

# Maschinelles Lernen verbessert Gefährdungs- und Risikoanalysen von Naturgefahren

Heidi Kreibich, Kai Schröter, Yuri Shprits, Jonathan Bedford, Frederik Tilmann  
Deutsches GeoForschungsZentrum GFZ, Potsdam

*Hundreds of thousands of people are killed every year by disasters resulting from natural hazards, and property damage has been doubling about every seven years over the past four decades. Thus, understanding the causes and consequences of natural hazards and contributing to mitigation solutions is one of the grand challenges facing the GFZ German Research Centre for Geosciences. Increasingly, machine learning methods are being adopted by geoscientists as the wider scientific community begins to realise both the success and potential in employing a data science strategy to their research. GFZ scientists are using these methods to generate insights from large and heterogeneous data sets that would have been virtually impossible a decade ago. Such data sets consist of continuous recordings of natural and laboratory natural hazard data, hazard maps as well as exposure and damage data. In the case of supervised machine learning, predictions are optimized based upon features mined from the data and, in some cases, probabilities for specific events can be calculated. For instance, machine learning is applied for both classification of earthquake events and in attempts to predict future seismic behaviour in a target region. Additionally, machine learning, and in particular neural networks, are used to predict the planetary Kp-index and for reconstructions of the global plasmasphere dynamics depending on the geomagnetic conditions. Random forests and Bayesian Networks are used to analyse and model the complex damage processes during floods. The analysis and modelling of multi-hazard and cascading events is still a challenge, one that can also be tackled with machine learning. Thus, within the Natural Hazards research unit at GFZ, expertise with machine learning techniques is shared across disciplines and harmonised approaches of machine learning for improved multi-risk assessments are developed.*



Jedes Jahr werden Tausende Menschen durch Naturkatastrophen getötet und der verursachte Sachschaden hat sich während der letzten vierzig Jahre etwa alle sieben Jahre verdoppelt. Daher ist es eine der zentralen Herausforderungen am Deutschen GeoForschungsZentrum GFZ, die Ursachen und Konsequenzen von Naturgefahren besser zu verstehen und die Reduktion von Risiken zu unterstützen. Es werden grundlegende Prozesse untersucht, die zu einzelnen und kaskadierenden Naturgefahren führen, um ihre Dynamik und ihre Auswirkungen besser quantifizieren und prognostizieren zu können. Verfahren des maschinellen Lernens helfen auf Basis vorhandener Datenbestände und Algorithmen, Muster und Gesetzmäßigkeiten zu erkennen. Insbesondere die Analyse großer Datenmengen (z. B. Ergebnisse aus Haftgleit-Experimenten, bei denen das ruckartige Gleiten von gegeneinander bewegten Festkörpern untersucht wird) sowie heterogener Daten (z. B. Schadensinformationen) werden erleichtert, indem das maschinelle Lernen relevante Daten findet, extrahiert und zusammenfasst. Es können aber auch Vorhersagen auf Basis der analysierten Daten getroffen und Wahrscheinlichkeiten für bestimmte Ereignisse berechnet werden. So wird beispielsweise maschinelles Lernen nicht nur dazu verwendet, die komplexen Schädigungsprozesse bei Hochwasser zu analysieren, sondern auch, diese Prozesse besser zu verstehen, zu beschreiben und für Prognosen zu modellieren.

## Maschinelles Lernen in der Erbebenforschung

In der Erdbebenforschung wird maschinelles Lernen z. B. zur Klassifizierung von Ereignissen verwendet. Ein weiteres Ziel ist es, das zukünftige seismische Verhalten in einem Untersuchungsgebiet vorherzusagen. Letzteres ist dabei ein sehr viel ambitionierteres Forschungsziel, dessen Erreichen aufgrund der – verglichen mit dem Erdbebenzyklus – kurzen Beobachtungszeit, der relativen Seltenheit von großen Beben und der Schwierigkeit, Messdaten in unmittelbarer Nähe von aktiven Verwerfungen zu sammeln, gehemmt wird. Die stärksten Erdbeben – und damit die, für die eine Vorhersage besonders nutzbringend wäre – kommen so selten vor, dass es nicht genug Fallbeispiele gibt, um damit Verfahren

des maschinellen Lernens zuverlässig trainieren zu können. Außerdem befinden sich die seismogenen Bereiche der Verwerfungen üblicherweise viele Kilometer unter der Erdoberfläche.

Bisherige Anwendungen aus dem Bereich des maschinellen Lernens für die statistische Vorhersage von Erdbeben konzentrieren sich häufig auf die Daten aus Erdbebenkatalogen. Dabei besteht ein möglicher Ansatz darin, ein binäres Szenario dafür zu entwerfen, ob ein Erdbeben über einer bestimmten Stärke innerhalb eines Zeitfensters in der Zukunft eintritt (oder nicht) und sich dabei auf Merkmale aus einem Erdbebenkatalog zu stützen (z. B. *Adeli und Pannakat, 2009*). Mit dieser auf Kataloge gestützten Strategie konnte jedoch bisher kein großer wissenschaftlicher Durchbruch erzielt werden. Eine mögliche Erklärung für den ausbleibenden Erfolg könnte die Komplexität der Erdkruste sein, in der zahlreiche Verwerfungsstränge in einem sehr heterogenen Medium interagieren. Sehr vielversprechende Ergebnisse wurden dagegen im Bereich der Vorhersage des Auftretens und der Intensität von Laborerdbeben erzielt. Hierbei werden in Gesteinsproben im Labor durch schrittweise Scherung mehrfach makroskopische Brüche induziert. *Rouet-Leduc et al. (2017)* haben beispielsweise die Möglichkeit demonstriert, durch maschinelles Lernen den Eintrittszeitpunkt für zukünftige Brüche (definiert in Form eines Schwellenwerts für plötzlichen Spannungsabfall) auf der Basis von kontinuierlich aufgezeichneten Schallemissionen vorherzusagen. Mit Hilfe des Random-Forest-Algorithmus konnten diejenigen physikalischen Parameter identifiziert werden, die besondere Aussagekraft über den Spannungszustand des Systems haben. *Goebel et al. (2017)* ist es im Gesteinslabor des GFZ gelungen, einen Zusammenhang zwischen der Rauheit von Schwächezonen und der Größenverteilung von kleineren Erdbeben herzustellen, indem sie die Daten von zehntausenden von Schallemissionen aus einem Haftgleit-Versuch verarbeitet haben.

Obwohl die Scheruntersuchungen im Labor wichtige Ergebnisse für die Anwendung auf natürliche Systeme liefern, kann mit ihnen nicht die Interaktion zwischen verschiedenen Verwerfungszonen modelliert werden. Hier können analoge Modelle, sogenannte Sandkastenmodelle helfen, den Brückenschlag zur Natur zu erleichtern. Ein realistisches Ziel für maschinelles Lernen in den nächsten Jahren ist es, die Vorhersagbarkeit der scheinbar komplexen Oberflächenbewegungen, z. B. von Subduktionszonen, in Sandkastenmodellen für verschiedene Größenordnungen zu erhöhen. Mit solchen Modellen können komplexere geometrische Gegebenheiten wiedergegeben werden, als bei Haftgleit-Laborexperimenten zu einzelnen Verwerfungen. Deshalb eignen sie sich dazu, die im Labor gewonnenen Erkenntnisse auf tektonische Systeme in der Größenordnung der Erdkruste zu übertragen. So kann im Labor untersucht werden, welche Messgrößen oder Kombinationen von Messgrößen (festgelegte Merkmale für den Bereich des maschinellen Lernens) in Observatorien erfasst werden sollten (Abb. 1).

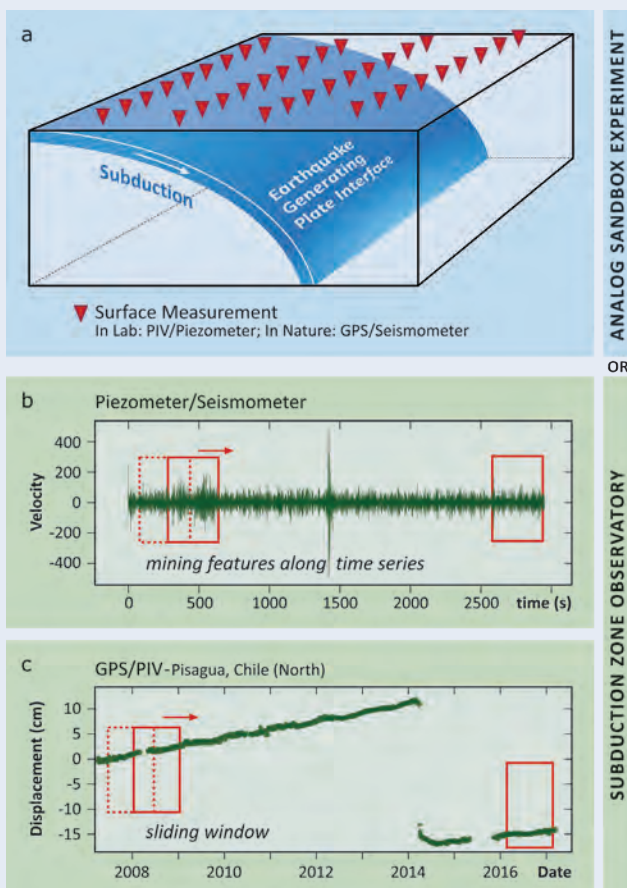
*Links: Verfahren des maschinellen Lernens helfen die Prozesse, die zu Naturgefahren und daraus resultierenden Konsequenzen führen, wie hier das Elbe-Hochwasser 2006 in Meißen, besser zu verstehen und zu modellieren. (Foto: U. Herrmann)*

*Left: Machine learning methods help to better understand and model processes which lead to natural hazards and resulting consequences, like shown here the Elbe flood 2006 in Meißen.*



**Kontakt:** H. Kreibich  
(heidi.kreibich@gfz-potsdam.de)





ANALOG SANDBOX EXPERIMENT

SUBDUCTION ZONE OBSERVATORY

Abb. 1: (a) Schematische Darstellung einer Subduktionszone, wie sie beispielsweise im Norden von Chile zu finden ist oder auch in Sandkastenmodellen im Labor simuliert wird. Es werden dort unterschiedliche Messreihen gesammelt, die aber im Allgemeinen nur an der Oberfläche gewonnen werden können; in den Plattenrandobservatorien des GFZ sind das geodätische und seismische Methoden; im Labor werden Particle Image Velocimetry (PIV) und Piezometer äquivalent verwendet (b, c). Beispielhafte mit einem Seismometer (b) und GPS-Sensor (c) gewonnene Messreihen der Deformationen auf sehr unterschiedlichen Zeitskalen. Über diese Art von Messreihen können sogenannte Features erstellt werden, indem gleitende Fenster über die Daten gelegt und innerhalb dieser Zeitfenster unterschiedliche Messgrößen berechnet werden. Diese Features können dann in einem Algorithmus für maschinelles Lernen verwendet werden, mit dem das zukünftige Verhalten der Messreihe oder andere Parameter des Spannungszustands und der Erdbebenaktivität vorhergesagt werden.

Fig. 1: (a) Sketch of a subduction zone (as observed by the plate boundary observatory in Northern Chile (IPOC) or modelled in a scaled analog experiment). Multiple time series measurements on the surface are acquired using geodetic and seismic methods in the IPOC observatory or derived using Particle Image Velocimetry (PIV) and piezometers for sandbox models (b, c). Example of seismometer time series (b) and surface motion (GPS) (c) from the IPOC observatory. With such time series, time-variant features can be generated by sliding windows over the data and calculating different measures of the data within those windows. Such features can then be fed into a machine learning algorithm for predicting future behavior of the time series or other parameters characterising the stress state or earthquake activity.

Zu den zentralen Fragestellungen für die nächsten Jahre gehört zu einem, auf welchen Zeitskalen mit welcher Genauigkeit Vorhersagen getroffen werden können. Dies kann beispielsweise für Frühwarnsysteme, d. h. Zeiträume von Zehnersekunden (Erdbebenfrühwarnung) oder Minuten (Tsunamiwarnung), für Prognosen zeitabhängiger Erdbebengefährdung für Zeiträume von Tagen bis Monaten oder für Vorhersagen zur Kinematik von Plattenschnittstellen über Jahrzehnte wichtig sein.

Andere Forschungsfragen sind, wie viele Oberflächenbeobachtungen benötigt werden, um belastbare Vorhersagen machen zu können, und in welchem Abstand die Messungen zur Verwerfungsfläche erfolgen müssen. Der größte Vorteil einer Laborsituation gegenüber der Natur ist die Möglichkeit, mehrere seismische Zyklen zu messen. Ein Zyklus beginnt mit einem Bruch und geht über das Heilen der Verwerfung bis zum Aufbau der Spannung zu einem weiteren Bruch. Im Feld kann dagegen an natürlichen Verwerfungen nur ein kleiner Teil eines Zyklus instrumentell beobachtet werden. Ein Ansatz kann darin bestehen, zunächst die Vorhersagbarkeit von kleineren Erdbeben zu erforschen, die innerhalb eines Zyklus viele Male auftreten. Vielversprechende Beobachtungen wurden bei starken Erdbeben gemacht, die sich in jüngster Zeit an einigen umfangreich instrumentierten Plattengrenzen ereignet haben. Hier ist jeweils dem Hauptbeben eine längere Erdbebenvorbereitungsphase vorausgegangen, die sich in erhöhter seismischer Aktivität und geodätisch aufgezeichneten Transienten zeigte (Schurr et al., 2014; Kato et al., 2012). Hieraus ergibt sich eine weitere Frage, die mit Hilfe von maschinellem Lernen geklärt werden könnte: Inwieweit geben geophysikalische Messungen von transienten Ereignissen Hinweise auf das bevorstehende Eintreten von großen Erdbeben?

## Neue Methoden zur Beobachtung des Weltraumwetters

Weltraumwetter ist der Sammelbegriff für die Beschreibung der vom Weltraum ausgehenden Gefahren. Die Quelle des Weltraumwetters ist die Sonne, die regelmäßig große Wolken von ionisiertem Gas mit heißem Plasma aussendet, die erhebliche Auswirkungen auf die Technologie im Weltall und auf das Leben auf der Erde haben können (Abb. 2). Geomagnetische Stürme, die durch Stoßwellen des Sonnenwinds ausgelöst werden, können zu Störungen von Stromnetzen und Satelliten führen, die wiederum große wirtschaftliche Verluste verursachen können und ein erhebliches Risiko für die Raumfahrt darstellen.

Das Verständnis von Weltraumwetterprozessen war bisher eine Herausforderung, da Beobachtungen oft sehr spärlich und auf Orte beschränkt waren, an denen Satelliten In-situ-Messungen liefern konnten. Aus diversen Weltraummissionen der NASA, ESA und anderer Organisationen stehen inzwischen jedoch umfassende und langfristige Datenreihen zur Verfügung. Fortschritte bei maschinellen Lerntechniken ermöglichen es, auf Grundlage dieser Datensätze komplexe empirische Modelle zu erstellen. Im Folgen-




Abb. 2: Die Strahlungsumgebung nahe der Erde. Die Intensität der Teilchenstrahlung ist farblich gekennzeichnet. Ebenfalls schematisch dargestellt sind die Van Allen Probes, Raumfahrzeuge der NASA, die Messungen der Strahlung, des Wellenfelds und der Plasmaumgebung nahe der Erde liefern.

Fig. 2: Near Earth radiation environment. Color-coding indicates the intensity of particle radiation. Also schematically shown are two of NASA's Van Allen Probes spacecraft that provide measurement of the radiation, wave and plasma environment.

den werden zwei Beispiele für die Anwendung von maschinellen Lerntechniken vorgestellt, die in der Sektion „Magnetosphärenphysik“ am GFZ eingesetzt werden. Diese ermöglichen es, die Weltraumwetterbedingungen besser zu beobachten und vorherzusagen.

### Rekonstruktion der globalen Plasmadichte

Die Plasmaelektronendichte ist ein entscheidender Parameter für die Simulation und Modellierung in der Weltraumphysik und ist zudem wichtig für die Vorhersage und Vermeidung gefährlicher Effekte des Weltraumwetters. Dieser Kennwert charakterisiert die Anzahl von Teilchen in einem Einheitsvolumen im Raum innerhalb der so genannten Plasmasphäre, einer Region kalten und dichten Plasmas, das mit der Erde rotiert. Die Plasmasphäre ist sehr dynamisch und ihre Form sowie ihre Größe werden stark durch solare und geomagnetische Bedingungen beeinflusst. Die genaue Modellierung der Dynamik der Plasmasphäre stellt eine langfristige Herausforderung für die Wissenschaft dar. Vorhandene empirische Modelle der Plasmadichte nehmen an, dass die Plasmasphäre näherungsweise kreisförmig ist, was für ruhige geomagnetische Bedingungen gelten kann, jedoch nicht während geomagnetischer Stürme.

Mit Hilfe maschinellen Lernens und insbesondere neuronaler Netzwerke konnte am GFZ ein Modell entwickelt werden, das in der Lage ist, die globale Plasmasphärendynamik in Abhängigkeit

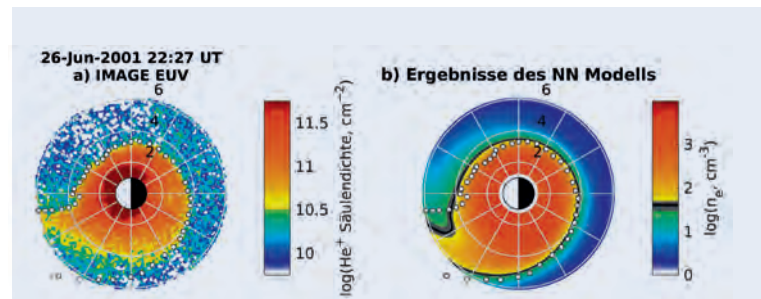


Abb. 3: Vergleich zwischen IMAGE-Satellitendaten (links) und Modellergebnissen (rechts) für eine geringe geomagnetische Störung am 26. Juni 2001. Die weißen Punkte zeigen die Außengrenze der Plasmasphäre an, anhand derer die Qualität des Modells beurteilt werden kann. Die Plasmadichte ist farblich gekennzeichnet. Die grauen und schwarzen Linien im Modellergebnis repräsentieren die Außengrenze der Plasmasphäre, die durch das Modell identifiziert wird. Das neuronale Netzwerk erfasst die Erosion auf der Nachtseite und die Bildung einer Plasmawolke im Nachmittagsbereich.

Fig. 3: Comparison between IMAGE satellite data (left) and model output (right) for a minor geomagnetic disturbance interval on 26 June 2001. The white dots indicate the outer boundary of the plasma sphere to which we compare our model. Color represents the plasma density, and the gray and black lines in the model output represent the outer boundary of the plasmasphere identified by the model. The neural network captures the erosion on the nightside and the formation of a plume in the afternoon sector.

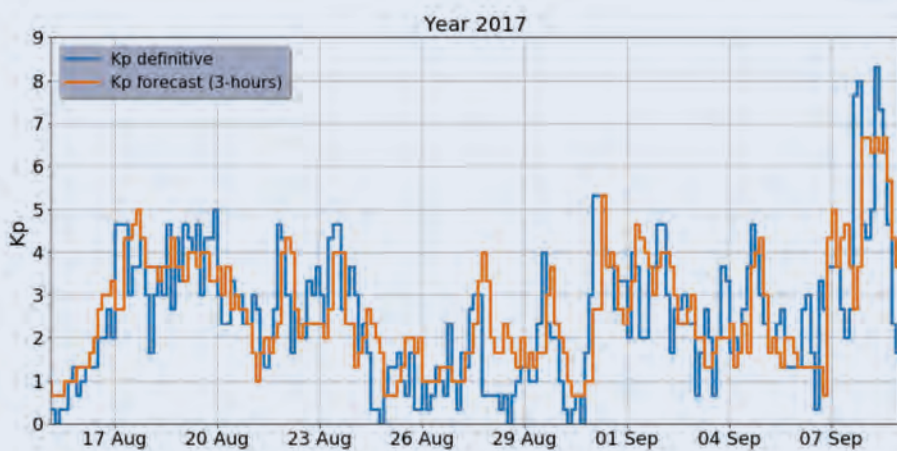


Abb. 4: Beispiel für die Kp-Vorhersage unter Verwendung eines neuronalen Netzwerks, das mit einminütigen Sonnenwinddaten trainiert wurde. Die Daten stammen aus dem OMNIWeb, einem Datendienst der NASA (<http://omniweb.gsfc.nasa.gov/form/dx1.html>). Der Kp-Index wurde durch das GFZ zur Verfügung gestellt (<http://www.gfz-potsdam.de/en/kp-index>).

Fig. 4: An example of Kp forecast using a neural network trained on 1-minute resolution solar wind data coming from NASA's OMNIWeb data service (<http://omniweb.gsfc.nasa.gov/form/dx1.html>). Kp index was provided by GFZ (<http://www.gfz-potsdam.de/en/kp-index>).

von den geomagnetischen Bedingungen zu rekonstruieren (Zhelavskaya et al., 2017). Neuronale Netzwerke können die Suche nach nicht-linearen multivariablen Beziehungen zwischen Ein- und Ausgabeparametern unterstützen. Die Eingabeparameter für die Modellierung sind der zeitliche Verlauf des Sonnenwinds und die geomagnetischen Parameter. Der einzige Ausgabeparameter ist die ortsabhängige Plasmadichte. Das Modell basiert auf einem vier Jahre umfassenden Beobachtungsdatensatz der Plasmadichte von den im Jahr 2012 gestarteten Van-Allen-Sonden, die eine beträchtliche räumliche Abdeckung um die Erde für eine große Vielfalt von geomagnetischen Bedingungen liefert (Zhelavskaya et al., 2016). Die beiden Van-Allen-Sonden bewegen sich auf elliptischen Bahnen um die Erde. Die Messungen dieser Mission sind daher räumlich begrenzt, da die Daten nur entlang der Satellitenbahnen verfügbar sind. Trotz dieser Schwierigkeit kann das neuronale Netzwerk die räumliche Verteilung von Plasma in der Plasmasphäre erfolgreich erlernen. Das trainierte neuronale Netzwerk kann das globale Bild der Plasmasphäre in allen radialen Abständen und Längengraden rekonstruieren.

Ein Beispiel für eine solche globale Rekonstruktion ist in Abb. 3 dargestellt, in der das am GFZ entwickelte Modell auf ein kleines geomagnetisches Störereignis am 26. Juni 2001 angewendet wurde. Es zeigt sich eine deutliche Übereinstimmung zwischen den Daten aus der Satellitenmission IMAGE und denjenigen Daten, die mit neuronalen Netzwerken erzeugt wurden.

### Kp-Vorhersage

Der Kp-Index ist ein Indikator für irreguläre Störungen im Erdmagnetfeld, die durch die solare Teilchenstrahlung verursacht werden. Der planetarische Kp-Index wiederum ist

der gewichtete Durchschnitt von Kp-Indizes aus einem globalen Netzwerk geomagnetischer Observatorien. Der Index wird durch die Sektion „Geomagnetismus“ des GFZ berechnet und weltweit verwendet. Er ist wichtig für die Vorhersage potenzieller geomagnetischer Stürme, die u. a. ein Risiko für Satellitentechnik, bemannte Raumfahrt und den Luftverkehr darstellen.

Die Entwicklungsschritte für die Kp-Vorhersage ähneln denen des Plasmadichte-Vorhersagemodells. Dabei wird eine große Anzahl neuronaler Netzwerke mit unterschiedlichen Eingabevariablen für verschiedene Vorlaufzeiten (Zeitabschnitte der Sonnenwind- und interplanetaren Magnetfeld (IMF)-Daten) sowie internen Netzwerkparametern (Anzahl von Neuronen in der ausgeblendeten Schicht) trainiert, um die Konfiguration der Eingabedaten und interne Parameter zu bestimmen, die ein quantitativ genaues Modell ergeben, ohne dass es zu einer Überanpassung an die Trainingsdaten kommt.

Abbildung 4 zeigt die Ergebnisse für die Vorhersage des Kp-Index im Jahr 2017. Dazu wurde das neuronale Netzwerkmodell unter Verwendung von Daten aus den Jahren von 2000 bis 2016 trainiert und validiert. Das in der Abbildung gezeigte Ereignis stammt aus Testdaten, die vorher unbekannt für das neuronale Netzwerk waren. Unverarbeitete Eingaben in das neuronale Netzwerk, also die Sonnenwindgeschwindigkeit  $V$ , Protonendichte  $n$ , IMF-Stärke ( $B$ ), Nord-Süd-Komponente des IMFs ( $B_z$ ) werden weiter verarbeitet, um insgesamt 36 spezifische Merkmale zu erhalten, die auf statistischer Häufigkeit innerhalb ihrer Zeitreihe basieren (z. B. Durchschnittswerte über mehrere Zeitfenster).





Abb. 5: Ein Bayessches Netz, hier schematisch dargestellt, ist ein gerichteter azyklischer Graph, in dem die Knoten Zufallsvariablen und die Verbindungen bedingte Abhängigkeiten zwischen den Variablen beschreiben. Jedem Knoten ist eine bedingte Wahrscheinlichkeitsverteilung der durch ihn repräsentierten Variable hinterlegt. Bayessche Netze helfen Hochwasserschädigungsprozesse auf der Gebäudeskala besser zu verstehen und werden zur Schadensmodellierung von lokaler bis kontinentaler Skala verwendet (IMPRES, 2018).

Fig. 5: A Bayesian network, as sketched here, is a directed acyclic graph, in which the nodes represent random variables and the edges represent conditional dependencies between the variables. Each node is associated with a probability function of the variable it is representing. Bayesian networks help to better understand flood damage processes on building level and are used for flood loss modelling from local to continental scale (IMPRES, 2018).

## Analyse und Modellierung von Hochwasserschäden

Hochwasser verursachen hohe Schäden, wie beispielsweise das Extremereignis im Juni 2013, das allein in Deutschland 14 Todesopfer und direkte ökonomische Schäden in Höhe von acht Milliarden Euro verursacht hat. Um ein effizientes Hochwasserisikomanagement zu ermöglichen, sind verlässliche Analysen notwendig. Das heißt, dass nicht nur die Hochwassergefährdung, sondern auch die resultierenden Schäden möglichst genau abgeschätzt werden müssen. Im Vergleich zur Hydrologie und Hydraulik ist noch recht wenig bekannt über die komplexen physikalischen und sozio-ökonomischen Prozesse und deren Interaktion, die zu Hochwasserschäden führen und deren Ausmaß bestimmen. Daher ist insbesondere die Schadensmodellierung mit hohen Unsicherheiten behaftet. Um Entscheidungen im Hochwasserrisikomanagement besser unterstützen zu können, müssen die Schädigungsprozesse genauer verstanden und beschrieben werden sowie durch adäquate Modelle die Unsicherheiten aufgezeigt, quantifiziert und reduziert werden (Abb. 5).

Empirische Daten sind ein Schlüssel, um die komplexen Zusammenhänge unterschiedlichster Einflussfaktoren zu erkennen. Die GFZ-Sektion „Hydrologie“ hat seit dem Hochwasserereignis im August 2002 für alle großen, schadensträchtigen Hochwasserereignisse in Deutschland Daten über die entstandenen Schäden und möglichst viele potenziell wichtige Einflussfaktoren durch Befragungen von betroffenen Privathaushalten und Unternehmen erhoben. Auf diese Weise ist eine weltweit einzigartige Datenbank mit objektspezifischen Hochwasserschäden entstanden – einzigartig im Hinblick auf die Detailliertheit der enthaltenen Informationen und die Anzahl der enthaltenen Schadensfälle. Allerdings ist die Datengrundlage, die nominal, ordinal und metrisch skalierte Da-

ten sowie relativ viele Fehlwerte enthält, sehr heterogen. Weitere Datenquellen, die am GFZ zur Charakterisierung der Exposition und Vulnerabilität genutzt werden, sind Fernerkundungsdaten, 3-D Stadtmodelle (Abb. 6) und die OpenBuildingMap.

Verfahren des maschinellen Lernens helfen, explorativ die Schädigungsprozesse besser zu verstehen und die wichtigsten schadensbeeinflussenden Variablen zu identifizieren. Beispielsweise wurden auf Basis von insgesamt 783 Schadensdaten von urbanen Sturzflutereignissen zunächst 55 Variablen abgeleitet, die einen möglichen Einfluss auf den Wohngebäudeschaden haben. Mittels vier verschiedener maschineller Lernverfahren wurden die wichtigsten Variablen ermittelt, die einerseits bestimmen, ob ein Schaden aufgetreten ist, und andererseits diejenigen Variablen, die die Höhe des Schadens bestimmen. Sowohl die gewählten linearen Verfahren LASSO und Ridge, als auch die baumbasierten Verfahren Conditional Random Forest und Gradient Boosting Machines, zeigen sich dabei robust gegenüber der zum Teil hohen Multikolarität des vorhandenen Datensatzes. Basierend auf den standardisierten Regressionskoeffizienten bei LASSO und Ridge und der sogenannten Permutation Importance bei den baumbasierten Verfahren wurden die wichtigsten Variablen ermittelt. Hierbei konnte gezeigt werden, dass neben dem Wasserstand vor allem Widerstandsfaktoren wie die Haushaltsgröße oder das Wissen über Hochwassergefährdung darüber entscheiden, ob ein Gebäudeschaden entsteht. Die Höhe des Schadens wird dagegen in erster Linie durch Einwirkungsfaktoren wie Wasserstand, Dauer der Überflutung und Kontamination beeinflusst.

Zudem nutzt die GFZ-Sektion „Hydrologie“ Verfahren des maschinellen Lernens, um Schädigungsprozesse zu modellieren. Beispielsweise haben Schröter *et al.* (2014) in einer mikroskaligen Studie auf Basis von gebäudespezifischen Daten Schadenmodelle

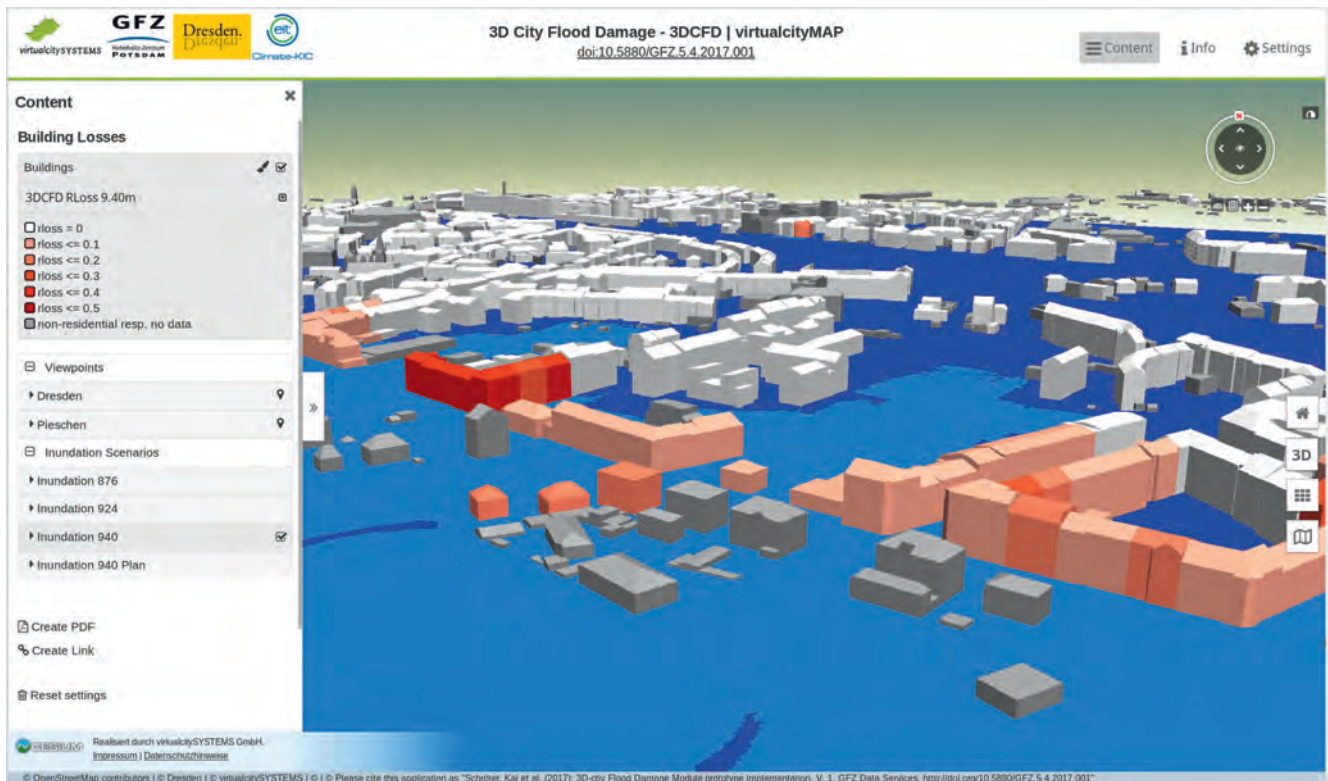


Abb. 6: Hochwasserschadenmodellierungstool auf Basis von 3-D Stadtmodellen (nach Schröter et al., 2018)

Fig. 6: Flood loss modelling tool on basis of 3D city models (according Schröter et al., 2018)

verschiedener Komplexität verglichen: ein Modell hatte nur eine Eingangsvariable, ein anderes Modell hatte zehn Eingangsvariablen. Außerdem waren die Modellstrukturen sehr unterschiedlich und variierten von traditionellen, deterministischen Wasserstandsschadensfunktion bis zu Verfahren des maschinellen Lernens wie Random Forests und Bayesschen Netzen. Die Studie zeigte, dass vor allem die Modellstruktur entscheidend für die verlässliche Abschätzung von Schäden ist. Bayessche Netze lieferten die verlässlichsten Schätzungen, insbesondere bei der Übertragung der Modelle in Zeit und Raum. Ein bedeutender Vorteil ist außerdem, dass Bayessche Netze Einblicke in die Abhängigkeitsstrukturen der Daten geben und konsistent Daten und Modellunsicherheiten quantifizieren (Abb. 7).

Zur multivariablen, probabilistischen Schadenmodellierung auf der Mesoskala, d. h. auf Basis von Landnutzungseinheiten, wurde das Modell BT-FLEMO entwickelt (Kreibich et al., 2016). Der direkte Schaden an Wohngebäuden wird anhand eines Ensembles von Regressionsbäumen mit acht Eingangsparametern geschätzt, nämlich Wasserstand, Überflutungsdauer, Fließgeschwindigkeit, Kontamination, Vorsorgemaßnahmen, Gebäudenutzfläche und -wert sowie Wiederkehrperiode des Hochwasserabflusses. Das Modell schätzt die ensemblebasierte Verteilung der zu erwartenden Schäden an Wohngebäuden pro Gemeinde und liefert somit neben der Schadensschätzung eine quantitative Abschätzung der

Unsicherheiten. Die Modellvalidierung zeigte, dass BT-FLEMO die bisherigen deterministischen Modelle in ihrer Vorhersagegenauigkeit übertrifft. Darüber hinaus liefert das Modell auch zuverlässige Ergebnisse, wenn einige Eingangsdaten fehlen. Die Unsicherheit des Modellierungsergebnisses wird durch die Betrachtung von Modellensembles quantifiziert. Informationen darüber sind für die Risikokommunikation, aber auch für die Entscheidungsfindung im Risikomanagement, d. h. bei der Hochwasserschutz- und Vorsorgeplanung von enormer Bedeutung.

## Ausblick

Wie diese Beispiele aus der am GFZ durchgeführten Forschung zu Erdbeben, Weltraumwetter und Hochwasser zeigen, helfen Verfahren des maschinellen Lernens die Prozesse, die zu einzelnen Naturgefahren und daraus resultierenden Konsequenzen führen, besser zu verstehen und zu modellieren. Eine große Herausforderung sind nach wie vor die Analyse und Modellierung von multiplen Gefährdungen bzw. von kaskadierenden Ereignissen. Auch in diesem interdisziplinären Feld kann maschinelles Lernen neue Erkenntnisse und verbesserte Modelle liefern. Daher werden im Rahmen der Forschungseinheit Naturgefahren am GFZ Erfahrungen mit Verfahren des maschinellen Lernens disziplinübergreifend ausgetauscht und harmonisierte Ansätze des maschinellen Lernens für verbesserte Multi-Risiko-Analysen entwickelt.

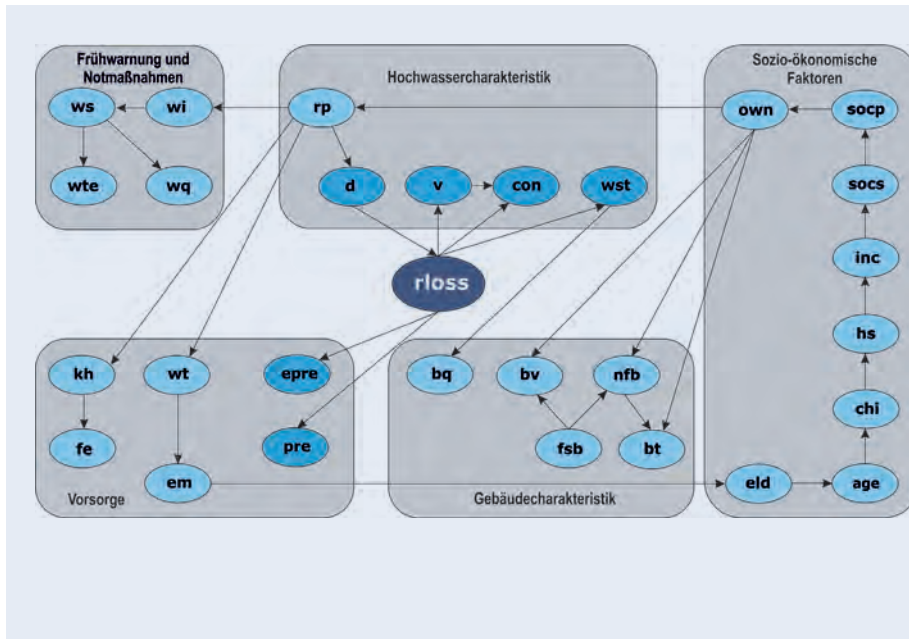


Abb. 7: Ein Bayessches Netz gibt Einblicke in bedingte Abhängigkeiten von Einflussgrößen und deren gemeinsamen Wahrscheinlichkeiten. Der relative Hochwasserschaden (rloss) ist direkt mit Variablen der Hochwassercharakteristik, wie dem Wasserstand (wst) und Variablen der Vorsorge, wie dem Vorsorgeindikator (pre) verbunden, aber indirekt auch mit anderen Variablen, wie der Gebäudequalität (bq).

Fig. 7: A Bayesian network describes the conditional dependencies of data and their joint probability. The relative flood loss (rloss) is directly linked to variables of flood characteristic, like water depth (wst) and variables of precaution like precaution indicator (pre), but also indirectly linked to other variables like building quality (bq).

## Literatur

- Adeli, H., Panakkat, A. (2009): A probabilistic neural network for earthquake magnitude prediction. - *Neural Networks*, 22, 7, pp. 1018–1024. DOI: <https://doi.org/10.1016/j.neunet.2009.05.003>
- Goebel, T., Kwiatek, G., Becker, T., Brodsky, E. E., Dresen, G. (2017): What allows seismic events to grow big?: Insights from b-value and fault roughness analysis in laboratory stick-slip experiments. - *Geology*, 45, 9, pp. 815–818. DOI: <https://doi.org/10.1130/G39147.1>
- IMPRES, 2018. Intermediate Report – Advances in novel concepts in hydro-meteorological risk assessments: <http://impres.eu/innovation/novel-concepts> [letzter Zugriff: 22.08.2018]
- Kato, A., Obara, K., Igarashi, T., Tsuruoka, H., Nakagawa, S., Hirata, N. (2012): Propagation of slow slip leading up to the 2011 Mw 9.0 Tohoku-Oki earthquake. - *Science*, 335, 6069, pp. 705–708. DOI: <https://doi.org/10.1126/science.1215141>
- Kreibich, H., Botto, A., Merz, B., Schröter, K. (2017): Probabilistic, Multi-variable Flood Loss Modeling on the Mesoscale with BT-FLEMO. - *Risk analysis*, 37, 4, pp. 774–787. DOI: <https://doi.org/10.1111/risa.12650>
- Rouet-Leduc, B., Hulbert, C., Bolton, D. C., Ren, C. X., Riviere, J., Marone, C., Guyer, R. A., Johnson, P. A. (2018): Estimating fault friction from seismic signals in the laboratory. - *Geophysical Research Letters*, 45, 3, pp. 1321–1329. DOI: <https://doi.org/10.1002/2017GL076708>
- Schröter, K., Kreibich, H., Vogel, K., Riggelsen, C., Scherbaum, F., Merz, B. (2014): How useful are complex flood damage models? - *Water Resources Research*, 50, 4, pp. 3378–3395. DOI: <https://doi.org/10.1002/2013WR014396>
- Schröter, K., Lüdtkke, S., Redweik, R., Meier, J., Bochow, M., Ross, L., Nagel, C., Kreibich, H. (2018): Flood loss estimation using 3D city models and remote sensing data. - *Environmental Modelling and Software*, 105, pp. 118–131. DOI: <https://doi.org/10.1016/j.envsoft.2018.03.032>
- Schurr, B., Asch, G., Hainzl, S., Bedford, J., Hoechner, A., Palo, M., Wang, R., Moreno, M., Bartsch, M., Zhang, Y., Oncken, O., Tilmann, F., Dahm, T., Victor, P., Barrientos, S., Vilotte, J.-P. (2014): Gradual unlocking of plate boundary controlled initiation of the 2014 Iquique earthquake. - *Nature*, 512, pp. 299–302. DOI: <https://doi.org/10.1038/nature13681>
- Zhelavskaya, I., Shprits, Y., Spasojević, M. (2017): Empirical Modeling of the Plasmasphere Dynamics Using Neural Networks. - *Journal of Geophysical Research*, 122, 11, pp. 11,227–11,244. DOI: <https://doi.org/10.1002/2017JA024406>
- Zhelavskaya, I., Spasojević, M., Shprits, Y., Kurth, W. S. (2016): Automated determination of electron density from electric field measurements on the Van Allen Probes spacecraft. - *Journal of Geophysical Research*, 121, 5, pp. 4611–4625. DOI: <https://doi.org/10.1002/2015JA022132>