sensitivities of AOGCMs (green). Horizontal lines and arrows mark the boundaries of the likelihood estimates defined in the IPCC Fourth Assessment Uncertainty Guidance

Quelle:

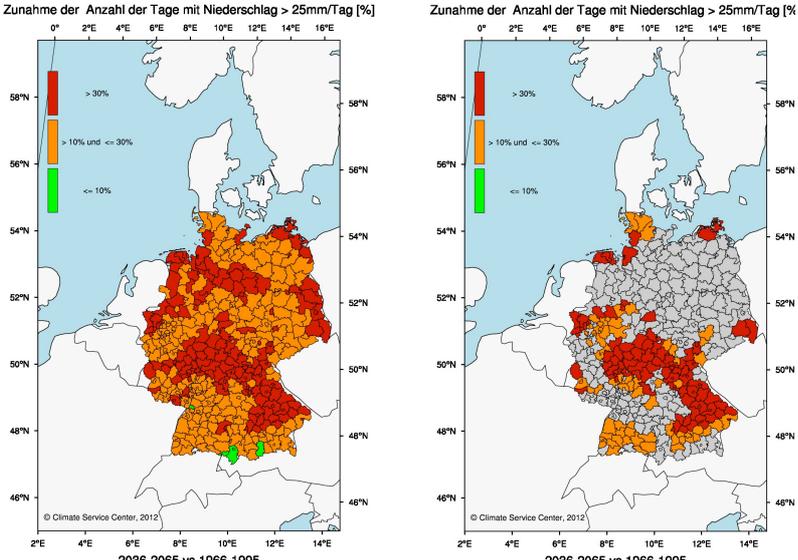
Solomon et al. (Es, 2007)

Kontakt / Projekt	Barbara Hennemuth Helmholtz-Zentrum Geesthacht, Climate Service Center barbara.hennemuth@hzg.de Diana Rechid, MPI für Meteorologie, Hamburg diana.rechid@zmaw.de
ggf. Software	

Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.), 2007: Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change, 2007, Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.

5.10.3 Robustheit eines Klimaänderungssignals

Übergeordnetes Ziel (Kategorie)	Ensembleanalyse
Verfahren	Robustheit eines Klimaänderungssignals
Beschreibung + Literatur	<p>Die Robustheit eines Ergebnisses ist im IPCC Third Assessment Report - Climate Change 2001: Synthesis Report, Question 9 definiert:</p> <p>'In this report, a robust finding for climate change is defined as one that holds under a variety of approaches, methods, models, and assumptions and one that is expected to be relatively unaffected by uncertainties.'</p> <p>Die Prüfung der Robustheit verlangt verschiedene Abfragen, hier wird die Methode beschrieben, die in den Klimasignalkarten angewendet wird</p> <p>http://www.climate-service-center.de/031443/index_0031443.html.de</p> <p>1. Übereinstimmung (s. Steckbrief Wahrscheinlichkeitsanalyse)</p> <p>Stimmen mehr als 66% der betrachteten Simulationen in der Richtung der Änderungen überein, gilt diese nach IPCC (2007) als „wahrscheinlich“.</p> <p>2. Signifikanz</p> <p>Prüfung, ob sich die Verteilung der zukünftigen Größen von der in der Referenzperiode signifikant unterscheidet. Es müssen mindestens 66% der Simulationen einen geeigneten (U-Test oder Mann-Whitney-Wilcoxon Test) Signifikanztest bestehen.</p> <p>3. Unabhängigkeit von kleinen zeitlichen Verschiebungen</p> <p>Die Zukunftsperiode und die Referenzperiode werden um 1 ... 5 Jahre nach vor und hinten verschoben. Die Streuung der Änderungssignale über alle so definierten Zeitintervalle darf nicht größer sein als 25% des berechneten Klimaänderungssignals der mittleren Perioden.</p> <p>Die Methode ist detailliert beschrieben unter:</p> <p>http://www.climate-service-center.de/031451/index_0031451.html.de</p>
Geeignet für (Parameter, zeitl. Auflösung)	Klimaänderungssignale - gemittelt über mindestens 30 Jahre, - verschiedener Klimasimulationen, sowie ermittelte Unsicherheiten über das Mittelungsintervall.
Voraussetzungen für Anwendung	Für den gewählten Signifikanztest ist u.U. eine Mindestanzahl an Daten gefordert.
Ergebnis / Interpretation	Belastbare Aussagen über Klimaänderungssignale, die auf einem Ensemble von Klimasimulationen (verschiedene Modelle, Realisierungen oder Projektionen) beruhen.

Bewertung	Die Robustheitsprüfung liefert keine quantitativen Aussagen über das Klimaänderungssignal.
Beispiel	<p>Klimasignalkarten http://www.climate-service-center.de/031486/index_0031486.html.de</p>  <p>Zunahme der Anzahl der Tage mit Niederschlag > 25mm/Tag [%]</p> <p>Zunahme der Anzahl der Tage mit Niederschlag > 25mm/Tag [%]</p> <p>2036-2065 vs 1966-1995</p> <p>2036-2065 vs 1966-1995</p> <p>Zunahme der Anzahl der Tage mit Starkregen (>25 mm/Tag) für den Zeitraum 2036 bis 2065 verglichen mit dem Referenzzeitraum von 1966 bis 1995 [%]. Median aus einem Ensemble von 28 regionalen Klimaänderungssimulationen (links), rechts nach Durchführung des dreistufigen Robustheitstests. Graue Regionen bestanden mindestens einen der drei Tests nicht. Darstellung auf Landkreisen. Im Falle der Zunahme der Starkregentage ist also das Klimaänderungssignal nur für einige Regionen Deutschlands robust.</p>
Kontakt / Projekt	<p>Susanne Pfeifer Helmholtz-Zentrum Geesthacht, Climate Service Center susanne.pfeifer@hzg.de Diana Rechid, MPI für Meteorologie, Hamburg diana.rechid@zmaw.de</p>
ggf. Software	keine

IPCC, 2001: *Climate Change 2001: Synthesis Report. A Contribution of Working Groups I, II, and III to the Third Assessment Report of the Intergovernmental Panel on Climate Change* [Watson, R.T. and the Core Writing Team (eds.)]. Cambridge University Press, Cambridge, United Kingdom, and New York, NY, USA, 398 pp.

Pfeifer, S., Hänsler, A., Ries, H., Weber, B., Jacob, D., Rechid, D., Teichmann, C., Gobiet, A., Mudelsee, M., 2013: Mapping the Robustness of Regional Climate Change Information, Submitted to: *Journal of Applied Meteorology and Climatology*.

5.10.4 Darstellungen

Im Folgenden sind einige Abbildungen dargestellt, die Möglichkeiten aufzeigen, wie die komplexen Aussagen einer Ensembleanalyse in einem Bild verständlich vermittelt werden können. Sie entstammen dem Dokument

Climate-Fact-Sheets - Lese- und Interpretationsanleitung für die Climate-Fact-Sheets
Climate Service Center, Hamburg, Mai 2013

http://www.climate-service-center.de/036238/index_0036238.html.de

Die Datenbasis umfasst die globalen Klimasimulationen des ‚Coupled Model Intercomparison Project No.3‘ (CMIP3) und die regionalen Klimasimulationen des EU-Projekts ENSEMBLES.

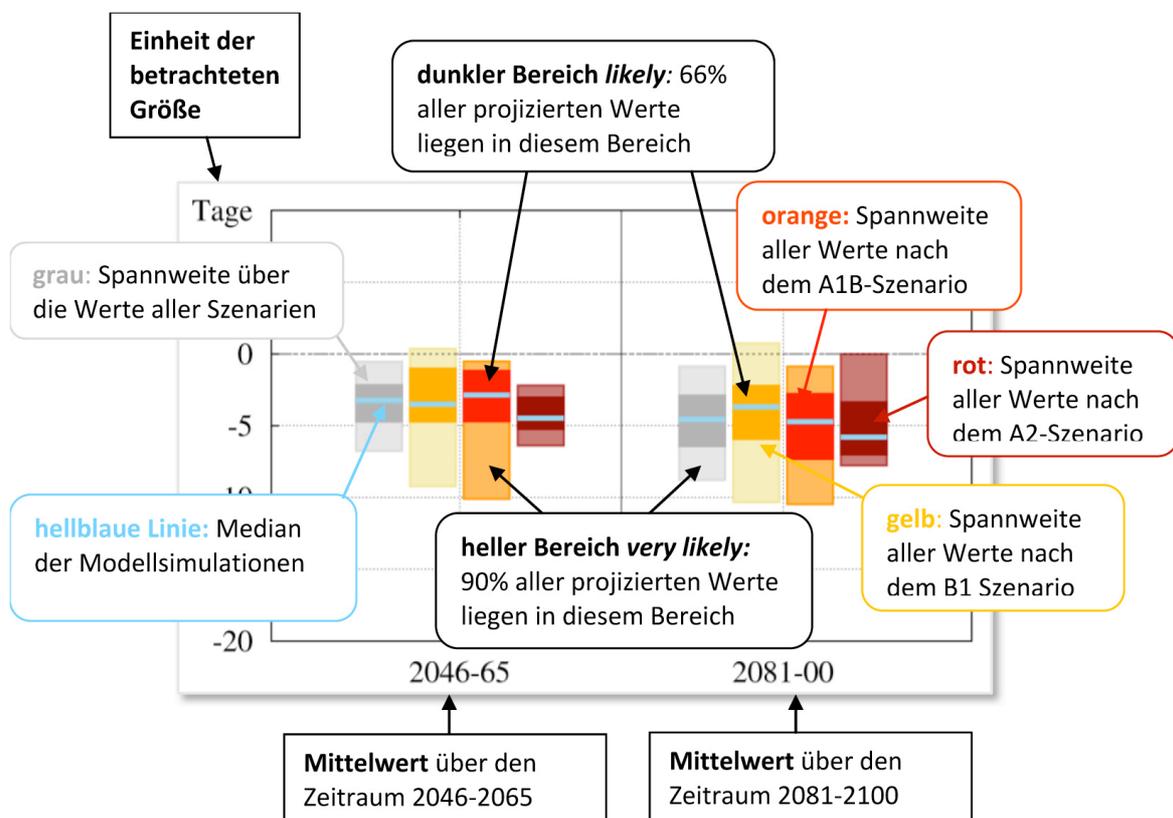


Abbildung 1: Diese Graphik zeigt die projizierte Änderung eines Parameters in den Zeiträumen 2046-2065 und 2081-2100 gegenüber dem Referenzzeitraum 1961-1990. Auf den Balken sind die Linie des Medians und die Bereiche der Wahrscheinlichkeit ‚likely‘ und ‚very likely‘ markiert.

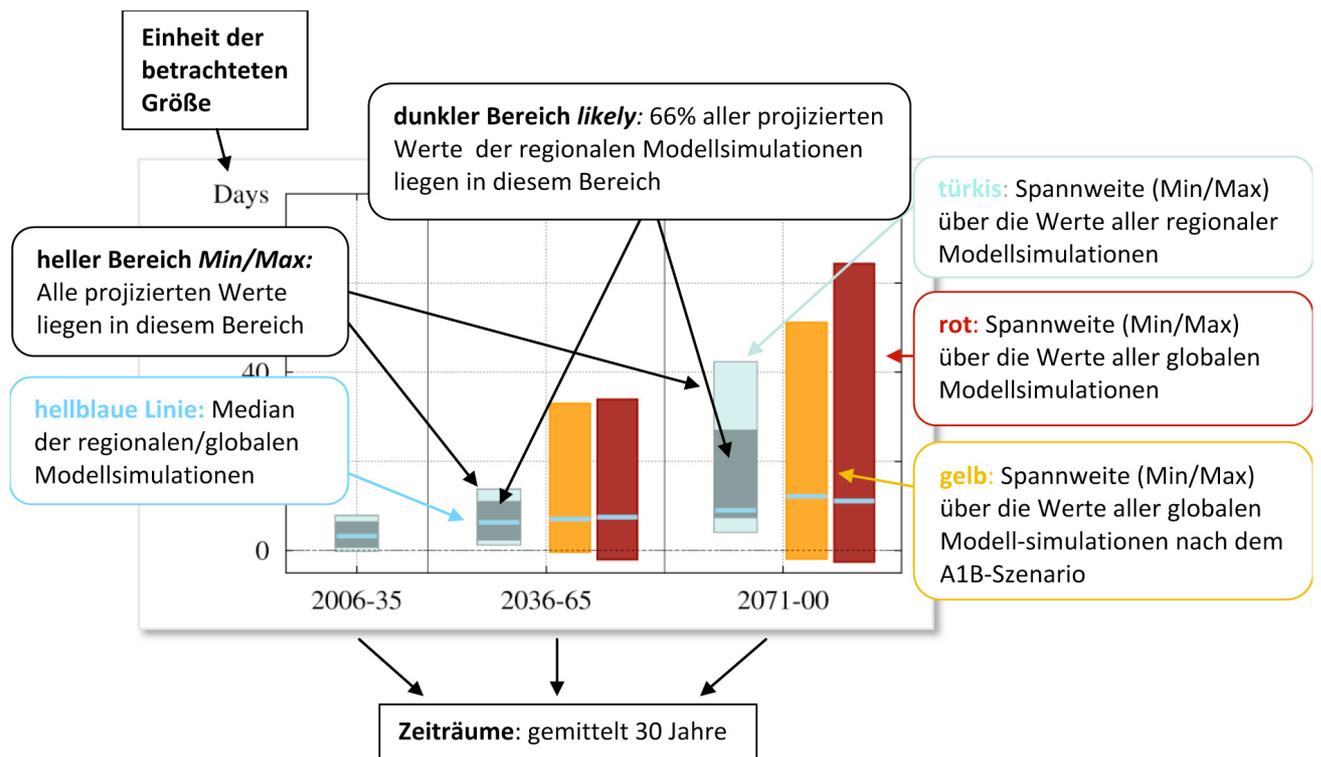


Abbildung 2: Diese Graphik zeigt die projizierte Änderung eines Parameters in den Zeiträumen 2006-2035, 2026-2065 und 2071-2100 gegenüber dem Referenzzeitraum 1961-1990. Auf den Balken sind die Linie des Medians, der Bereich der Wahrscheinlichkeit ‚likely‘ und die gesamte Spannweite markiert.

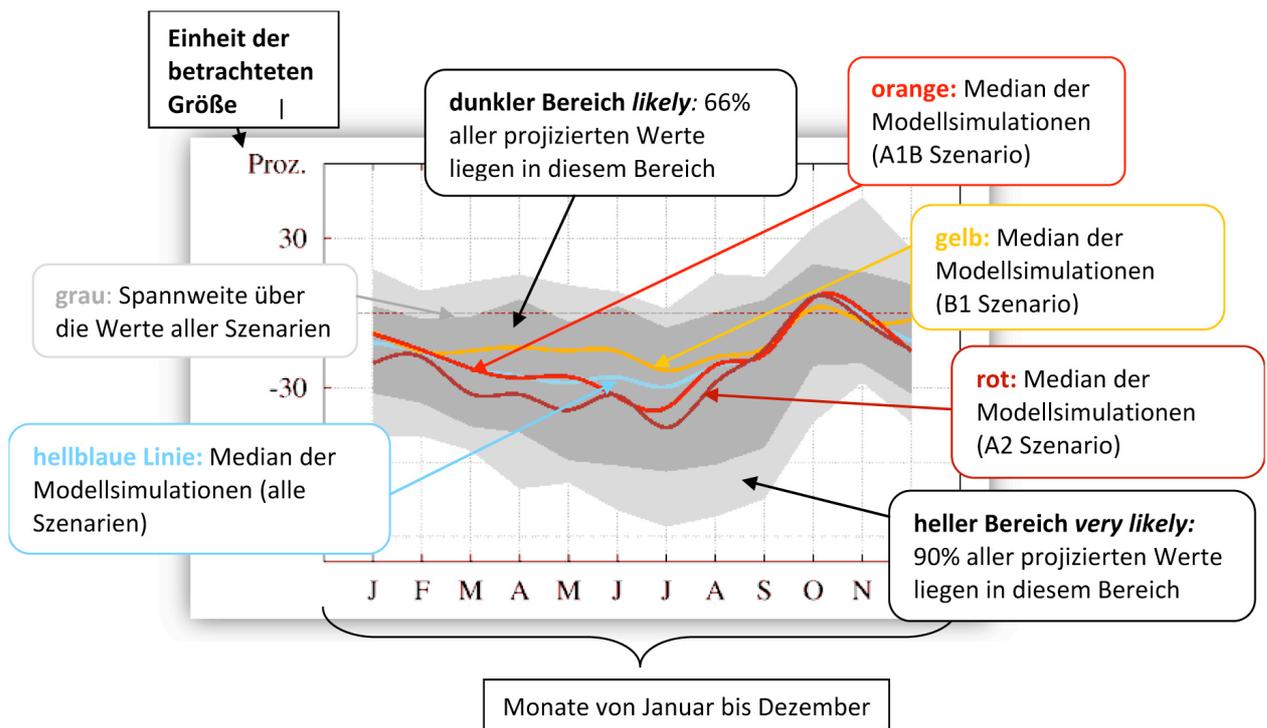


Abbildung 3: Diese Graphik zeigt die projizierte Änderung des Jahresgangs eines Parameters in % in dem Zeitraum 2071-2100 gegenüber dem Referenzzeitraum 1961-1990. Die Werte werden als 30jährige Mittel dargestellt. Eingezeichnet sind die Linien des Medians aller Szenarien und einzelner Szenarien und die Bereiche ‚likely‘ und ‚very likely‘.

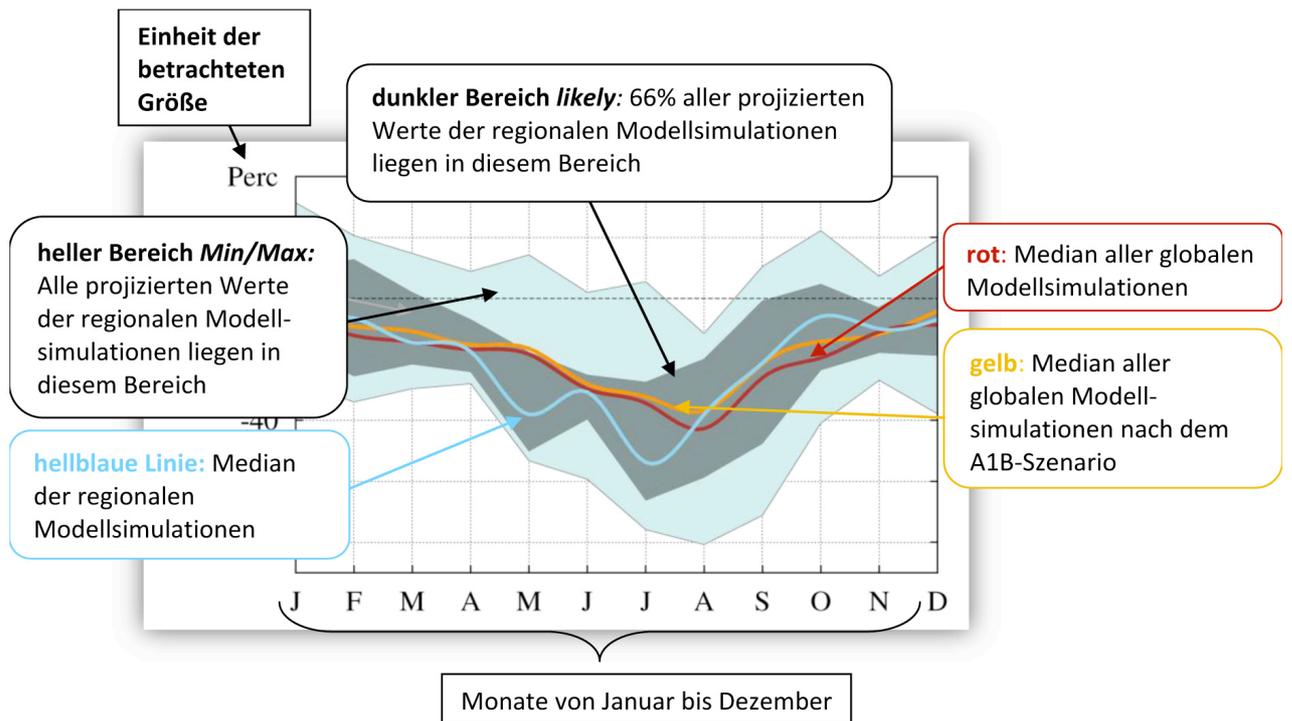


Abbildung 4: Diese Graphik zeigt die projizierte Änderung des Jahresgangs eines Parameters in % in dem Zeitraum 2071-2100 gegenüber dem Referenzzeitraum 1961-1990. Die Werte werden als 30jährige Mittel dargestellt. Eingezeichnet sind die Linien des Medians aller Szenarien und einzelner Szenarien und die Bereiche ‚likely‘ und die gesamte Spannweite.

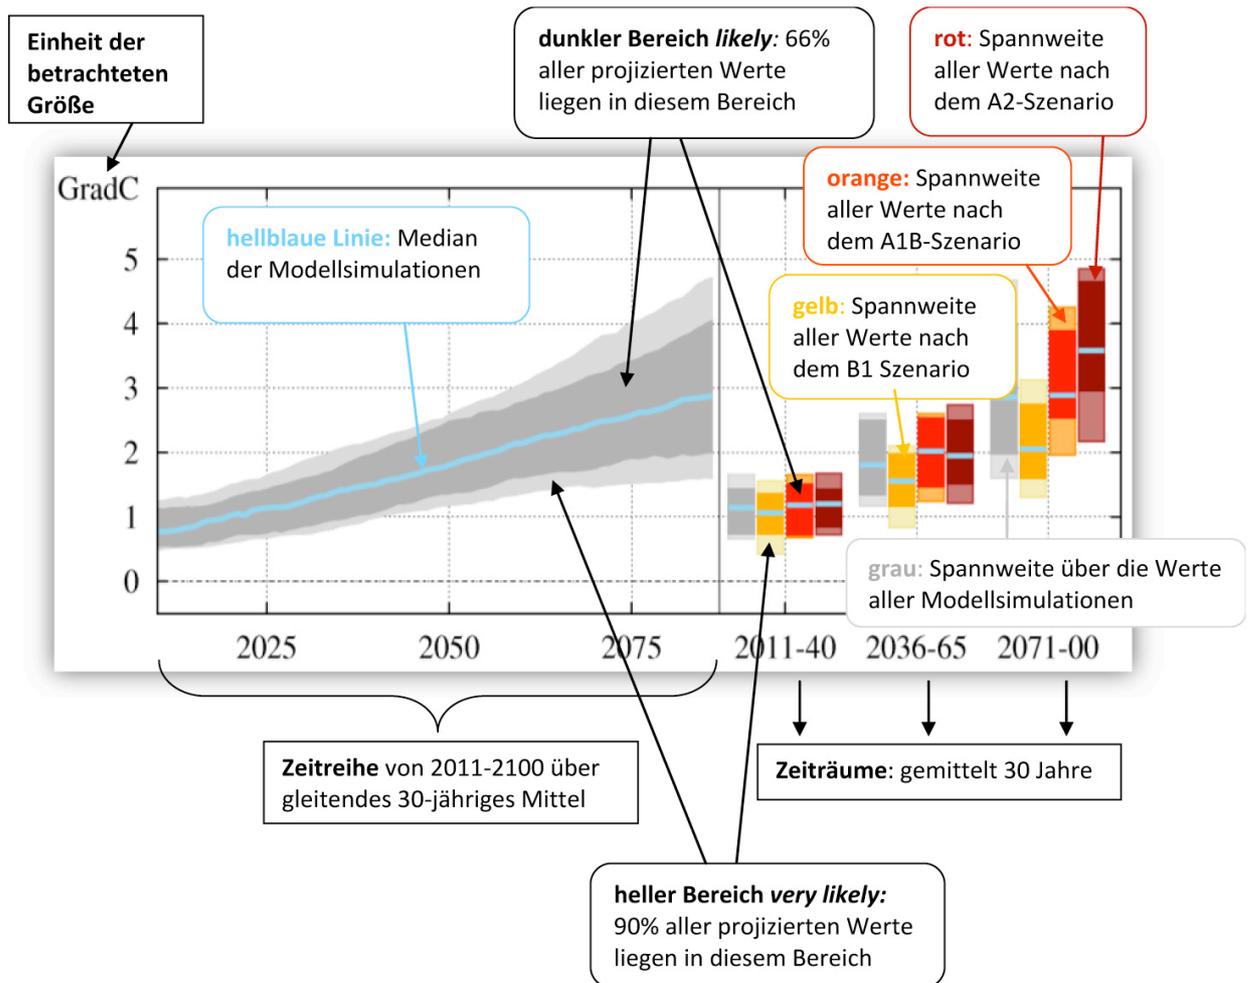


Abbildung 5: Diese Graphik zeigt im linken Teil die Zeitreihe des Medians der Temperatur als gleitendes Mittel über 30 Jahre von 2011 bis 2100 und der Bereiche ‚likely‘ und ‚very likely‘. Im rechten Teil sind 30-Jahresmittelwerte Jahresmittelwerte des Medians und der Bereiche ‚likely‘ und ‚very likely‘ für drei Zeitabschnitte und drei verschiedene Szenarien gezeigt.

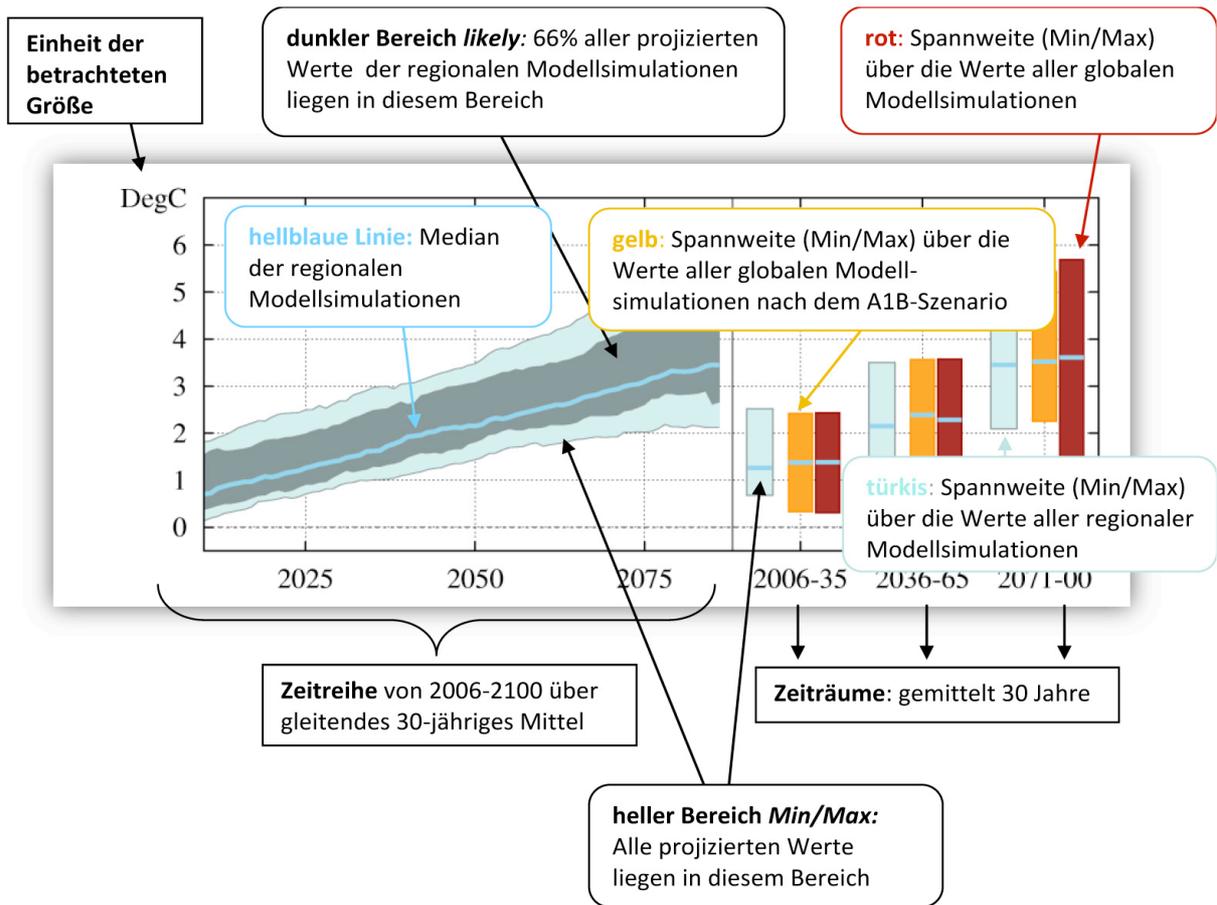


Abbildung 6: Diese Graphik zeigt die Zeitreihe des Medians und des Bereichs ‚likely‘ und der gesamten Spannbreite der projizierten Temperaturänderung als gleitendes Mittel über 30 Jahre von 2011 bis 2100. Im rechten Teil sind 30-Jahresmittelwerte des Medians, des Bereichs ‚likely‘ und der gesamten Spannbreite für drei Zeitabschnitte und für alle Globalmodelle, Regionalmodelle und der Globalmodelle für das Szenario A1B gezeigt.



Abbildung 7: Grafische Darstellung der Belastbarkeit und Signalstärke des projizierten Klimaänderungssignals am Beispiel einer mittleren Belastbarkeit und einer moderaten Signalstärke. Die Größen Belastbarkeit und Signalstärke sind in *Climate-Fact-Sheets - Lese- und Interpretationsanleitung für die Climate-Fact-Sheets, Climate Service Center, Hamburg, Mai 2013* http://www.climate-service-center.de/036238/index_0036238.html.de erklärt.

Literatur

Arbeitsgemeinschaft aqua plan GmbH, hydro & meteo, dr. Papadakis GmbH, 2010: *Extremwertstatistische Untersuchung von Starkniederschlägen in NRW (ExUS) Veränderung in Dauer, Intensität und Raum auf Basis beobachteter Ereignisse und Auswirkungen auf die Eintretenswahrscheinlichkeit. Abschlussbericht, erstellt für das Landesamt für Natur, Umwelt und Verbraucherschutz Nordrhein-Westfalen (LANUV NRW), Recklinghausen, 304 pp*

Arbeitskreis KLIWA (Hrsg.), 2011: *Langzeitverhalten von Grundwasserständen, Quellschüttungen und grundwasserbürtigen Abflüssen in Baden-Württemberg, Bayern und Rheinland-Pfalz. KLIWA-Berichte, Heft 16, Bezug über LUBW, Karlsruhe, BLU, Hof, LUWG, Mainz, 149 ff.*

Behr, F. J. & Lutz, S. (1989): *Ein schneller Algorithmus zur bilinearen Interpolation in Ankerpunktnetzen. Zeitschrift für Photogrammetrie und Fernerkundung, Bildmessung und Luftbildwesen, Heft 6, 57/1989, 222-229.*

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2009): *Das Klima in der REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 1, Rhombos-Verlag Dresden*

Bernhofer C, Matschullat M, Bobeth A (Hrsg. 2011): *Klimaprojektionen für die REGKLAM-Modellregion Dresden. Publikationsreihe des BMBF-geförderten Projektes REGKLAM – regionales Klimaanpassungsprogramm für die Modellregion Dresden, Heft 2, Rhombos-Verlag Dresden*

Bülow, K. (2010): *Zeitreihenanalyse von regionalen Temperatur- und Niederschlags-simulationen in Deutschland, Dissertation, Uni-Hamburg, Berichte zur Erdsystem Forschung 75, 2010.*

Burrough & McDonnell (2004): *Principles of Geographical Information Systems. Oxford.*

Butler, C. (1985): *Statistics in Linguistics. Web-Edition, <http://www.uwe.ac.uk/hlss/llas/statistics-in-linguistics/bkindex.shtml> (zuletzt abgerufen am 27.06.2013), University of West England, Bristol*

Chmielewski, F.-M.; Blümel, K.; Henniges, Y. und Müller, A. (2009): *Klimawandel und Obstbau in Deutschland. Endbericht des BMBF-Verbundprojekts KliO., Eigenverlag, Humboldt-Universität zu Berlin, 237 S.*

Chu, Pao-Shin, Jianxin Wang, 1998: *Modeling Return Periods of Tropical Cyclone Intensities in the Vicinity of Hawaii*. J. Appl. Meteor., 37, 951–960.*
doi: [http://dx.doi.org/10.1175/1520-0450\(1998\)037<0951:MRPOTC>2.0.CO;2](http://dx.doi.org/10.1175/1520-0450(1998)037<0951:MRPOTC>2.0.CO;2)

Clarke & Warwick (2001): *Change in Marine Communities: An Approach to Statistical Analysis and Interpretation. PRIMER-E, Plymouth, UK, 172 S.*

Coles, S. (2001): *An Introduction to Statistical Modeling of Extreme Values. Springer-Verlag, London.*

DAS –Deutsche Anpassungsstrategie an den Klimawandel, 2008:
<http://www.bmu.de/klimaschutz/downloads/doc/42783.php>

Deutschländer, T., Daleane, C., (2012): *Auswertung regionaler Klimaprojektionen für Deutschland hinsichtlich der Änderung des Extremverhaltens von Temperatur, Niederschlag*

und Windgeschwindigkeit, Abschlussbericht des Forschungsvorhabens der ressortübergreifenden Behördenallianz des BBK, THW, DWD & UBA, 153S.

DVWK Merkblatt 251 (1999), Statistische Analyse von Hochwasserabflüssen. ATV-DVWK-Regelwerk, DVWK, Bonn.

DVWK-Regel 101 (1976) Empfehlung zur Berechnung der Hochwasserwahrscheinlichkeit, DVWK, Bonn.

DVWK Regel 121 (1992): Niedrigwasseranalyse Teil II: Statistische Untersuchung der Unterschreitungsdauer und des Abflussdefizits, DVWK, Bonn.

Embrechts, P., Klüppelberg, C. und Mikosch, T. (1997): *Modelling Extremal Events. Vol. 33 of Applications in Mathematics.* Springer-Verlag, New York, 648 S.

Falk, W., Dietz, E., Grünert, S., Schultze, B. und Kölling, C. (2008): *Wo hat die Fichte genügend Wasser? - Neue überregional gültige Karten des Wasserhaushalts von Fichtenbeständen verbessern die Anbauentscheidung; LWF aktuell, 2008.*

Ferraz-Mello, S. (1981): *Estimation of periods from unequally spaced observations. The Astronomical Journal* 86, 4, 619-624.

Field, C.B. and Coauthors, Eds. (2012): *Managing the risks of extreme events and disasters to advanced climate change adaptation. Spec.Report of Intergovernmental Panel on Climate Change, Cambridge University Press, 19pp.*

Freeman, E.A., G. Moisen (2008:) *PresenceAbsence: An R package for presence absence analysis, Journal of Statistical Software* 23, 111 -31.

Gupta, H. V.; Sorooshian, S. und Yapo, O. P. (1999): *Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. In: Journal of Hydraulic Engineering* 4, Nr. 2, S. 135-143

Hammel, K. und Kennel, M. (2001): *Charakterisierung und Analyse der Wasserverfügbarkeit und des Wasserhaushalts von Waldstandorten in Bayern mit dem Simulationsmodell BROOK90. Forstliche Forschungsberichte München, 185, 135 S.*

Hartkamp et al. (1999): *Interpolation Techniques for Climate Variables. Geographic Information Systems. Series 99-01.*

Hellmers, S. (2010): *Hydrological Impacts of Climate Change on Flood Probability in Small Urban Catchments and Possibilities of Flood Risk Mitigation, ISBN 978-3-937693-13-2, Wasserbauschrift Band 13.*

Henson, R. 2011, *The rough guide to climate change, ISBN 13:978-1-84836-579-7, 401pp.*

Hoffmann, P., Krüger, O., Schlünzen, K.H. (2011): *A statistical model for the urban heat island and its application to a climate change scenario. Int. J. Climatol., 32:1238-1248, doi: 10.1002/joc.2348.*

Hoffmann, P., Krüger, O., Schlünzen, K.H. (2011): *A statistical model for the urban heat island and its application to a climate change scenario. International Journal of Climatology (accepted).*

Hong et al. (2005): *Spatial interpolation of monthly mean climate data for china. In: International Journal of Climatology, Vol. 25, 1369-1379.*

Huth, R. and Beck, C. and Philipp, A. and Demuzere, M. and Ustrnul, Z. and Cahynova, M. and Kysely, J. and Tveito, O. E., (2008): *Classifications of Atmospheric Circulation Patterns, Recent Advances and Applications, Trends and Directions in Climate Research: Ann. N.Y. Acad. Sci.* 1146: 105-152

Jacob D, Göttel H, Kotlarski S, Lorenz P, Sieck K (2008): *Klimaauswirkungen und Anpassung in Deutschland: Erstellung regionaler Klimaszenarien für Deutschland mit dem Klimamodell REMO. Forschungsbericht 204 41 138 Teil 2, i.A. des UBA Dessau*

Jacob D, Bülow K, Kotova L, Moseley C, Petersen J, Rechid D. (2011): *Regionale Klimasimulationen für Europa und Deutschland – Ensemble-Simulationen für die Klimafolgenforschung. – in Vorbereitung*

Jendritzky, M., T. Grothmann, D. Schröter, C. Hasse, U. Fritsch, W. Cramer (2007): *Klimawandel in Deutschland – Vulnerabilität und Anpassungsstrategien klimasensitiver Systeme. Umweltbundesamt, Forschungsbericht 201 41 253, UBA-FB 000844, ISSN 1611-8855*

Kabas (2005): *Das Klima in Südösterreich 1961-2004. Wissenschaftlicher Bericht Nr.4-2005. http://www.uni-graz.at/igam7www_wcv-wissber-nr4-tkabas-okt2005.pdf*

Katz, Richard W, Parlange, Marc B, and Naveau, Philippe: *Statistics of extremes in hydrology, Advances in Water Resources* 25(8-12), 1287–1304, 2002

Keuler, K., A. Block, W. Ahrens, D. Jacob, D. Rechid, L. Kotova, S. Kotlarski, D. Heimann, M. Zemsch, R. Knoche, E. Dittmann, A. Walter, F. Berger, and M. Sommer, 2006: *Quantification of uncertainties in regional climate and climate change simulations (QUIRCS).*

Kreienkamp, F. H. Huebener, C. Linke und A. Spekat, 2012: *Good practice for the usage of climate model simulation results - a discussion paper. Environmental Systems Research* 2012, <http://www.environmentalsystemsresearch.com/content/1/1/9>

Kreiß, J.-P., G. Neuhaus, 2006: *Einführung in die Zeitreihenanalyse, Springer-Verlag.*

Krüger, O & J-S von Storch, *A simple empirical model for decadal climate prediction, Journal of Climate*, 2011, doi: 10.1175/2010JCLI3726.1.

Kuratorium für Forschung im Küsteningenieurwesen (2002): *Die Küste - EAK 2002: Empfehlungen für die Ausführung von Küstenschutzwerken, Bd. 65, Westholsteinische Verlagsanstalt Boyens und Co., Heide i. Holstein. S. 285-291.*

Leander, R., T. Adri Buishand (2007): *Resampling of regional climate model output for the simulation of extreme river flows; Journal of Hydrology* 332, 487-496

Leps & Smilauer, 2003: *Multivariate Analysis of Ecological Data using CANOCO.*

Lilliefors Test. In: *Encyclopedia of Statistical Sciences. John Wiley & Sons, 2006, doi:10.1002/0471667196.ess1451.pub2*

Longley et al. (2001): *Geographic Information Systems and Science, Chichester.*
Tobin et al. (2011): *Improved interpolation of meteorological forcings for hydrologic applications in a Swiss Alpine region. In: Journal of Hydrology.*

Ly et al. (2010): *Spatial interpolation of daily rainfall at catchment scale: a case study of the Ourthe and Ambleve catchments, Belgium. In: Hydrology and Earth System Sciences Discussions, Vol. 7, pp 7383-7416, 27-9-2010.*

Marques, J. C., Salas, F., Patricio, J., Teixeira, C. M., & Neto, J. M. (2009). *Ecological indicators for Coastal and estuarine environmental assessment - a user guide*. WIT Press.

McCune, B. and M. J. Mefford. 1999. *PC-ORD. Multivariate Analysis of Ecological Data, Version 4.0*. MjM Software Design, Gleneden Beach, Oregon. 237 pp.

Morgan G., H. Dowlatabadi, M. Henrion, D. Keith, R. Lempert, S. McBrid, M. Small, T. Wilbanks (eds.), 2009: *SAP 5.2 CoverCCSP, 2009: Best practice approaches for characterizing, communicating, and incorporating scientific uncertainty in decisionmaking*. National Oceanic and Atmospheric Administration, Washington D.C., USA.

Moriasi, D. N.; Arnold, J. G.; Liew, M. W. V.; Bingner, R. L.; Harmel, R. D.; Veith, T. L.: *Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations*. In: *Transactions of the ASABE 50* (2007), Nr. 3, S. 885-900
Mudelsee, M., *Climate Time Series, Analysis, 2010*, pp 74-77.

Mudelsee M (2010) *Climate Time Series Analysis: Classical Statistical and Bootstrap Methods*. Springer, Dordrecht Heidelberg London New York. 474 pp; *Atmospheric and Oceanographic Sciences Library, Vol. 42]*

Mudelsee, M., D. Chirila, T. Deutschländer, C. Döring, J.O. Haerter, S. Hagemann, H. Hoffmann, D. Jacob, P. Krahe, G. Lohmann, C. Moseley, E. Nilson, O. Panferov, T. Rath, B. Tinz, 2010: *Climate Model Bias Correction und die Deutsche Anpassungsstrategie*. *Mitteilungen der Deutschen Meteorologischen Gesellschaft 03/2010*.

Mudersbach, Ch. and Jensen, J. (2009): *Extremwertstatistische Analyse von historischen, beobachteten und modellierten Wasserständen an der Deutschen Ostseeküste, Die Küste, Heft 75, Sonderheft MUSTOK, S. 131-162, Boyens Medien GmbH, Heide i. Holstein*

Mudersbach, Ch. and Jensen, J. (2010): *Non-stationary extreme value analysis of annual maximum water levels for designing coastal structures on the German North Sea coastline, Journal of Flood Risk Management , Vol. 3., Issue 1, pp. 52-62, DOI:10.1111/j.1753-318X.2009.01054.x*

Muthers, S.; Matzarakis, A.; Koch, E (2010). *Climate Change and Mortality in Vienna—A Human Biometeorological Analysis Based on Regional Climate Modeling*. *Int. J. Environ. Res. Public Health*, 7, 2965-2977.

Nash, J.E.; Sutcliffe, J.V.: *River flow forecasting through conceptual models: Part I - A discussion of principles*. In: *Journal of Hydrology 10* (1970), Nr. 3, S. 282- 290.

Pfeifer, S., Hänsler, A., Ries, H., Weber, B., Jacob, D., Rechid, D., Teichmann, C., Gobiet, A., Mudelsee, M., 2013: *Mapping the Robustness of Regional Climate Change Information*, Submitted to: *Journal of Applied Meteorology and Climatology*.

Philipp, A., J. Bartholy, C. Beck, M. Erpicum, P. Esteban, X. Fettweis, R. Huth, P. James, S. Jourdain, F. Kreienkamp, T. Krennert, S. Lykoudis, S. C. Michalides, K. Pianko-Kluczynska, P. Post, D. R. Álvarez, R. Schiemann, A. Spekat and F. S. Tymvios (2010): *Cost733cat – A database of weather and circulation type classification*. *Physics and Chemistry of the Earth*, 35, 360-373.

Piani, C., G.P. Weedon, M. Best, S.M. Gomes, P. Viterbo, S. Hagemann, J.O. Haerter, 2010: *Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models*. *Journal of Hydrology*. 395, 199-215.

Piscopia, R., Inghilesi, R., Panizzo, A., Corsini, S. and Franco, L. (2002): Analysis of 12-year wave measurements by the Italian wave network. In: Smith, J. Mckee. COASTAL ENGINEERING 2002: Solving Coastal Conundrums. Proceedings of the 28th International Conference, Cardiff, Wales, July 2002, pp 121-133.

Plate E.-J (1993).: Statistik und angewandete Wahrscheinlichkeitslehre für Bauingenieure, Ernst & Sohn Verlag für Architektur und technische Wissenschaften, Berlin, ISBN 3-433-01073-0, S.20-22.

Pöhler H, Chmielewski F-M, Jasper, K, Henniges Y, Scherzer J (2007): KliWEP - Abschätzung der Auswirkungen der für Sachsen prognostizierten Klimaveränderungen auf den Wasser- und Stoffhaushalt im Einzugsgebiet der Parthe. Weiterentwicklung von WaSiM-ETH: Implikation dynamischer Vegetationszeiten und Durchführung von Testsimulationen für sächsische Klimaregionen. Abschlussbericht zum FuE-Vorhaben des Sächsischen Landesamtes für Umwelt und Geologie

Pöhler, H., Schultze, B., Scherzer, J. (2010): Auswirkungen des Klimawandels auf den Wasserhaushalt eines bewaldeten Kleineinzugsgebietes im Hochsauerland, Freiburger Forstliche Forschung, in Druck.

Rapp 2000; Hoy A, Sepp M, Matschullat J (in Bearbeitung): Variability of atmospheric circulation in Europe and Russia, 1901-2010.

Real, R., A. M. Barbosa, J. M. Vargas (2006): Obtaining environmental favourability functions from logistic regression, Environmental and Ecological Statistics 13 (2), 237-245.

Roedel, W., T. Wagner: Physik unserer Umwelt: Die Atmosphäre, 4th ed., Springer-Verlag Berlin Heidelberg 2011, auf S. 177

Rosiuta, A. A. (2003): Minimierung der Stützstellen zur Interpolation in dreidimensionalen Texturen, Studienarbeit, Fakultät für Informatik, Institut für Visualisierung und Interaktive Systeme, Universität Stuttgart, <http://elib.uni-stuttgart.de/opus/volltexte/2003/1451/>

Sachs L.: Angewandte Statistik: Anwendung statistischer Methoden, 6. Aufl., Springer-Verlag Berlin, Heidelberg, New York, Tokio, 1984, ISBN 3-540-12800-X, S. 46-48.

Schableger (1996): Statistische Analysen klimatologischer Zeitreihen. Historical Social Research, 21, 3, 4-33. http://hsr-trans.zhsf.uni-koeln.de/hsrretro/docs/artikel/hsr/hsr1996_395.pdf

Scherzer, J., Schultze, B., Niederberger, J., Pöhler, H. (2010): WASKlim - Potenzielle Auswirkungen des Klimawandels auf den Wasserhaushalt am Beispiel der Wupper (NRW), der oberen Iller (Bayern) und der Salza (Sachsen-Anhalt). Forum für Hydrologie und Wasserbewirtschaftung, 29/10, 9-15.

Schönwiese, C.-D., 2006: Praktische Methoden für Meteorologen und Geowissenschaftler, 232-234. Stuttgart.

Schönwiese, C.-D., 1985: Praktische Statistik für Meteorologen und Geowissenschaftler. Gebrüder Bornträger, Berlin, Stuttgart: 1985

Schultze B., C. Kölling, C. Dittmar, T. Rötzer, W. Elling (2005): Konzept für ein neues quantitatives Verfahren zur Kennzeichnung des Wasserhaushalts von Waldböden in Bayern: Modellierung - Regression - Regionalisierung; Forstarchiv 76, 155-163.

Schumacher (2007): Spline Functions: Basic Theory. New York.

Scott, D. W. On optimal and data-based histogram. In: *Biometrika* (1979) 66 (3): 605-610. doi: 10.1093/biomet/66.3.605

Scott, D. W. *Multivariate Density Estimation: Theory, Practice, and Visualization*. John Wiley, 1992. ISBN 978-0471547709.

Sepp und Jaagus 2002; Hoy A, Jaagus J Sepp M, Matschullat J (eingereicht bei TAC): *Spatial response of two European atmospheric circulation classifications (data from 1901 to 2010)*.

Serano et al., K. (2003): *Comparative analysis of interpolation methods in the middle Ebro Valley (Spain): application to annual precipitation and temperature*, *Climate Research*, 24, 160-180.

Soares, C. G., and Scotto, M. G.: *Application of the r largest-order statistics for long-term predictions of significant wave height*, *Coastal Engineering* 51(5-6), 387–394, 2004.

Soukissian, T.H., Kalantzi, G. (2009). *A new method for applying the r -largest maxima model for design sea-state prediction*. *International Journal of Offshore and Polar Engineering*, Vol. 19, No. 3, September 2009, ISSN 1053-5381, 176–182.

Smith, Richard L.: *Extreme value theory based on the r largest annual events*, *Journal of Hydrology* 86(1-2), 27–43, 1986.

Stein (1999): *Interpolation of Spatial Data: some theory for kriging*. New York.
Woeste B., *Diplomarbeit (2010): Eine Anwendung der Block Maxima Methode im Risikomanagement*. Mathematisches Institut für Statistik, Fachbereich Mathematik und Informatik, Westfälische Wilhelms-Universität Münster.

Streit, U.: *Vorlesungen zur Geoinformatik, Kap. 7.4.4 Zweidimensionale räumliche Interpolation im Rastermodell*, Institut für Geoinformatik der Universität Münster, http://ifgivor.uni-muenster.de/vorlesungen/Geoinformatik/kap/kap7/k07_4.htm

Tait et al. (2006): *Thin plate smoothing spline interpolation of daily rainfall for New Zealand using a climatological rainfall surface*. In: *International Journal of Climatology*, Vol. 26, 2097-2115.

Tobin et al. (2011): *Improved interpolation of meteorological forcings for hydrologic applications in a Swiss Alpine region*. In: *Journal of Hydrology*.

Tobler, W. 1970: „Erstes Gesetz der Geographie“
„The first law of geography is that everything is related to everything else, but near things are more related than distant things.“ in Abler et al. (1992): *Geography's inner worlds, Pervasive Themes in Contemporary American Geography*. New Jersey.

Trömel, S. (2004): *Statistische Modellierung von Klimazeitreihen*, Dissertation, J.W. Goethe Universität Frankfurt am Main.

Trömel, S. und C.-D. Schönwiese (2007): *Probability change of extreme precipitation observed from 1901 to 2000 in Germany*, *Theor. Appl. Climatol.*, 87, 29--39, doi:10.1007/s00704-005-0230-4.

Umbaugh S. E. (2010). *Digital Image Processing and Analysis: Human and Computer Vision Applications with Cviptools*. 2nd edition, Crc Pr Inc, 2010. 977p.

Van Vledder, G., Goda, Y., Hawkes, P. J., Mansard, E., Martin, M. J., Mathiesen, M., Peltier, E. and Thompson, E. 1993. A case study of extreme wave analysis : a comparative analysis. WAVES'93, pp. 978-992.

Von der Lippe, P. *Deskriptive Statistik*. Gustav Fischer Verlag, Stuttgart, Jena, 1993, ISBN 3-437-40268-4

<http://www.von-der-lippe.org/dokumente/buch/buch07.pdf>

von Storch, H. and Zwiers, F.W.(1999), *Statistical Analysis in Climate Research*, Cambridge University Press, Cambridge, 484 pp.

Wahl, T., Jensen, J. and Mudersbach, Ch.: (2010), A multivariate statistical model for advanced storm surge analyses in the North Sea, *International Conference on Coastal Engineering Shanghai*.

Warwick, R. M., & Clarke, K. R. (2001). Practical measures of marine biodiversity based on relatedness of species. *Oceanography And Marine Biology An Annual Review*, 39, 207-231.

Webster & Oliver (2007): *Geostatistics for Environmental Scientists*. Chichester.

Wilby, R.L. (2008): Constructing climate change scenarios of urban heat island intensity and air quality. *Environment and Planning B: Planning and Design*, 35, 902-919.

Wilks, Daniel S. *Statistical methods in the atmospheric sciences / 3rd ed. (International geophysics series; v. 100)*. Academic Press, Elsevier, 2011, 151-154

Wood, S. (2006): *Generalized additive models: an introduction with R*, Vol. 66, CRC Press.

Wood, S. (2012): *Mixed GAM Computation Vehicle with GCV/AIC/REML smoothness estimation (06 2012)*.

Zebisch, M., T. Grothmann, D. Schröter, Cl. Hasse, U. Fritsch, W. Cramer (2005): *Vulnerabilität und Anpassungsstrategien klimasensitiver Systeme*. *Climate Change 08/05*, Umweltbundesamt, ISSN 1611-8855, 203pp.

Danksagung

Herzlichen Dank an Andree Nather (Master student, Met.) und die Kollegen des CSC für Ihre freundliche Unterstützung bei der Fertigstellung der Broschüre.

Kontakt:

Climate Service Center
Fischertwiete 1
20095 Hamburg

Tel. 040-226 338-424
Fax. 040-226 338-163

www.climate-service-center.de

ISSN 2192-4058

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung