



Universität Augsburg  
Wissenschaftszentrum  
Umwelt

# Jahresbericht 2015



# Virtuelles Alpenobservatorium

## PROJEKTTEAM

- Prof. Dr. Jucundus Jacobeit  
jucundus.jacobeit@geo.uni-augsburg.de  
Tel.: 0821 598 2662
- Prof. Dr. Karl-Friedrich Wetzel  
karl-friedrich.wetzel@geo.uni-augsburg.de  
Tel.: 0821 598 2277
- PD Dr. Christoph Beck  
christoph.beck@geo.uni-augsburg.de  
Tel.: 0821 598 2129
- PD Dr. Matthias Bernhardt  
matthias.bernhardt@boku.ac.at  
Tel.: +43 147654 5508
- PD Dr. Andreas Philipp  
a.philipp@geo.uni-augsburg.de  
Tel.: 0821 598 2266
- Severin Kaspar  
severin.kaspar@geo.uni-augsburg.de  
Tel.: 0821 598 3564
- Georg Strobl  
georg.strobl@geo.uni-augsburg.de  
Tel.: 0821 598 3565
- Michael Weber  
m.weber@iggf.uni-muenchen.de  
Tel.: 089 3187 2582

## PROJEKTPARTNER

- Bayerische Akademie der Wissenschaften, Abteilung Glaziologie der Kommission für Erdmessung und Glaziologie, Dr. L. Braun
- Bayerischer Lawinenwarndienst, B. Zenke

- BOKU Wien (Institute of Water Management, Hydrology and Hydraulic Engineering), Prof. Dr. K. Schulz
- Deutscher Wetterdienst (Station Zugspitze und Meteorologisches Observatorium Hohenpeißenberg), Dr. W. Thomas, Dr. J. Seltmann
- Eidgenössische Forschungsanstalt für Wald, Schnee und Landschaft (Standort Davos), Dr. M. Lehning, Dr. C. Fierz
- Helmholtz Zentrum München (Institut für Strahlenschutz), Dr. K. Hürkamp, Dr. J. Tschiersch
- KIT (IMK-IFU Garmisch-Partenkirchen), Prof. Dr. H. Kunstmann
- Pyrenean Institute of Ecology (Zaragoza), Dr. N. Lopez-Moreno
- University of Saskatchewan (Global Institute for Water Security), Prof. Dr. J. Pomeroy
- Zentralanstalt für Meteorologie und Geodynamik Wien, Dr. W. Schöner

## FÖRDERUNG

- Bayerisches Staatsministerium für Umwelt und Verbraucherschutz

## PROJEKTLAUFZEIT

- 2014-2017

# Virtuelles Alpenobservatorium

## Projekt Virtuelles Alpenobservatorium (VAO): Klimawandel und Wasserbilanz in Hochgebirgsregionen

### Worum geht es?

Der Einfluss des Klimawandels auf den alpinen Raum war in den letzten Jahrzehnten im Vergleich zum globalen Durchschnitt überproportional stark ausgeprägt, was sich zum Beispiel in einem höheren Anstieg der Temperaturen widerspiegelt. Neben thermischen Auswirkungen werden auch Änderungen im Wasserhaushalt beobachtet. Schon heute stellt man Modifikationen in der jahreszeitlichen Verteilung des Niederschlags und des darin enthaltenen Schneeanteils, aber auch in den anderen Komponenten des Wasserkreislaufes wie zum Beispiel dem Speicherterm, also Schneerücklagen, Schneefallgrenze und Akkumulation/Ablation von Gletschereis, fest. Änderungen im Wasserhaushalt können nicht nur gravierende Auswirkungen auf das betroffene Ökosystem haben, sondern auch die Infrastruktur und Wirtschaft beeinflussen. Hochgebirgsregionen spielen aufgrund der dort verzeichneten hohen Niederschlagsraten, aber auch durch die Speicherfunktion von Schnee und Eis eine wichtige Rolle in der Wasserversorgung des Umlandes. Zudem machen diese Regionen attraktive Tourismusangebote, die vom Wasserkreislauf abhängig sind, wie beispielsweise der Wintertourismus von der Schneesicherheit.

Um rechtzeitig Gegenmaßnahmen gegen die potentiell negativen Auswirkungen des Klimawandels einleiten zu können, ist es nötig, die hydrologischen Komponenten

des Wasserhaushaltes zu verstehen. Gerade hier besteht bisher aber ein großes Forschungsdefizit. Eine besondere Herausforderung stellt die Beschreibung kleinskaliger atmosphärischer Prozesse dar, welche für den Wasserkreislauf von entscheidender Bedeutung sind. In diesem Projekt werden deshalb statistische *Down-scaling*-Modelle (erläutert im Unterkapitel „Methoden“) entwickelt, welche die Variabilität der alpinen Klimatelemente Temperatur, Niederschlag, Wind, Feuchte- oder Strahlung simulieren können. Die statistischen Modelle sollen zudem in der Lage sein, verlässliche Zukunftsprojektionen des Klimas zu liefern, um mögliche zukünftige Änderungen im Wasserhaushalt aufzuzeigen.

### Durchführung und Ergebnisse

Klimaprojektionen werden mit Hilfe globaler Klimamodelle, sogenannten „*General Circulation Models*“ (GCMs) oder „*Earth System Models*“ (ESMs), erstellt. Klimamodelle besitzen typischerweise diverse Einschränkungen, wie zum Beispiel eine zu niedrige räumliche Auflösung. Der „Flaschenhals“ ist dabei die aktuell unzureichende Computerleistung selbst großer Rechenzentren. Die übliche horizontale räumliche Auflösung der Atmosphäre globaler Klimamodelle im aktuellen fünften Sachstandsbericht des IPCC (*Intergovernmental Panel on Climate Change*), einem der umfangreichsten Sammlungen aktueller Klimaforschung, liegt derzeit bei 0.5° - 4° Länge und Breite (Taylor et al. 2012), wobei eine Auflösung von 2° im europäischen Raum in etwa einer Kantenlänge von 180 km entspricht. Verlässliche Aussagen über die zukünftige Entwicklung von Klimatelementen europäischer Regionen mit komplexem

# Virtuelles Alpenobservatorium

Relief, wie dem der Alpen, sind damit nicht zu treffen, da die für das lokale Klima wichtigen mikro- und mesoklimatischen Strukturen und Prozesse im groben Raster globaler Klimamodelle nicht dargestellt werden können. Um dennoch eine Aussage für den heterogenen Raum der Alpen treffen zu können, benötigt man sogenannte *Downscaling*-Verfahren, die aus dem großskaligen Klimamodell-*Output* (Prädiktoren) kleinskalige Informationen (Prädiktanden) generieren können. Die Modellbildung basiert auf Beobachtungsdaten, die im Hinblick auf das Lokalklima (Prädiktanden) an Klimamessstationen in den höheren Lagen der Alpen aufgezeichnet werden. Das hat den Vorteil, sich im direkten Einflussbereich der freien Atmosphäre zu befinden und damit den Zusammenhang zwischen Atmosphäre und lokalem *Feedback* ungestörter erfassen zu können. Allerdings liegen die untersuchten Stationen in stark reliefiertem Terrain, was eine hohe Beeinflussung des Mikro- und Mesoklimas vermuten lässt und somit das *Downscaling* womöglich erschwert.

## Daten

Neben den Klimadaten globaler Modelle für die Projektion der Szenarien werden Referenzdaten benötigt, um die *Downscaling*-Modelle zu kalibrieren. Die Variablen zur Beschreibung der großskaligen Atmosphärenvariabilität werden aus einem Reanalysedatensatz entnommen, konkret dem *20th Century Reanalysis*-Datensatz der US-amerikanischen *National Oceanic and Atmospheric Administration* (Compo et al. 2011). Reanalysedaten werden mit speziellen Vorhersagemodellen erstellt und gelten als beobachtungsnahe Datensätze. Das besondere an diesem Datensatz ist die weit zurückreichende

zeitliche Verfügbarkeit von 2014 bis in das Jahr 1871. Die räumliche Auflösung von  $2^\circ$  ist ähnlich wie die der meisten globalen Klimamodelle, die Klimadaten werden dabei unter anderem auf täglicher Basis zur Verfügung gestellt. Typische aus den Reanalysen entnommene Prädiktoren sind der mittlere Luftdruck auf Meereshöhe sowie die Höhe unterschiedlicher Luftdruckniveaus der Atmosphäre (Geopotentielle Höhen), die Stärke horizontaler und vertikaler Luftströmungen, Feuchtegröße oder die Lufttemperatur. Die Zielgrößen des *Downscaling*-Ansatzes sind tägliche Temperatur- und Niederschlagswerte der hochalpinen Messstationen Zugspitze und Sonnblick. Beide Zeitreihen reichen weit in die Vergangenheit zurück, an der Zugspitze stehen Messdaten seit 1900 und am Sonnblick seit 1886 zur Verfügung. Die Daten globaler Klimamodelle, welche für die Zukunftsprojektionen benötigt werden, können aus dem frei-zugänglichen CMIP5- (*Coupled Model Intercomparison Project Phase 5*) Ensemble entnommen werden. Das CMIP5-Ensemble stellt ein Sammelsurium von Klimamodellen dar, welche von unterschiedlichen Institutionen weltweit entwickelt worden sind. Beispiele sind das *Max-Planck-Institute Earth System Model* (MPI-ESM) des Max-Planck-Institutes, das *Hadley Centre Global Environment Model* (HadGEM) des britischen *Hadley Centers* oder das Modell eines Europäischen Gemeinschaftsprojektes: *EC-EARTH*.

## Methoden

Der *Downscaling*-Ansatz, der in diesem Projekt verfolgt wird, nennt sich „*Perfect Prognosis*“ oder „*Perfect Prog*“ (Rummukainen 1997). Zunächst wird das statistische Modell anhand von Messdaten kalibriert. Nach ausreichender Validierung der Modellgüte kann das kalibrierte Modell anschließend mittels globaler Klimamodelle angetrieben werden. In der Praxis finden in *Perfect Prog* sehr unterschiedliche *Downscaling*-Modelle Verwendung, von denen im Folgenden zwei nichtlineare statistische Methoden vorgestellt werden.

## Reference Class Forecast-Modelle

Das Prinzip dieses Verfahrens beruht auf der Erstellung von Wetterlagenklassifikationen, also der Gruppierung ähnlicher beobachteter atmosphärischer Zirkulationstypen zu Klassen und der Ermittlung des typischen Temperatur- bzw. Niederschlagswertes am Zielstandort für jede dieser Klassen. Zur Modellierung können anschließend neue Zirkulationsdaten den Klassen zugeordnet und der typische Wert der entsprechenden Klasse als Modellwert verwendet werden. Die Modellgüte lässt sich im Falle der Validierung dann unter anderem durch den quadrierten Korrelationskoeffizienten zwischen Modellwertreihe und beobachteten Temperaturen und Niederschlagssummen ermitteln. Im Rahmen des VAOII-Programms wurden zunächst die geeignetsten Klassifikationen aus der schon bestehenden COST733-Datenbank (Philipp et al. 2014) ermittelt. Weiterhin wurden spezielle Klassifikationen entwickelt, die individuell für Temperatur und Niederschlag an den genannten Stationen optimiert sind, insbesondere durch die Integration der optimal gewich-

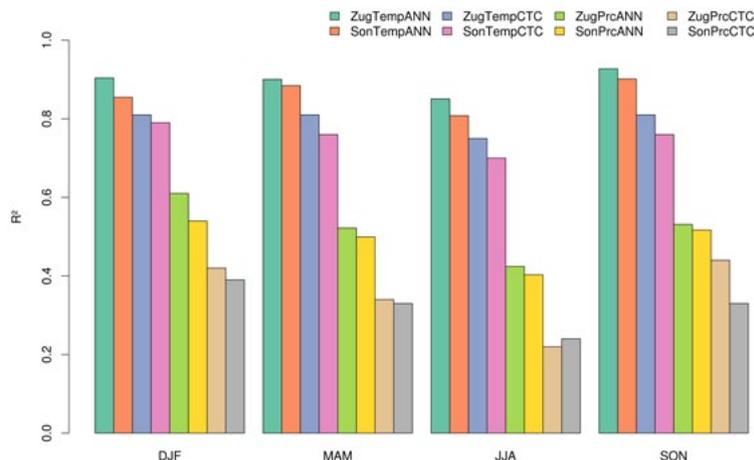


Abb. 1: Mittlere erklärte Varianzen  $R^2$  für die Zielgrößen Temperatur (Temp) und Niederschlag (Prc), welche im Rahmen der Validierung der künstlichen Neuronalen Netze (ANN) und Wetterlagenklassifikationen (CTC) für die Zugspitze (Zug) und den Sonnblick (Son) saisonal (Winter: DJF, Frühling: MAM, Sommer: JJA, Herbst: SON) ermittelt wurden.

teten Zielvariablen selbst. Abbildung 1 zeigt, dass für die Temperatur der Stationen Zugspitze und Sonnblick bereits recht hohe Modellgüten erreicht werden. Die Entwicklung unterschiedlicher Klassifikationsansätze in diesem Projekt ist, bis auf einige ausstehende Anpassungen, weitestgehend abgeschlossen. Eine dieser Anpassungen bezieht sich auf die Aufbereitung der Daten: es hat sich interessanterweise herausgestellt, dass nicht immer die individuell optimierten VAOII-Klassifikationen sondern häufig COST733-Klassifikationen mit einer vorgeschalte-

ten Hauptkomponentenanalyse am besten abschneiden. Dies ist ein Hinweis auf weiteres Steigerungspotential der Modellgüte, da vorgeschaltete Hauptkomponentenanalysen für die VAOII-Klassifikation bislang noch nicht durchgeführt wurden.

## Künstliche Neuronale Netze (KNN)

Künstliche Neuronale Netze stellen ein Verfahren dar, um nichtlineare Zusammenhänge zwischen zwei Variablen, hier Prädiktor (Zirkulation) und Prädiktand (Temperatur oder Niederschlag an der Messstation) zu approximieren. Die Optimierung von KNNs stellt den momentanen Arbeitsschwerpunkt dar. Abbildung 2 zeigt den schematischen Aufbau eines typischen KNNs. Die Information, enthalten in den Prädiktorvariablen, wird von der Eingabeschicht (*Input Layer*) über gewichtete Verbindungen hin zu Schnittstellen (Neuronen im *Hidden Layer*, in Abb. 2 dargestellt als Kreise) und schließlich zur Ausgabeschicht (*Output Layer*), welche den Prädiktanden repräsentiert, weitergegeben. Die Schwierigkeit besteht darin, gute Werte für die Gewichte zu finden, was in der Kalibrierungsphase durch iterative Optimierung mittels Lernalgorithmen bewerkstelligt wird. Außerdem müssen, um eine gute Netzkonfiguration zu finden, diverse Einstellungen, sogenannte Hyperparameter, getestet werden. Beispiele für Hyperparameter sind Schritte im Präprozessing, z.B. die Standardisierung oder Skalierung der Prädiktoren, die gewählte Anzahl an Versteckten Neuronen (*Hidden Neurons*), die Anzahl an *Hidden Layer* oder diverse Parameter, welche den Lernalgorithmus konfigurieren (Lernrate u.a.). KNNs reagieren meist sehr sensibel auf Fehleinstellungen. Typische Probleme sind einerseits das *Underfitting*: hierbei wird kein

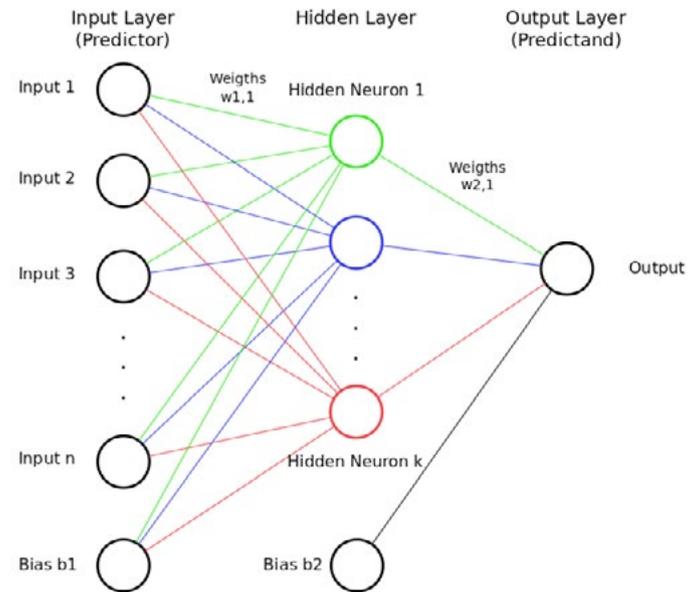


Abb. 2: Schematischer Aufbau eines Neuronalen Netzes. Eingabeschichten werden als *Input Layer*, die Ausgabe des Netzes als *Output Layer* bezeichnet. Dazwischen kann eine beliebige Anzahl an verdeckten Schichten, den sogenannten *Hidden Layers*, mit einer beliebigen Anzahl an Versteckten Neuronen (*Hidden Neurons*) platziert werden, welche über gewichtete Verbindungen mit den umliegenden Schichten verknüpft sind. Der *Input Layer* wird durch die Eingabedaten (Prädiktoren) definiert, während der Prädiktand den *Output Layer* darstellt.

Zusammenhang zwischen Prädiktoren und Prädiktand gefunden. Andererseits bereitet *Overfitting* Schwierigkeiten, da der Zusammenhang zwischen Prädiktoren und Prädiktand sozusagen „auswendig gelernt“ wird, was zur

# Virtuelles Alpenobservatorium

Folge hat, dass das Modell neue, unbekannte Daten nicht sinnvoll verarbeiten kann. Abbildung 3 zeigt exemplarisch eine Sensitivitätsstudie bezüglich der Anzahl an verwendeten Versteckten Neuronen. Beobachtet wird hierbei ein erneutes Ansteigen des Fehlers (dargestellt durch den *Mean Square Error*, MSE) bei zu großer Anzahl an Versteckten Neuronen, was als Zeichen für *Overfitting* des KNN zu werten ist.

## Ergebnisse

Aktuelle Ergebnisse kalibrierter KNNs für das Beispiel der Zugspitze werden in Abbildung 4 für Temperatur und Abbildung 5 für Niederschlag dargestellt. Es wurden dafür mehrere Konfigurationen (12 für die Temperatur und 16 für den Niederschlag) auf saisonaler Basis ent-

wickelt. Berücksichtigt wurden dabei unterschiedliche Prädiktor-Kombinationen und Einstellungen bezüglich der KNNs, wie zum Beispiel eine variierende Anzahl an verdeckten Neuronen. Während die Temperatur gut auf die dazugehörigen beobachteten Messwerte (Obs in Abb. 4 und 5) abgebildet wird, zeigen sich beim Niederschlag kleinere Abweichungen. Der Niederschlag erweist sich aber generell und unabhängig von der gewählten Methode als schwer fassbare Größe beim *Downscaling*. Verglichen mit den Wetterlagenklassifikationen konnte in allen Bereichen die Güte der Modelle mittels Neuronaler Netze verbessert werden (siehe Abb. 1).

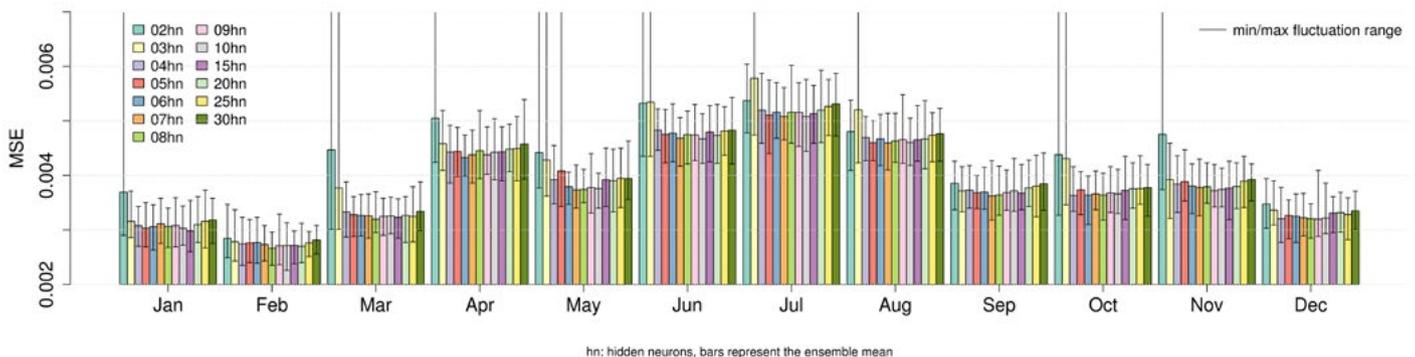


Abb. 3: Bei zunehmender Anzahl an Neuronen nimmt die Güte im Validierungszeitraum zu, bis ein kritischer Punkt überschritten wird. Ab dann wird das Netz zu komplex und tendiert zum *Overfitting*, d.h. die Generalisierungsfähigkeit des Modells nimmt ab, was sich in einer erneuten Zunahme des Fehlers (hier MSE: Mean Square Error) widerspiegelt. Die Modelle wurden im Zeitraum 1900-2000 kalibriert, wobei 20% der Daten zufällig zur Validierung separiert wurden.

## Zusammenfassung und Ausblick

In den letzten zwei Jahren wurden für die Zugspitze und den Sonnblick *Downscaling*-Ansätze entwickelt, mit dem Ziel, wasserhaushaltsrelevante Größen abzuschätzen. Zwei nichtlineare statistische Verfahren, die Wetterlagenklassifikation und Künstliche Neuronale Netze wurden dafür verwendet. Es zeigte sich, dass beide Verfahren und insbesondere die Neuronalen Netze in der Lage sind, Temperaturen und Niederschläge in den untersuchten hochalpinen Regionen zu simulieren. Die kalibrierten statistischen Modelle können im weiteren Projektverlauf dazu genutzt werden, die zukünftigen klimatologischen Veränderungen in den Alpen zu pro-

jizieren. Diese Szenariorechnungen wiederum können verwendet werden, um dynamische Klima-Impaktmodelle, etwa zur Schneehydrologie oder Gletscherdynamik anzutreiben. Dies wird in einem weiteren Teilprojekt des VAOII umgesetzt werden.

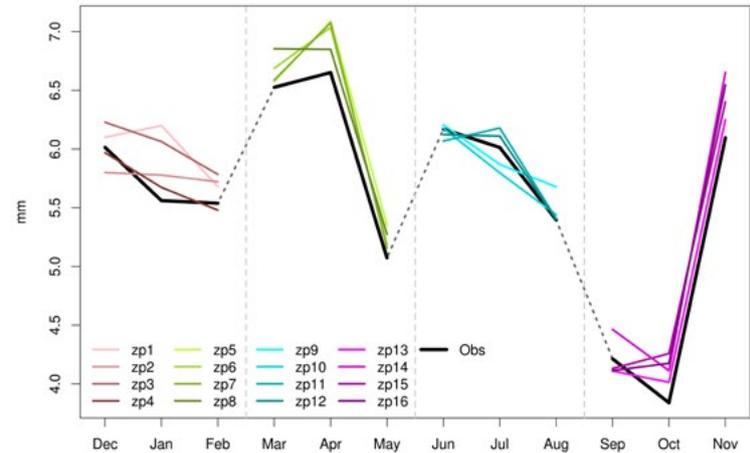
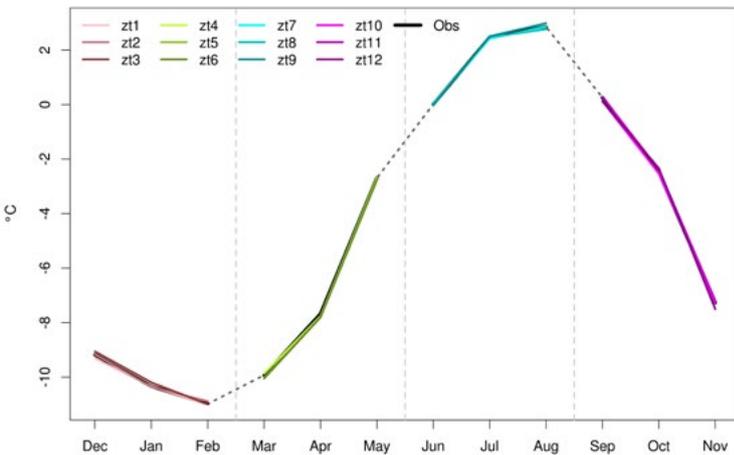


Abb. 4 und 5: Validierung der mittleren Monatstemperaturen und Monatsniederschläge, errechnet mittels KNNs. Die Modelle wurden im Zeitraum 1970-2000 kalibriert, wobei 20% der Daten zufällig zur Validierung separiert wurden. Die Abkürzungen in der Legende bedeuten: Obs=Beobachtung, z=Zugspitze, t=Temperatur, p=Niederschlag, während die Ziffer die unterschiedlichen Setups nummeriert (12 für Temperatur und 16 für Niederschlag). Jedes Setup ist für eine Saison und einen Prädiktanden gültig.

## Literatur

- Compo, G. P./Whitaker, J. S./Sardeshmukh, P. D./Matsui, N./Allan, R. J./Yin, X./Crouthamel, R. I./Grant, A. N./Groisman, P. Y./Jones, P. D./Kruk, M. C./Kruger, A. C./Marshall, G. J./Maugeri, M./Mok, H. Y./Nordli, Ø./Ross, T. F./Trigo, R. M./Wang, X. L./Woodruff, S. D./Worley, S. J. (2011) The Twentieth Century Reanalysis Project, *Quarterly Journal of the Royal Meteorological Society* 137, S. 1-28.
- Philipp, A./Beck, C./Huth, R./Jacobeit, J. (2014) Development and comparison of circulation type classifications using the COST 733 dataset and software, *International Journal of Climatology*, DOI: 10.1002/joc.3920.
- Rummukainen, M. (1997) Methods of statistical downscaling of GCM simulations, *SMHI Rapporten. Meteorologi och Klimatologi* 80.
- Taylor, K. E./Stouffer, R. J./Meehl, G.A. (2012) An Overview of CMIP5 and the Experiment Design, *Bulletin of the American Meteorological Society* 93, S. 485-489.