

Hydroinformatik - SoSe 2025

UM-BHW-414-G: Künstliche Neuronale Netze

Olaf Kolditz

¹Helmholtz Centre for Environmental Research – UFZ, Leipzig

²Technische Universität Dresden – TUD, Dresden

³Center for Advanced Water Research – CAWR

⁴TUBAF-UFZ Center for Environmental Geosciences – C-EGS, Freiberg / Leipzig

Dresden, 30.05.2025

<https://www.ufz.de/index.php?de=40416>

<https://bildungsportal.sachsen.de/opal/auth/RepositoryEntry/32518209537?10>

Zeitplan: Hydroinformatik I+II

Sommersemester 2025

Stand: 08.05.2025

Nr.	KW	Datum	ID	Thema
01	15	11.04.2025	UW-BHW-414-A	Einführung, Werkzeuge#1, Hello World
03	17	25.04.2025	UW-BHW-414-B	Umweltinformatik, Werkzeuge#2 (git), Datentypen
05	18	02.05.2025	UW-BHW-414-C	Selbststudium
07	19	09.05.2025	UW-BHW-414-D	Objekt-Orientierte Programmierung: C++, Klassen
09	20	16.05.2025	UW-BHW-414-E	Python
11	21	23.05.2025	UW-BHW-414-F	Modellierung, Digitalisierung, Wasser 4.0
13	22	30.05.2025	UW-BHW-414-G	KI, Maschinelles Lernen, Neuronale Netzwerke
15	23	06.06.2025	UW-BHW-414-H	Kontinuumsmechanik, Hydromechanik
05	18	13.06.2025		Vorlesungsfreie Woche
17	25	20.06.2025	UW-BHW-414-I	Differentialgleichungen, Näherungsverfahren
19	26	27.06.2025	UW-BHW-414-J	Finite-Differenzen, explizite Verfahren
21	27	04.07.2025	UW-BHW-414-K	Finite-Differenzen, implizite Verfahren
24	28	11.07.2025	UW-BHW-414-L	Gerinnehydraulik, Grundwasserhydraulik
25	29	18.07.2025	UW-BHW-414-M	Zusammenfassung, Klausurvorbereitung

Fahrplan für heute ...

0. Rückblick letzte Veranstaltung: Modell-Begriff, BigData

1. Modell-Begriff: Abschluss
 2. Hydrologische Modelle: Definition
 3. Künstliche Neuronale Netzwerke (ANN)
 4. Künstliche Neuronale Netzwerke in der Hydrologie
 5. Mesoskalige Hydrologische Modellierung (mHM)
 6. Beispiele für Anwendungen
-

7. Ausblick auf die nächste Veranstaltung: Mechanik

Modell-Begriff

Hydrologische Modelle

Definition

”Hydrologisches Modell: Vereinfachte Beschreibung der in einem hydrologischen System ablaufenden physikalischen, chemischen und biologischen Prozesse (hydrologischer Prozeß) oder Teilprozesse mit Hilfe mathematischer Gleichungen. Diese werden zeitlich und räumlich so miteinander verknüpft, wie sie in der Natur ablaufen.”

Source: <http://www.spektrum.de/lexikon/geowissenschaften/hydrologisches-modell/7239>

Hydrologische Modelle

Definition

- ▶ " Je nach Berücksichtigung des zeitlichen Verhaltens wird zwischen **stationären und instationären** Modellen unterschieden.
- ▶ Weitere Unterscheidungen erfolgen nach den Lösungsverfahren der mathematischen Gleichungen in **analytische und numerische** Modelle,
- ▶ nach Berücksichtigung zufallsbedingter Systemänderungen in **stochastische und deterministische** Modelle,
- ▶ nach der Abhängigkeit der Modellparameter vom momentanen Systemzustand in **lineare und nichtlineare** Modelle."

Source: <http://www.spektrum.de/lexikon/geowissenschaften/hydrologisches-modell/7239>

Hydrologische Modelle

Definition

”Die **deterministischen** Modelle werden in drei Hauptgruppen unterteilt, wobei der Grad der Kausalität in Form der Ursachen-Wirkungs-Beziehung Beachtung findet:

1. physikalische Modelle (White-Box-Modelle), die auf den Grundgesetzen der Physik, insbesondere der Hydro- und Thermodynamik, der Chemie und der Biologie beruhen,
2. konzeptionelle Modelle (Grey-Box-Modelle), die sich auf die physikalischen Gesetze in vereinfachter Näherung stützen und ein gewisses Maß an Empirie enthalten und
3. Modelle der Black-Box, die unter Vernachlässigung der physikalischen Grundgesetze nur Ursachen-Wirkungsbeziehungen zwischen den Systemein- und Systemausgaben betrachten.”

Source: <http://www.spektrum.de/lexikon/geowissenschaften/hydrologisches-modell/7239>

Künstliche Neuronale Netzwerke

ANN

Künstliche Neuronale Netzwerke

Definition

”Künstliche neuronale Netze, auch künstliche neuronale Netzwerke, kurz: KNN (engl. artificial neural network, ANN), sind Netze aus künstlichen Neuronen. Sie sind Forschungsgegenstand der Neuroinformatik und stellen einen Zweig der künstlichen Intelligenz dar. Die künstlichen neuronalen Netze haben, ebenso wie künstliche Neuronen, ein biologisches Vorbild. Man stellt sie den natürlichen neuronalen Netzen gegenüber, welche Nervenzellvernetzungen im Gehirn und im Rückenmark bilden. Doch geht es mehr um eine Abstraktion (Modellbildung) von Informationsverarbeitung und weniger um das Nachbilden biologischer neuronaler Netze, was eher Gegenstand der Computational Neuroscience ist.”

Source: https://de.wikipedia.org/wiki/K\u00f6nigliche_Akademie_der_Wissenschaften

[//de.wikipedia.org/wiki/K\u00f6nigliche_Akademie_der_Wissenschaften](https://de.wikipedia.org/wiki/K\u00f6nigliche_Akademie_der_Wissenschaften)

Künstliche Neuronale Netzwerke

Definition


In künstlichen neuronalen Netzen bezeichnet die Topologie die Struktur des Netzes. Damit ist im Allgemeinen gemeint, wie viele künstliche Neuronen sich auf wie vielen Schichten befinden, und wie diese miteinander verbunden sind. Künstliche Neuronen können auf vielfältige Weise zu einem künstlichen neuronalen Netz verbunden werden. Dabei werden Neuronen bei vielen Modellen in hintereinander liegenden Schichten (englisch layers) angeordnet; bei einem Netz mit nur einer trainierbaren Neuronenschicht spricht man von einem einschichtigen Netz.

Source: https://de.wikipedia.org/wiki/K\u00f6nigliches_neuronales_Netz

https://de.wikipedia.org/wiki/K\u00f6nigliches_neuronales_Netz

Künstliche Neuronale Netzwerke

Definition



Ausgabeschicht


Unter Verwendung eines Graphen können die Neuronen als Knoten und ihre Verbindungen als Kanten dargestellt werden. Die Eingaben werden gelegentlich auch als Knoten dargestellt. Die hinterste Schicht des Netzes, deren Neuronenausgaben meist als einzige außerhalb des Netzes sichtbar sind, wird Ausgabeschicht (engl. output layer) genannt. Davor liegende Schichten werden entsprechend als verdeckte Schicht (engl. hidden layer) bezeichnet.

Source: https://de.wikipedia.org/wiki/K\u00f6nigliches_neuronales_Netz

[//de.wikipedia.org/wiki/K\u00f6nigliches_neuronales_Netz](https://de.wikipedia.org/wiki/K\u00f6nigliches_neuronales_Netz)

Künstliche Neuronale Netzwerke

Definition



Source:

<https://www.lfi.rwth-aachen.de/index.php?page=kunstl-neuronale-netze>

Figure: Typisches künstliches neuronales Netz (KNN)

Künstliche Neuronale Netzwerke


Definition

Abbildung 1 zeigt ein typisches, aus drei Schichten bestehendes KNN (eine Eingangsschicht, eine versteckte Schicht und eine Ausgangsschicht). Jedes Neuron des Netzes verarbeitet die ankommenden Eingaben zu einer Ausgabe. Diese Ausgabe wird dann mit anderen Neuronen verknüpft. Die Informationen gelangen über die Eingangsschicht in das Netz hinein. Alle Schichten des Netzes verarbeiten diese Signale, bis sie die Ausgangsschicht erreichen. Bei der Entwicklung von Neuronalen Netzen werden zwei Hauptphasen betrachtet:

Source: <https://www.lfi.rwth-aachen.de/index.php?page=kunstl-neuronale-netze>

Künstliche Neuronale Netzwerke

Beispiel



Übung:

Entwerfen Sie ANN für ein Hochwasser-Modell.

- ▶ Was sind die wichtigsten Eingangsparameter?
- ▶ Welche hydrologischen Kompartimente sind involviert?
- ▶ Zielfunktion: Hochwasserstand

Source: Vorlesung 12.01.2018

Künstliche Neuronale Netzwerke

Definition

Lernphase Diese Phase umfasst den Prozess, bei dem dem Netz mit Hilfe von Trainingsets (z.B. historische Daten) und Trainingsalgorithmen eine gewünschte Verhaltensweise beigebracht wird.

Arbeitsphase Nach dem Lernprozess ist das KNN bereit, in die Arbeitsphase einzutreten. Das Netz gibt Ausgangswerte aus, die denen im Beispieldatensatz ähneln, wenn die Eingangswerte zu denen eines Trainingsbeispiels passen.

Source: <https://www.lfi.rwth-aachen.de/index.php?page=kunstl-neuronale-netze>

ANN Beispiel aus der Hydrologie

Künstliche Neuronale Netzwerke

Hydrologie

Ronny Peters

KÜNSTLICHE NEURONALE NETZE ZUR BESCHREIBUNG DER
HYDRODYNAMISCHEN PROZESSE FÜR DEN HOCHWASSERFALL UNTER
BERÜCKSICHTIGUNG DER NIEDERSCHLAGS-ABFLUSS-PROZESSE IM
ZWISCHENEINZUGSGEBIET

Dresden, Juli 2008

Source: <https://www.baufachinformation.de/dissertation/K\unhbox\voidb\x\bgroup\accent127u\protect\penalty\@M\hskip\z@skip\egroupnstliche-neuronale-Netze-zur-Beschreibung-der-hydrodynamischen-Prozess>

Künstliche Neuronale Netzwerke

Hydrologie




Figure: Aus dem Defizit an Trainingsdaten abgeleitete allgemeine Methodik

Source: Peters, 2008

Künstliche Neuronale Netzwerke

Hydrologie (Peters, 2008)




Figure: Freiburger Mulde: Höhen und Gefälle im Untersuchungsgebiet

Künstliche Neuronale Netzwerke

Hydrologie (Peters, 2008)




Figure: Darstellung einzelner Szenarien für Durchfluß und Wasserstand

Differences Between Machine Learning vs Neural Network

"Machine Learning is an application or the **subfield of artificial intelligence** (AI). Machine Learning enables a system to automatically learn and progress from experience without being explicitly programmed. Machine Learning is a continuously developing practice. The goal of Machine learning is to understand the structure of data and fit that data into models, these models can be understood and used by people. In Machine Learning generally, the tasks are classified into broad categories. These categories explain how learning is received, two of the most widely used machine learning methods are supervised learning and unsupervised learning. The neural network is inspired by the structure of the brain. The neural network contains highly interconnected entities, called units or nodes. Neural networks are deep learning technologies. It generally focuses on solving complex processes. A typical neural network is a group of algorithms, these algorithms model the data using neurons for machine learning."

<https://www.educba.com/machine-learning-vs-neural-network/>

mesoskalige Hydrologische Modellierung

mHM

Hydrologische Modelle

mHM





Figure: Landsurface Hydrology - das Modell mHM

Source: Rakovec, O., Kumar, R., Mai, J., Cuntz, M., Thober, S., Zink, M., Attinger, S., Schäfer, D., Schrön, M., Samaniego, L., 2016. Multiscale and Multivariate Evaluation of Water Fluxes and States over European River Basins. J. Hydrometeorol 17, 287–307. doi:10.1175/jhm-d-15-0054.1

Hydrologische Modelle

mHM



UFZ Dürremonitor




Figure: Mehrskalen-Verifikation mHM in der Pan-EU

Testfragen

Hydrologische Modelle

Fragen

1. Zu welchem hydrologischen Modelltyp gehören die künstlichen neuronalen Netzwerke?
2. Was ist der englische Begriff für "Künstliche Neuronale Netzwerke"?
3. Skizzieren sie ein ANN-Konzept für eine Hochwasservorhersage. Benennen sie Einflussfaktoren für verschiedene Layer des ANN (d.h. die Kette von Abhängigkeiten).
4. ...

Hydroinformatik - SoSe 2025

UM-BHW-414-G: Maschinelles Lernen

Olaf Kolditz

¹Helmholtz Centre for Environmental Research – UFZ, Leipzig

²Technische Universität Dresden – TUD, Dresden

³Center for Advanced Water Research – CAWR

⁴TUBAF-UFZ Center for Environmental Geosciences – C-EGS, Freiberg / Leipzig

Dresden, 30.05.2025

<https://www.ufz.de/index.php?de=40416>

<https://bildungsportal.sachsen.de/opal/auth/RepositoryEntry/32518209537?10>

Zeitplan: Hydroinformatik I+II

Sommersemester 2025

Stand: 08.05.2025

Nr.	KW	Datum	ID	Thema
01	15	11.04.2025	UW-BHW-414-A	Einführung, Werkzeuge#1, Hello World
03	17	25.04.2025	UW-BHW-414-B	Umweltinformatik, Werkzeuge#2 (git), Datentypen
05	18	02.05.2025	UW-BHW-414-C	Selbststudium
07	19	09.05.2025	UW-BHW-414-D	Objekt-Orientierte Programmierung: C++, Klassen
09	20	16.05.2025	UW-BHW-414-E	Python
11	21	23.05.2025	UW-BHW-414-F	Modellierung, Digitalisierung, Wasser 4.0
13	22	30.05.2025	UW-BHW-414-G	KI, Maschinelles Lernen, Neuronale Netzwerke
15	23	06.06.2025	UW-BHW-414-H	Kontinuumsmechanik, Hydromechanik
05	18	13.06.2025		Vorlesungsfreie Woche
17	25	20.06.2025	UW-BHW-414-I	Differentialgleichungen, Näherungsverfahren
19	26	27.06.2025	UW-BHW-414-J	Finite-Differenzen, explizite Verfahren
21	27	04.07.2025	UW-BHW-414-K	Finite-Differenzen, implizite Verfahren
24	28	11.07.2025	UW-BHW-414-L	Gerinnehydraulik, Grundwasserhydraulik
25	29	18.07.2025	UW-BHW-414-M	Zusammenfassung, Klausurvorbereitung

Fahrplan für heute ...

0. Rückblick letzte Veranstaltung: Netzwerke

1. ML: Definition
 2. ML: Anwendungsmöglichkeiten
 3. ML: Methodik
 4. ML: Algorithmen
 5. ML in der Forschung
 6. ML in der Hydrologie
-

7. Ausblick auf die nächste Veranstaltung: Mechanik

Maschinelles Lernen

Differences Between Machine Learning vs Neural Networks

"Machine Learning is an application or the **subfield of artificial intelligence** (AI). Machine Learning enables a system to automatically learn and progress from experience without being explicitly programmed. Machine Learning is a continuously developing practice. The goal of Machine learning is to understand the structure of data and fit that data into models, these models can be understood and used by people. In Machine Learning generally, the tasks are classified into broad categories. These categories explain how learning is received, two of the most widely used machine learning methods are supervised learning and unsupervised learning. The neural network is inspired by the structure of the brain. The neural network contains highly interconnected entities, called units or nodes. Neural networks are deep learning technologies. It generally focuses on solving complex processes. A typical neural network is a group of algorithms, these algorithms model the data using neurons for machine learning."

<https://www.educba.com/machine-learning-vs-neural-network/>

Maschinelles Lernen

Definition

” **Maschinelles Lernen** ist ein Oberbegriff für die „künstliche“ Generierung von Wissen aus Erfahrung: Ein künstliches System lernt aus Beispielen und kann diese nach Beendigung der Lernphase verallgemeinern. Das heißt, es werden nicht einfach die Beispiele auswendig gelernt, sondern es „erkennt“ Muster und Gesetzmäßigkeiten in den Lerndaten. So kann das System auch unbekannte Daten beurteilen (Lerntransfer) oder aber am Lernen unbekannter Daten scheitern (Überanpassung).”

Source: https://de.wikipedia.org/wiki/Maschinelles_Lernen

Maschinelles Lernen

Definition

”Maschinelles Lernen ist ein Oberbegriff für die „künstliche“ **Generierung von Wissen aus Erfahrung**: Ein künstliches System lernt aus Beispielen und kann diese nach Beendigung der Lernphase **verallgemeinern**. Das heißt, es werden nicht einfach die Beispiele auswendig gelernt, sondern es „erkennt“ **Muster und Gesetzmäßigkeiten in den Lerndaten**. So kann das System auch unbekannte Daten beurteilen (**Lerntransfer**) oder aber am Lernen unbekannter Daten scheitern (Überanpassung).”

Source: https://de.wikipedia.org/wiki/Maschinelles_Lernen

Maschinelles Lernen

Anwendungen

”Aus dem weiten Spektrum möglicher Anwendungen seien hier genannt: automatisierte Diagnoseverfahren, Erkennung von Kreditkartenbetrug, Aktienmarktanalysen, Klassifikation von Nukleotidsequenzen, Sprach- und Texterkennung sowie autonome Systeme.” Naturwissenschaften ?

Source: https://de.wikipedia.org/wiki/Maschinelles_Lernen

Maschinelles Lernen

Anwendungen

”Das Thema ist eng verwandt mit „Knowledge Discovery in Databases“ und „Data-Mining“, bei dem es jedoch vorwiegend um das Finden von neuen **Mustern** und **Gesetzmäßigkeiten** geht. Viele Algorithmen können für beide Zwecke verwendet werden. Außerdem können Methoden der „Knowledge Discovery in Databases“ genutzt werden, um Lerndaten für „maschinelles Lernen“ zu produzieren oder vorzuverarbeiten, und Algorithmen aus dem maschinellen Lernen finden beim Data-Mining Anwendung.”

Source: https://de.wikipedia.org/wiki/Maschinelles_Lernen

Maschinelles Lernen

Algorithmen

”Die praktische Umsetzung geschieht mittels Algorithmen. Verschiedene Algorithmen aus dem Bereich des maschinellen Lernens lassen sich grob nach diesem Schema einteilen:”

- ▶ Überwachtes Lernen (engl. supervised learning)
- ▶ Unüberwachtes Lernen (engl. unsupervised learning)

Source: https://de.wikipedia.org/wiki/Maschinelles_Lernen

Maschinelles Lernen

Algorithmen - Überwachtes Lernen


”Der Algorithmus lernt eine Funktion aus gegebenen Paaren von Ein- und Ausgaben. Dabei stellt während des Lernens ein „Lehrer“ den korrekten Funktionswert zu einer Eingabe bereit. Ziel beim überwachten Lernen ist, dass dem Netz nach mehreren Rechengängen mit unterschiedlichen Ein- und Ausgaben die Fähigkeit antrainiert wird, **Assoziationen** herzustellen. Ein Teilgebiet des überwachten Lernens ist die automatische Klassifizierung. Ein Anwendungsbeispiel wäre die Handschrifterkennung.”

Source: https://de.wikipedia.org/wiki/Maschinelles_Lernen

Maschinelles Lernen

Lineare Regression

”Die lineare Regression ist ein Spezialfall der Regressionsanalyse, also ein statistisches Verfahren, mit dem versucht wird, eine beobachtete abhängige Variable durch eine oder mehrere unabhängige Variablen zu erklären. Bei der linearen Regression wird dabei ein lineares Modell angenommen. Es werden also nur solche Zusammenhänge herangezogen, bei denen die abhängige Variable eine Linearkombination der Regressionskoeffizienten (aber nicht notwendigerweise der unabhängigen Variablen) ist.”




Quelle: https://de.wikipedia.org/wiki/Lineare_Regression

Maschinelles Lernen

Random Forest

”Ein Random Forest ist ein Klassifikations- und Regressionsverfahren, das aus mehreren unkorrelierten Entscheidungsbäumen besteht. Alle Entscheidungsbäume sind unter einer bestimmten Art von Randomisierung während des Lernprozesses gewachsen. ... Random Forests können auch zur Regression eingesetzt werden.”



Quelle: https://de.wikipedia.org/wiki/Random_Forest

ML Beispiele aus der Hydrologie

Maschinelles Lernen

... in der Hydrologie

maschinelles lernen hydrologie

Alle News Videos Bilder Shopping Mehr Einstellungen Tools

Ungefähr 9.320 Ergebnisse (0,41 Sekunden)

FAQ Machine Learning: Was Sie über Maschinelles Lernen wissen ...
<https://www.computerwoche.de/.../was-sie-ueber-maschinelles-lernen-wissen-muessen,...> ▾
Maschinelles Lernen wird heute mehr und mehr zum Mainstream. Waren selbstlernende Programme noch bis vor wenigen Jahren ausschließlich ein Thema für Universitäten, Forschungseinrichtungen und einige Technologieunternehmen, finden sie heute zunehmend Eingang in ganz normale Produkte und Lösungen.
Es fehlt: hydrologie

Programm — Professur für Hydrologie — TU Dresden
<https://tu-dresden.de/bu/umwelt/hydro/ihm/hydrologie/tdh2018/programm> ▾
16.11.2017 - Messen und Modellieren. Modellbasierte Planung von Messnetzen sowie Methoden zur Regionalisierung von Messdaten. Neue Datenquellen und Methoden zur inversen Modellierung. Datenbasierte Modellierung und maschinelles Lernen ...
Du hast diese Seite 3 Mal aufgerufen. Letzter Besuch: 25.01.18

Maschinelles Lernen – Wikipedia
https://de.wikipedia.org/wiki/Maschinelles_Lernen ▾
Maschinelles Lernen ist ein Oberbegriff für die „künstliche“ Generierung von Wissen aus Erfahrung: Ein künstliches System lernt aus Beispielen und kann diese nach Beendigung der Lernphase verallgemeinern. Das heißt, es werden nicht einfach die Beispiele auswendig gelernt, sondern es „erkennt“ Muster und ...
Es fehlt: hydrologie
Du hast diese Seite am 25.01.18 besucht.

Suche: maschinelles lernen hydrologie

- ▶ Google
- ▶ ChatGPT
- ▶ DeepSeek

Maschinelles Lernen

... in der Hydrologie

Water Resources Research



RESEARCH ARTICLE

10.1002/2016WR019933

Key Points:

- Groundwater level change can be modeled with high accuracy using machine learning methods
- Model framework does not require subsurface parameters and simulates comparable groundwater levels to numerical models of physical flow
- Seasonal irrigation demand has the highest relevance to groundwater level change compared to climate and streamflow inputs for most wells

Supporting Information:

- Supporting Information S1

Correspondence to:

Machine learning algorithms for modeling groundwater level changes in agricultural regions of the U.S.

S. Sahoo¹ , T. A. Russo¹ , J. Elliott^{2,3} , and I. Foster^{2,3,4}

¹Department of Geosciences, Pennsylvania State University, University Park, Pennsylvania, USA, ²Computation Institute, University of Chicago, Chicago, Illinois, USA, ³Mathematics and Computer Science Division, Argonne National Laboratory, Lemont, Illinois, USA, ⁴Department of Computer Science, University of Chicago, Chicago, Illinois, USA

Abstract Climate, groundwater extraction, and surface water flows have complex nonlinear relationships with groundwater level in agricultural regions. To better understand the relative importance of each driver and predict groundwater level change, we develop a new ensemble modeling framework based on spectral analysis, machine learning, and uncertainty analysis, as an alternative to complex and computationally expensive physical models. We apply and evaluate this new approach in the context of two aquifer systems supporting agricultural production in the United States: the High Plains aquifer (HPA) and the Mississippi River Valley alluvial aquifer (MRVA). We select input data sets by using a combination of mutual information, genetic algorithms, and lag analysis, and then use the selected data sets in a Multilayer Perceptron network



Maschinelles Lernen

Grundwasserwirtschaft

Sahoo, S., T. A. Russo, J. Elliott, and I. Foster (2017), Machine learning algorithms for modeling groundwater level changes in agricultural regions of the U.S., Water Resour. Res., 53, 3878–3895, doi:10.1002/2016WR019933.

HPA High Plains Aquifer

MRVA Mississippi River Valley alluvial Aquifer

Source: Sahoo et al. (2017)

Maschinelles Lernen

Grundwasserwirtschaft





Figure 1. (a) HPA and (b) MRVA showing observation wells (red circles), stream gauges (blue stars), and DSSAT-simulated annual average irrigation demand (m³/yr) at 5 arc min resolution. The irrigation demand in the HPA is shown for seven crops: corn, sorghum, soybean, cotton, barley, spring wheat, and winter wheat, and accounts for 83% of the total irrigated cropland. The irrigation demand in the MRVA is shown for five crops: cotton, sorghum, soybean, corn, and winter wheat, and accounts for 93% of the total irrigated cropland.

Source: Sahoo et al. (2017)

Maschinelles Lernen

Grundwasserwirtschaft



Source: Sahoo et al. (2017)

Maschinelles Lernen

Grundwasserwirtschaft




Figure 2. Methodological framework of the proposed groundwater model.

Source: Sahoo et al. (2017)

Maschinelles Lernen

Grundwasserwirtschaft




Figure 3. (a) Original time series of the rainfall anomalies. (b-e) Decomposed time series (4 RCs shown here out of 10 RCs) using SSA.

Maschinelles Lernen

Grundwasserwirtschaft




Figure 4. (a) Correlations and (b) respective time lags between monthly groundwater level and precipitation over the HPA for 687 well locations.

Source: Sahoo et al. (2017)

Maschinelles Lernen

Grundwasserwirtschaft




Figure 8. Average seasonal groundwater level uncertainty in model prediction for (a) 687 wells in the HPA and (b) 437 wells in MRVA calculated using HANN model and Monte Carlo method.

Source: Sebes et al. (2017)

Maschinelles Lernen

Grundwasserwirtschaft





Figure 9. Relative importance of model inputs to groundwater level change prediction by connection weight approach for the example wells in the (a) HPA and (b) MRVA (I: irrigation demand, P: precipitation, T: temperature, S: stream discharge), and the input parameter with the highest relevance at each well location using the HANN model for (c) 687 wells in the HPA and (d) 437 wells in the MRVA. The black stars in the HPA and MRVA indicate the locations of two example sites. The ranking for all of the input parameters and percentage of wells that fall under each category is included in Table 2.

Source: Sahoo et al. (2017)

Maschinelles Lernen

Grundwasserwirtschaft



Source: Sahoo et al. (2017)

Maschinelles Lernen

... in den Geowissenschaften

Geophysical Research Letters

RESEARCH LETTER

10.1002/2017GL075661

Key Points:

- A new geothermal heat flux map of Greenland is obtained within ~15% accuracy using machine learning techniques
- The new map honors regional geology, tectonic settings, and ice core measurements
- Pockets of high heat flux are predicted in central-north Greenland and upstream of several fast-flowing outlet glaciers

Supporting Information:

- Supporting Information S1

Correspondence to:

S. Rezvanbehbahani,
soroushr@ku.edu

Predicting the Geothermal Heat Flux in Greenland: A Machine Learning Approach

Soroush Rezvanbehbahani^{1,2} , Leigh A. Stearns^{1,2} , Amir Kadivar³ , J. Doug Walker¹ ,
and C. J. van der Veen⁴ 


¹Department of Geology, University of Kansas, Lawrence, KS, USA, ²Center for Remote Sensing of Ice Sheets, University of Kansas, Lawrence, KS, USA, ³Department of Mathematics and Statistics, McGill University, Montréal, Québec, Canada, ⁴Department of Geography and Atmospheric Sciences, University of Kansas, Lawrence, KS, USA

Abstract Geothermal heat flux (GHF) is a crucial boundary condition for making accurate predictions of ice sheet mass loss, yet it is poorly known in Greenland due to inaccessibility of the bedrock. Here we use a machine learning algorithm on a large collection of relevant geologic features and global GHF measurements and produce a GHF map of Greenland that we argue is within ~15% accuracy. The main features of our predicted GHF map include a large region with high GHF in central-north Greenland surrounding the NorthGRIP ice core site, and hot spots in the Jakobshavn Isbræ catchment, upstream of Petermann Gletscher, and near the terminus of Nioghalvfjærdsfjorden glacier. Our model also captures the trajectory of Greenland movement over the Icelandic plume by predicting a stripe of elevated GHF in central-east Greenland. Finally, we show that our model can produce substantially more accurate predictions if additional measurements of GHF in Greenland are provided.



Source: AGU

Maschinelles Lernen

... in der eigenen Forschung



Müglitz-Studie



Video

Simulationen: Thomas Kalbacher, Thomas Fischer, Johannes Boog, Erik Nixdorf
Visualisierung: Karsten Rink, Ozan Sen (Umweltinformatik)

Maschinelles Lernen

Quellen

1. Tobias Reitmaier: Aktives Lernen für Klassifikationsprobleme unter der Nutzung von Strukturinformationen. kassel university press, Kassel 2015, ISBN 978-3-86219-999-0, S. 1 (Google books).
2. Lillian Pierson: Data Science für Dummies. 1. Auflage. Wiley-VCH Verlag, Weinheim 2016, ISBN 978-3-527-80675-1, S. 105 f. (Google books).
3. Ralf Mikut: Data Mining in der Medizin und Medizintechnik. KIT Scientific Publishing, 2008, ISBN 978-3-86644-253-5, S. 34 (Google books).
4. Paul Fischer: Algorithmisches Lernen. Springer-Verlag, 2013, ISBN 978-3-663-11956-2, S. 6–7 (Google books).
5. Andreas C. Müller / Sarah Guido: Einführung in Machine Learning mit Python. Hrsg.: O'Reilly-Verlag. ISBN 978-3-96009-049-6 (oreilly.de [abgerufen am 28. November 2017]).
6. Sebastian Raschka: Machine Learning mit Python — ISBN 978-3-95845-422-4. mitp-Verlag, abgerufen am 28. November 2017

Testfragen

Maschinelles Lernen

Fragen

1. Beschreiben sie die Methode "Maschinelles Lernen" mit eigenen Worten (3 Sätze).
2. Was ist der Unterschied zwischen "supervised" und "un-supervised" Maschinellern Lernen ?
3. Welche Methoden des Maschinellen Lernens kennen Sie ?
4. ...