

## **Statistische Modellierung wasserhaushaltsrelevanter Klimaparameter für den Hochgebirgsraum**

**Andreas Philipp, Severin Kaspar, Christoph Beck, Jucundus Jacobeit**

### **Angaben zur Veröffentlichung / Publication details:**

Philipp, Andreas, Severin Kaspar, Christoph Beck, and Jucundus Jacobeit. 2015. "Statistische Modellierung wasserhaushaltsrelevanter Klimaparameter für den Hochgebirgsraum." UFS: Wissenschaftliche Resultate 03 (2013/2014): 24-26. [https://schneefernerhaus.de/fileadmin/user\\_files/Downloads/Wissenschaftliche-Resultate/3Wissenschaftliche\\_Resultate\\_2013\\_2014\\_UFS.pdf](https://schneefernerhaus.de/fileadmin/user_files/Downloads/Wissenschaftliche-Resultate/3Wissenschaftliche_Resultate_2013_2014_UFS.pdf).

### **Nutzungsbedingungen / Terms of use:**

**licgercopyright**

Dieses Dokument wird unter folgenden Bedingungen zur Verfügung gestellt: / This document is made available under the following conditions:

**Deutsches Urheberrecht**

Weitere Informationen finden Sie unter: / For more information see:

<https://www.uni-augsburg.de/de/organisation/bibliothek/publizieren-zitieren-archivieren/publizieren>



## STATISTISCHE MODELLIERUNG WASSERHAUSHALTSRELEVANTER KLIMAPARAMETER FÜR DEN HOCHGEBIRGSRAUM

ANDREAS PHILIPP, SEVERIN KASPAR, CHRISTOPH BECK, JUCUNDUS JACOBET

UNIVERSITÄT AUGSBURG, INSTITUT FÜR GEOGRAPHIE, A.PHILIPP@GEO.UNI-AUGSBURG.DE

**Um langfristige künftige Veränderungen des alpinen Wasserhaushalts besser einschätzen zu können, wird eine Maximierung der Modellgüte statistischer Verfahren angestrebt. Hierbei konnten mit Klassifikationsverfahren bereits bemerkenswerte Gütemaße für die Lufttemperatur erreicht werden. Aktuelle Arbeiten zur Implementierung künstlicher Neuronaler Netze lassen jedoch noch weitere deutliche Verbesserungen, insbesondere für den Niederschlag, erwarten.**

Als Steuerfaktoren für den Wasserhaushalt spielen Veränderungen sowohl des Niederschlags als auch der Lufttemperatur in Hochgebirgsregionen eine maßgebliche Rolle. Die Bedeutung der Lufttemperatur ergibt sich insbesondere durch die Steuerung der Rücklagenbildung bzw. -reduktion bei Gefrier- und Schmelzvorgängen. Beide Klimaparameter hängen im Wesentlichen ab von der atmosphärischen Zirkulation, d. h. der räumlichen Verteilung und Intensität von Hoch- und Tiefdruckgebieten, die ihrerseits Ein- und Ausstrahlung sowie Luftmassentransport und somit Energie- und Feuchteflüsse steuern.

Um dekadische und säkulare klimatische Veränderungen einschätzen zu können, werden globale und regionale Klimamodelle betrieben, die die großskalige atmosphärische Zirkulation im Wesentlichen gut, die kleinskaligen Veränderungen von Temperatur und Niederschlag jedoch immer noch nur unzureichend wiedergeben können. Dies gilt umso

mehr, als kleinräumige Unterschiede im stark reliefierten Hochgebirge, etwa zwischen vergletscherten und unvergletscherten Lagen, nicht aufgelöst werden können, obgleich sie für den alpinen Wasserhaushalt von hoher Relevanz sind.

Gestützt auf die relativ hohe Qualität der großskaligen Zirkulationsdaten der Klimamodelle lassen sich jedoch statistische Modellierungsverfahren entwickeln, die die Beziehung zwischen Temperatur oder Niederschlag einzelner Standorte und der großskaligen Zirkulation aus der Vergangenheit auf die Zukunftsszenarien projizieren (sog. statistische Downscalingverfahren). Die Verlässlichkeit derartiger Projektionen hängt jedoch maßgeblich von der Modellgüte der statistischen Techniken ab, die mit Validierungsdatensätzen überprüft werden kann, also Teilstichproben aus der Vergangenheit, die nicht zur Erstellung der Modelle verwendet, sondern allein für die Abschätzung der Modellqualität reserviert wurden.

Im Rahmen der zweiten Phase des Forschungsvorhabens Virtuelles Alpenobservatorium (VAO-II) werden insbesondere folg. zwei statistische Verfahren implementiert und optimiert: i) für den jeweiligen Standort und Parameter optimierte Zirkulationstypenklassifikationen (RCF, engl. reference class forecast) sowie ii) künstliche neuronale Netze (ANN, engl. artificial neural networks).

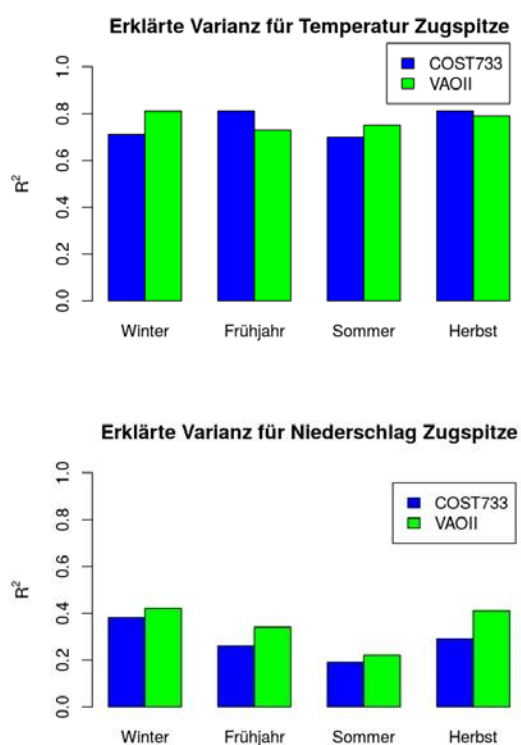
### Reference Class Forecast Modelle

Das Prinzip dieses Verfahrens besteht in der Erstellung von Wetterlagenklassifikationen auf Grundlage beobachteter Zirkulationsdaten und der Ermittlung des typischen Temperatur- bzw. Niederschlagswertes am Zielstandort für jede Klasse. Zur Modellierung können anschließend neue Zirkulationsdaten (z. B. zur Validierung oder aus Klimamodellsimulationen) den Klassen zugeordnet und der typische Wert der entsprechenden Klasse als Modellwert verwendet werden. Die Modellgüte lässt sich im Falle der Validierung dann z. B. durch den (evt. quadrierten) Korrelationskoeffizienten zwischen Modellwertreihe und beobachteten Temperaturen oder Niederschlagssummen ermitteln.

Im Rahmen des VAO-II-Programmes wurden zunächst die geeignetsten Klassifikationen aus der schon bestehenden COST733- Datenbank ermittelt. Weiterhin wurden spezielle Klassifikationen entwickelt, die individuell für Temperatur und Niederschlag an den genannten Stationen optimiert sind, insbesondere durch die Integration der (optimal gewichteten) Zielvariablen selbst. Abbildung 1 (oben) zeigt, dass für die Temperatur der Station Zugspitze (ähnlich auch für den Sonnblick) bereits recht hohe Modellgüten erreicht werden.

Interessanterweise sind jedoch nicht immer die individuell optimierten VAO-II- Klassifikationen führend, was ein Hinweis auf weiteres Steigerungspotential ist, da die besten COST733-Klassifikationen mit einer vorgeschalteten Hauptkomponentenanalyse arbeiten, die für die VAO-II-Klassifikationen bislang noch nicht verwendet wurde. Weitere Analysen sollen diese mögliche zusätzliche Verbesserung, die auf eine Art Tiefpassfilterwirkung der Hauptkomponentenanalyse für die Zirkulationsdaten zurückgeführt wird, weiter verfolgen. Die Modellgüten für den Niederschlag (Abb. 1 unten) liegen bemerkenswerterweise insgesamt deutlich über

denen von Tieflandsstationen (hier nur i. d. R.  $R^2 < 0,2$ ) und erreichen für die Zugspitze maximale Werte von  $R^2 = 0,42$  im Winter (am Sonnblick  $R^2 = 0,33$ ). Auch ergeben sich für die VAO-II-Optimierung durchweg Verbesserungen im Vergleich zu den COST733- Klassifikationen. Allerdings wird in keiner Jahreszeit mehr als die Hälfte der Varianz des Niederschlags durch die Modelle erklärt, was für die Erstellung robuster Modellprojektionen immer noch unzureichend ist.




**Abb.1: Modellgüte für Temperatur und Niederschlag der Station Zugspitze im Vergleich zwischen COST733 und eigens optimierten Klassifikationen (VAO-II) auf Tagesbasis für drei- monatige Jahreszeiten.  $R^2$  ist der quadrierte Korrelationskoeffizient zwischen modellierter und beobachteter Zeitreihe im Validierungszeitraum (2001 bis 2013).**

### Künstliche neuronale Netze

Im aktuell laufenden zweiten Projektteil werden Lernalgorithmen für das Training künstlicher neuronaler Netze (ANN) implementiert. In einem ANN wird durch die Weitergabe gewichteter Informationen zwischen einzelnen Elementen (Neuronen) des Netzes eine Abbildungsfunktion zwischen dem Prädiktor (Zirkulationsdaten) und einem Prädiktanden (Temperatur bzw. Niederschlag) iterativ optimiert. Als sog. Eingabeneuronen dienen die Gitterpunktwerte des Zirkulationsdatensatzes, als Ausgabeneuronen der Niederschlag bzw. die Temperatur selbst. Zwischen diesen zwei Ebenen können beliebig viele sog. versteckte Neuronen konfiguriert werden. Eine elementare Frage stellt sich hierbei hinsichtlich der optimalen

weiteren Neurons steigt, anstatt wie im Trainingsdatensatz weiter zu sinken, da hier die Übertragbarkeit reduziert wird. Abbildung 2 zeigt das Ergebnis einer derartigen aufwändigen Evaluierungsprozedur für die Temperatur der Zugspitze mit einem charakteristischen Ansteigen des Fehlerbalkens nach ca. 7-8 versteckten Neuronen. Diese Optimierungen führen für die Temperatur der Zugspitze bereits jetzt zu erklärten Varianzanteilen von 98 %, für den Niederschlag ist jedoch noch immer Steigerungsbedarf sichtbar, dem im bevorstehenden letzten Projektteil u. a. durch die Kombination von ANN mit optimierten Klassifikationen genüge getan werden soll.



**Abb.2: Veränderung des Modellfehlers (Mean Square Error, Ordinate) für neuronale Netze bei Erhöhung der Anzahl der versteckten Neuronen (Farben) für die Temperatur der Zugspitze nach Monaten. Dargestellt ist der Fehler des Validierungsdatensatzes, der nach anfänglicher Abnahme jeweils wieder ansteigt und damit die optimale Anzahl an versteckten Neuronen anzeigt. Die Fluktuation aus randomisiert initialisierten Trainingsläufen ist zur Beurteilung der Robustheit in Strichen dargestellt.**

Anzahl der versteckten Neuronen. Eine zu hohe Zahl kann zu einer schlechten Übertragbarkeit des Modells auf neue Daten führen, da dann die Tendenz steigt, Einzelfälle aus dem Trainingsdatensatz in den Gewichten abzuspeichern (Auswendiglernen). Eine zu geringe Anzahl wiederum führt zur mangelhaften Repräsentation niederschlags- bzw. temperaturrelevanter Prozesse. Eine optimale Anzahl kann genau dann festgestellt werden, wenn der Fehler im Validierungsdatensatz bei Hinzunahme eines

### Danksagung

Wir bedanken uns für die Förderung des Forschungsvorhabens durch das Bayerische Staatsministerium für Umwelt und Verbraucherschutz (StMUV) im Rahmen des Verbundprojekts Virtuelles Alpenobservatorium (VAO-II).