

Wie schnell steigt Magma auf?

Maschinelles Lernen (ML) hilft bei der Antwort

Wissenschaftler*innen der Geoinformatik und der Geowissenschaften bündeln ihre Expertisen, um Georisiken zu minimieren. In diesem Beitrag zeigen sie, dass maschinelles Lernen (ML) für die Auswertung von großen analytischen Datensätzen unumgänglich ist, um Prozesse in Magma-Reservoirs nachzuvollziehen. Der Einsatz von ML ermöglicht ein schnelles Reagieren bei laufenden vulkanischen Eruptionen, wie zum Beispiel La Palma.



Minerale sind Zeitzeugen der Erdgeschichte. Die Bestimmung des Alters der Erde, unser Wissen über die Entstehungsgeschichte von Gebirgen sowie Erosionsgeschwindigkeiten basieren auf Untersuchungen von Mineralen. Aus ihrer chemischen Zusammensetzung kann ermittelt werden, bei welcher Tiefe (oder Druck) und Temperatur sich die Minerale gebildet haben. Minerale sind somit „Thermometer“ und „Barometer“ und werden für die Rekonstruktion von Gebirgsbildung und von magmatischen Prozessen unter Vulkanen herangezogen.

So wie Menschen haben jedoch Minerale ihren ganz eigenen Charakter. Manche pas-

sen ihre chemische Zusammensetzung sehr schnell auf Änderungen in der Umgebung an; manche sind träge und können langzeitige geologische Veränderungen überleben. Aufgrund dieses Verhaltens können chemische Heterogenitäten in Mineralen genutzt werden, um dynamische Prozesse während Eruptionen zu untersuchen und um Georisiken nachzuvollziehen. Bei Eruptionen wie zum Beispiel La Palma 2021 (Dauer insgesamt 4 Monate), können die Lavaströme kontinuierlich beprobt werden, um die Aufstiegsgeschwindigkeit der Magmen zu bestimmen. Wenn diese Information mit dem Monitoring der seismischen Aktivität gekoppelt wird, kön-

nen die Magmabewegungen sehr genau verfolgt und Prognosen über die Dauer der Eruptionen erstellt werden. Das Problem bei der praktischen Umsetzung dieses Ansatzes ist, dass für eine zuverlässige Auswertung die Analyse von Hunderten von Kristallen in einer Gesteinsprobe notwendig ist. Eine manuelle Auswertung ist daher in einem akzeptablen Zeitfenster unmöglich. Eine schnelle Auswertung ist essenziell für die Prognose des Ablaufs einer Eruption und ist nur mit dem Einsatz von ML möglich. Maschinelle Lernverfahren könnten die Beprobung prinzipiell auch automatisiert auswerten und bieten so potenziell Echtzeitfähigkeit.

Abbildung 1
Vulkanausbruch auf La Palma vom November 2021.
Foto: Edgar Zorn, GeoForschungsZentrum GFZ, Potsdam

Der Ansatz des maschinellen Lernens

Beim ML wird ein Modell zur automatischen Lösung spezifischer Aufgaben aus vorgegebenen Daten, so genannten Trainingsdaten, erlernt. Im vorliegenden Fall besteht diese Aufgabe in der Analyse von Bildern von Gesteinen, um Informationen über die chemischen Eigenschaften der abgebildeten Minerale abzuleiten,

Millionen von Parametern benötigen, die im Training bestimmt werden. Zu diesem Zweck ist eine Funktion zu minimieren, welche die Fehler der Ergebnisse des neuronalen Netzes bei Anwendung auf die Trainingsdaten beschreibt. Neben Hardware mit ausreichend hoher Rechenleistung sowie einer großen Anzahl an Trainingsbeispielen sind auch die Wahl der Netzwerkarchitektur und die Defi-

sich aus der Summe der Daten Informationen über Magmakammern und Aufstiegsprozesse der Magmen im Inneren des Vulkans ableiten. Dieser Ansatz ist sehr zeitaufwändig, da die Konzentration der Elemente Fe und Mg in Olivin mit einer Auflösung von 1 µm bestimmt werden muss. Folglich wäre die vulkanische Eruption bereits vorbei, wenn die Auswertung der Daten abgeschlossen ist.




Abbildung 2 Die verschiedenen Etappen in der Untersuchung von vulkanischen Gesteinen. Von links nach rechts: Probenahme; Herstellung von Dünnschliffen und Identifizierung von einzelnen Kristallen (grüne Minerale sind hier Olivin) mit REM und EDX; Erstellung von Element-Konzentrationsprofilen (hier Magnesium (Mg)-Gehalt) mit der konventionellen Methode (ESM; oben) bzw. mit ML (unten); Anwendung zur Charakterisierung magmatischer Prozesse. Die Auswertung mit ML ermöglicht auch die Identifizierung von mehreren Populationen von Olivinen. Quelle: eigene Darstellung

zum Beispiel über den Mineraltyp oder das Verhältnis bestimmter Elemente. Die Trainingsdaten bestehen aus Beispielen, für welche die zu präzisierenden Ausgaben (Sollwerte) bereits bekannt sind. Im Training werden die Parameter des Modells so bestimmt, dass dessen Ausgaben für die Trainingsbilder möglichst gut zu den Sollwerten passen. Im Anschluss kann das Modell schnell und ohne menschliche Interaktion neue Bilder auswerten. Heutzutage kommen bei solchen Aufgaben häufig künstliche neuronale Netze zum Einsatz. Mit ihrer Hilfe können sehr komplexe Zusammenhänge modelliert werden, wozu sie mitunter mehrere

nition einer geeigneten Zielfunktion wichtige Faktoren.

Praktisches Beispiel: Untersuchung von Mineralen in vulkanischen Gesteinen

Der Einsatz von neuronalen Netzen zur automatischen Analyse eines vulkanischen Gesteins wurde im Rahmen einer Kooperation zwischen den Geowissenschaften und der Geoinformatik durchgeführt. In einem konventionellen manuellen Ansatz wird die chemische Zusammensetzung von Mineralen – hier Olivine – mit einer Elektronenstrahlmikrosonde (ESM) angefertigt. Werden genügend Kristalle analysiert, lassen

Aus diesem Grund wurde ein alternativer Ansatz entwickelt, der auf der Verwendung eines neuronalen Netzes basiert (vgl. Abbildung 2). Aus einer vulkanischen Gesteinsprobe wurde ein Dünnschliff mit einer Fläche von ca. 12 cm² vorbereitet. Die Probe wurde in einem Rasterelektronenmikroskop (REM) aufgenommen. Mit dem REM können in kürzester Zeit große Bereiche der Probe aufgenommen werden, wenn auch ohne explizite Informationen über die chemische Zusammensetzung der Kristalle. Mit dem Energiedispersive Röntgen Sensor (EDX), welcher vergleichsweise langsam ist, werden explizite Informationen über die chemische Zusammensetzung der Olivine




Abbildung 3
 Prozessierung mit Hilfe der
 Verfahren des ML.
 NN: Neuronales Netz.
 Quelle: eigene Darstellung

gewonnen. Um den manuellen Prozess der Analyse der Kristalle zu ersetzen, müssen zunächst automatisch die Olivin Kristalle (Abbildung 2 und 3) auf Basis der REM-Daten erkannt und für diese großflächig und schnell Profile bestimmt werden. Dies kann in eine Standardaufgabe des Deep Learning überführt werden, wenn entsprechende Trainingsdaten verfügbar sind. Die aufwändige Generierung dieser Daten konnte automatisiert werden, weil sowohl REM und EDX Aufnahmen vorhanden waren, wodurch aus den REM Daten die Zielwerte für das Training automatisch abgeleitet werden können, sodass das Modell lernen kann, anhand der EDX Aufnahmen zu prädizieren, wo sich Olivinkristalle befinden. Anhand von einigen wenigen manuell erstellten Profilen (mit ESM) kann der Zusammenhang zwischen REM Werten und chemischen Eigenschaften gelernt werden („Kalibrierung“ in Abbildung 3). Im Anschluss kann das Modell genutzt werden, um die chemischen Eigenschaften für das ausgewählte Mineral großflächig und in kürzester Zeit aus den REM-Daten zu prädizieren. Mit diesem automatisierten Ansatz können mehr als 10.000 chemische Profile durch alle Olivinkristalle des Dünnschliffes (mehr als 2000) in drei Minuten erfasst werden. Damit kann eine statistisch relevante Zahl von

Messungen generiert werden, die es ermöglicht unterschiedliche Populationen von Kristallen zu identifizieren (farbige Profile in Abb. 2) und die einzelne Geschichte der Kristalle nachzuvollziehen (zum Beispiel die Aufstiegsge-
 schwindigkeit).

Fazit

Die Verwendung von ML in den Geowissenschaften eröffnet ganz neue Möglichkeiten für die schnelle Analyse gro-

ßer Datenmengen. Dies gilt auch im Kontext der Geowissenschaften für die Analyse von Gesteinsproben. Eine Herausforderung bleibt das Erstellen geeigneter Trainingsdaten, jedoch bedeutet dies nicht zwangsläufig, dass Menschen diese mit großem manuellem Aufwand generieren müssen. Wie im Beispiel gezeigt, kann eine geschickte Kombination von vorhandenen Sensordaten genutzt werden, um mit geringem Aufwand Trainingsdaten zu erzeugen.



Prof. Dr. rer. nat. Francois Holtz
 Jahrgang 1960, ist seit 1996 Professor am Institut für Mineralogie. Er ist er Ko-Sprecher des Leibniz Forschungszentrums FZ:GEO. Der Schwerpunkt seiner Forschung liegt auf Simulationen von geologischen Hochtemperatur - Prozessen im experimentellen Labor. Kontakt: f.holtz@mineralogie.uni-hannover.de



Dr. Renat Almeev
 Jahrgang 1970, ist wissenschaftlicher Mitarbeiter am Institut für Mineralogie. Seine Forschungsschwerpunkte liegen im Bereich der Experimentellen Petrologie und der thermodynamischen Modellierung von geologischen Hochtemperatur-Prozessen. Kontakt: r.almeev@mineralogie.uni-hannover.de



apl. Prof. Dr. techn. Franz Rottensteiner

Jahrgang 1967, ist außerplanmäßiger Professor am Institut für Photogrammetrie und Geo-Information, wo er seit 2008 die Gruppe „Photogrammetrische Bildanalyse“ leitet. Der Schwerpunkt seiner Forschung liegt auf der automatischen Bildanalyse mit Hilfe von Verfahren des maschinellen Lernens. Seit 2018 ist er Mitglied im FZ:GEO. Kontakt: rottensteiner@ipi.uni-hannover.de



M.Sc. Dennis Cyrill Wittich

Jahrgang 1990, ist wissenschaftlicher Mitarbeiter und Doktorand am Institut für Photogrammetrie und GeoInformation. Seine Forschungsschwerpunkte liegen im Bereich Deep Learning und Domänenadaptation. Kontakt: wittich@ipi.uni-hannover.de



Prof. Dr.-Ing. habil. Monika Sester

Jahrgang 1961, ist Professorin und Leiterin des Instituts für Kartographie und Geoinformatik. In der Forschung beschäftigt sie sich mit ihrem Team mit Fragen der Automation in der räumlichen Datenverarbeitung, u.a. mit Methoden der KI, speziell Lernverfahren. Sie ist Ko-Sprecherin des FZ:GEO. Kontakt: monika.sester@ikg.uni-hannover.de



M.Sc. Artem Leichter

Jahrgang 1986, ist wissenschaftlicher Mitarbeiter und Doktorand am Institut für Kartographie und Geoinformatik. Sein Forschungsschwerpunkt liegt im Bereich ML mit räumlichen Daten. Kontakt: leichter@ikg.uni-hannover.de