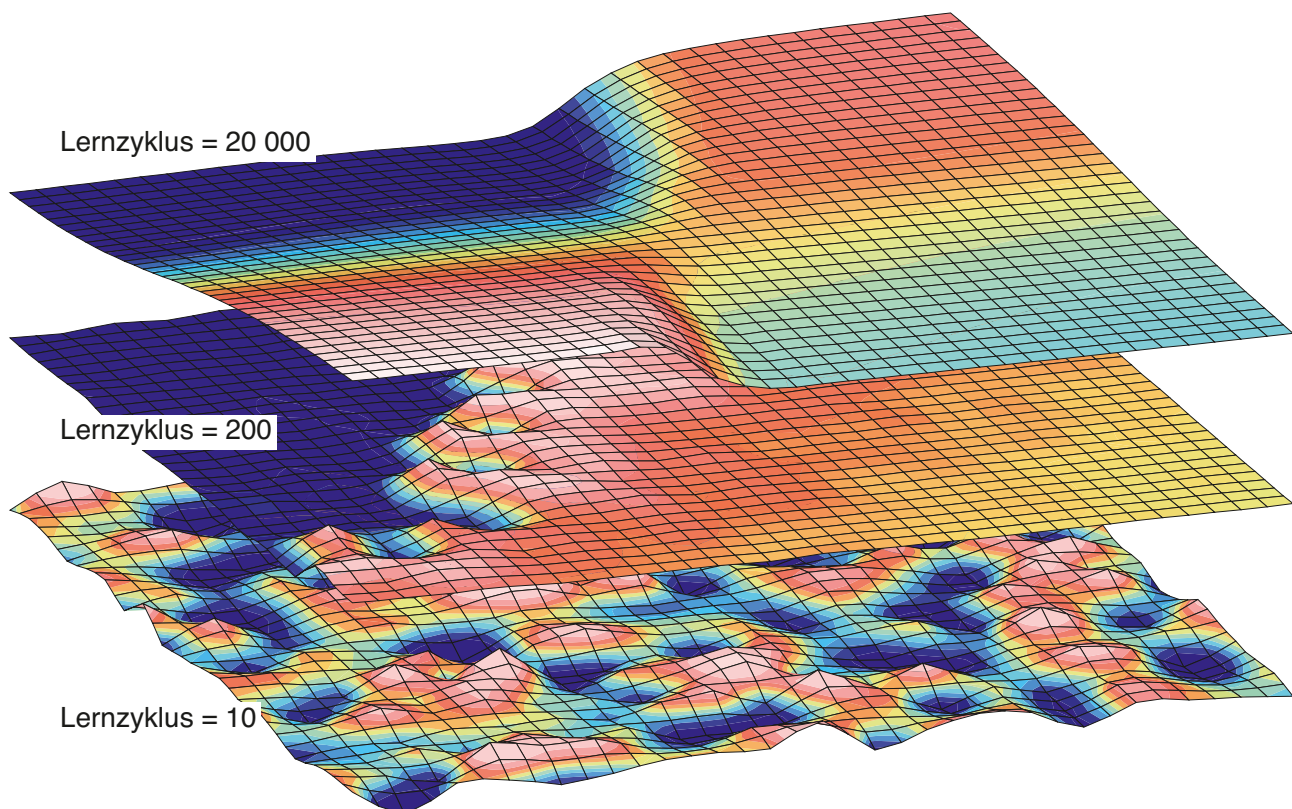


# Neuronale Netze und Selbstorganisation – neue Perspektiven bei der Interpretation von Geodaten

Klaus Bauer, Umar Muksin, Gerard Muñoz  
Deutsches GeoForschungsZentrum GFZ, Potsdam

*Neural networks are simplified mathematical models to simulate certain aspects of information processing in biological nervous systems. Some principles adopted from nature include parallel processing, learning by example, and abstraction of knowledge. Neuro-computing is a rapidly growing branch of research, where constantly new types of neural networks are developed for different applications. Pattern recognition and classification is the typical application of such approaches. Many tasks in geosciences, particularly in data interpretation, can be considered and treated as classification problems. In such a terminology, the studied objects (e.g. sub-regions of earth models) are classified as rock types based on characteristic features (e.g. physical properties). Numerical solutions have to address challenges such as incorrectness and incompleteness of data, and overlap in some properties for different lithologies. The self-organizing map is an intriguing concept, which allows to establish a certain classification behavior by unsupervised learning. We developed a work flow at GFZ, which includes preparation of data, application of learning rules, the segmentation of the trained map by adopting image processing techniques, and employment of knowledge. Applications are shown from geothermal exploration projects in the Northeast German basin and in Indonesia, where different geophysical models from the same study area were combined for a joint lithological interpretation.*



Die Interpretation von Geodaten lässt sich häufig als Problem der Mustererkennung und Klassifizierung beschreiben. Dabei werden Untersuchungsobjekte wie z. B. Gesteinsproben, Tiefenintervalle in Bohrungen, Regionen innerhalb eines 2D- oder 3D-Untergrundmodells oder Fernerkundungsdaten an Hand von charakteristischen Merkmalen (z. B. physikalische Kenngrößen, chemische Zusammensetzung, Isotopenverhältnisse oder Signalform-Eigenschaften) einer bestimmten Kategorie – in der Regel einem Gesteinstyp – zugeordnet.

Bei der mathematisch-numerischen Lösung von Teilaspekten dieser komplexen Aufgabenstellung ergeben sich eine Reihe von Schwierigkeiten: (1) Die Ausgangsdaten sind immer unvollständig auf Grund von Limitierungen bei der Datengewinnung (nur eine begrenzte Anzahl von Proben kann genommen werden; eingeschränkte Zugänglichkeit der Zielregion bei geophysikalischen Experimenten). (2) Naturgemäß sind die zu analysierenden Daten verrauscht und mit Fehlern behaftet. (3) Nicht immer ist vorab klar, welche Eigenschaften für die untersuchte Fragestellung besonders wichtig sind. (4) Die für eine bestimmte Klasse (Gesteinstyp) charakteristischen Merkmale weisen eine gewisse Streubreite auf, so dass es in manchen Eigenschaften zu Überlappungen mit anderen Klassen kommen kann.

Neuronale Netze sind, neben statistischen Verfahren, ein moderner Ansatz für die numerische Behandlung von Mustererkennungs- und Klassifizierungsproblemen, der den oben genannten Herausforderungen Rechnung trägt. Dieser Artikel beschäftigt sich mit dem mathematischen Konzept der sogenannten selbstorganisierenden Karten, einem speziellen Verfahren innerhalb der Neuroinformatik. Wir beschreiben eine am Deutschen GeoForschungsZentrum GFZ entwickelte Methodik und zeigen deren Anwendung auf verschiedene Fragestellungen bei der geothermischen Exploration, einem Schwerpunktthema am GFZ.

*Links: Eine selbstorganisierende Karte verändert sukzessive ihre Parameter während des algorithmischen Lernens an Hand von Datenbeispielen.*

*Left: The parameters of a self-organizing map are successively modified during the algorithmic learning phase while data examples are analysed.*

## Was sind neuronale Netze?

Neuronale Netze sind mathematische Modelle, mit denen bestimmte Aspekte der Informationsverarbeitung in biologischen Nervensystemen in stark vereinfachter Weise nachgebildet werden. Als wesentliche Prinzipien werden dabei beispielsweise die parallele Bearbeitung und Verteilung von Information, Lernfähigkeit sowie Abstraktionsvermögen simuliert. In den meisten Fällen realisiert man diese neuronalen Modelle als Computerprogramme. Für verschiedene Aufgabenstellungen wurde eine Reihe von Netztypen entwickelt, die sich hinsichtlich Aufbau, Funktionsweise und Lernstrategie unterscheiden. Wie beim biologischen Vorbild bilden die namensgebenden Neuronen die Grundelemente eines neuronalen Netzes. An diesen Knotenpunkten werden Informationen gebündelt, durch bestimmte mathematische Operationen verarbeitet und über eine Vernetzung an andere Neuronen weitergeleitet. Die Berechnungsvorschriften sind bei jedem Netztyp anders definiert. In der Regel wird der am Neuron eingehende Wert mit relativ einfachen, stetig differenzierbaren Funktionen in einen Ausgabewert umgewandelt. Als Beispiel sei hier die Sigmoid-Funktion genannt. Die eigentliche Leistungsfähigkeit der neuronalen Netze entsteht durch die parallele Anwendung dieser Funktionen an vielen Knotenpunkten. Die Neuronen werden in Schichten zusammengefasst – auch dies ist eine Anleihe aus der Natur. Schnittstellen nach außen gibt es über eine Eingabeschicht zur Aufnahme von Daten, sowie, für die meisten Netztypen, über eine weitere Schicht zur Ausgabe der verarbeiteten Information. Alle internen Schichten und deren Vernetzung untereinander, sowie die Verknüpfung mit den externen Schnittstellen werden schließlich zu einer Netzwerk-Architektur zusammengefasst.

Bei Anwendungen fungieren neuronale Netze in ihrer Gesamtheit betrachtet als Eingabe-Ausgabe-System, haben demnach eine Filter-Funktion. Auf der Eingabeseite werden die zu klassifizierenden Daten eingelesen. Ähnlich wie bei der Mustererkennung beim Menschen dürfen diese Daten auch fehlerbehaftet, verrauscht und unvollständig sein. Die Ausgabe ist eine Klassifizierung der Eingabedaten, eine Zuordnung zu einer bestimmten Kategorie, also eine Erkennung. Das gesuchte Eingabe-Ausgabe-Verhalten wird in einer Trainingsphase an Hand von Beispielen erlernt. Dafür gibt es prinzipiell zwei Lernstrategien: Beim sogenannten überwachten Lernen werden Eingabemuster zusammen mit der gewünschten Netzausgabe vorgegeben. Auf diese Weise kann man a priori Wissen in die Datenanalyse einfließen lassen. Im mathematisch-numerischen Sinn entspricht das überwachte Lernen einer Optimierungsaufgabe. Hierfür kommen beispielsweise lokale Suchverfahren wie die Gradientenabstiegsmethode zum Einsatz. Das nicht-überwachte Lernen erfolgt ohne Vorgabe der Netzausgabe. Die Mustererkennung wird allein durch die in



**Kontakt:** K. Bauer  
(klaus@gfz-potsdam.de)

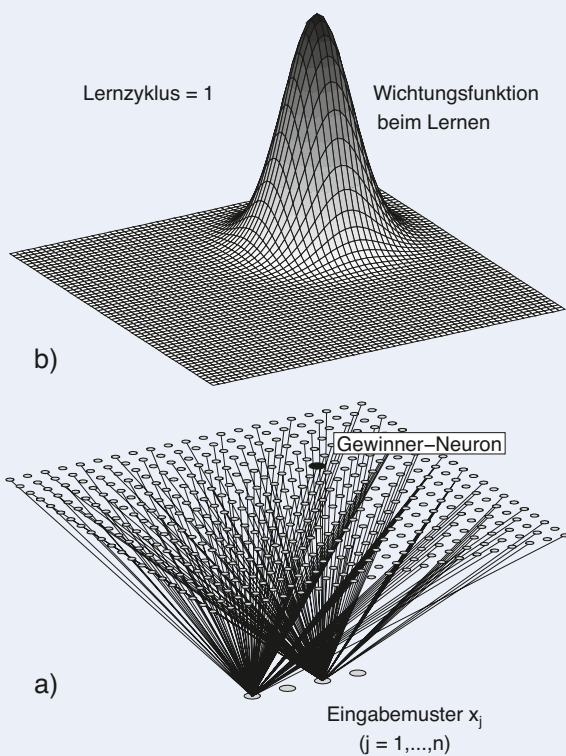


Abb. 1: a) Prinzipieller Aufbau eines neuronalen Netzes vom Typ „Selbstorganisierende Karte“. b) Eine Gauß-Funktion wird zur Gewichtung bei der Anwendung von Lernregeln verwendet.

Fig. 1: a) General architecture of a self-organizing map, the neural network type discussed in this article. b) A Gaussian is used as a weighting function during the application of a learning rule.

den Datenbeispielen enthaltenen Informationen erlernt. Der Vorteil in diesem Fall ist die Vermeidung von unkorrekten Vorgaben oder Vorprägungen (Bias) durch den Nutzer. Die mathematischen Aspekte des nicht-überwachten Lernens werden im Folgenden skizziert.

## Selbstorganisierende Karten

Die sogenannten selbstorganisierenden Karten wurden vom finnischen Informatikprofessor Teuvo Kohonen entwickelt (Kohonen, 2001). Es handelt sich hierbei um den wahrscheinlich am häufigsten verwendeten Typ eines neuronalen Netzes mit einem nicht-überwachten Lernverfahren. Mit dieser Methodik können Datensätze in Teilgruppen mit jeweils ähnlichen Eigenschaften zerlegt und daraufhin klassifiziert werden. Ein wichtiger Aspekt ist hierbei, dass die Aufteilung in Kategorien ausschließlich auf Grund der inhärenten Eigenschaften der Daten erfolgt. Im Englischen spricht man deshalb auch von Data Mining.

Eine selbstorganisierende Karte besteht aus einer Eingabe sowie einer Neuronen-Schicht (Abb. 1a). Letztere, auch Kohonen-Schicht genannt, ist eine zweidimensionale Anordnung von Knoten. An der Eingabe werden Muster in Form von n-dimensionalen Daten-Vektoren eingelesen. Die Dimension n auf der Eingabeseite wird durch die Anzahl der zu Grunde gelegten Eigenschaften (Merkmale) vorgegeben. Ein Muster kann beispielsweise ein Zellblock in einem geologisch-geophysika-

lischen Untergrundmodell sein, für den verschiedene physikalische Eigenschaften bestimmte worden sind. Die Anzahl der Neuronen in der darüber angeordneten Schicht soll generell wesentlich kleiner als die Gesamtzahl der zu analysierenden Muster sein (Kohonen, 2001). Um z. B. bei einer Anwendung etwa 300 000 Muster zu analysieren, verwendeten wir eine Schicht mit 20 mal 20 Knoten (Muksin et al., 2013).

Die am GFZ entwickelte Methodik einer selbstorganisierenden Karte beinhaltet folgende Arbeitsschritte: (1) Aufbereitung der Daten, (2) nicht-überwachte Lernphase, (3) Segmentierung der trainierten Kohonen-Schicht mit Hilfe von Bildbearbeitungsalgorithmen, sowie (4) Anwendung des erlernten Wissens und Klassifizierung aller Daten. Im ersten Schritt werden die zu klassifizierenden Daten in Eingabemuster umgewandelt: Zur Veranschaulichung zeigt Abb. 2a ein Beispiel mit synthetischen Modellen für verschiedene geophysikalische Parameter aus hypothetischen seismischen und magnetotellurischen Experimenten. In der Regel sind solche Modelle wegen des unterschiedlichen Auflösungsvermögens der verschiedenen geophysikalischen Methoden nicht äquivalent parametrisiert. Deshalb ist zunächst eine Interpolation auf ein vereinheitlichtes Gittermodell erforderlich. Für jeden Gitterblock werden daraufhin die verschiedenen Kenngrößen (in diesem Fall: sogenannte P-Geschwindigkeit einer seismischen Kompressionswelle, Vertikalgradient der P-Geschwindigkeit, Dezimal-Logarithmus des elektrischen Widerstands) in Form eines Datenvektors  $\vec{x}(t)$  zusammengefasst ( $t$  steht für die Auswahl einer bestimmten Gitterzelle):

$$\vec{x}(t) = \left( v_p(t), \frac{dv_p}{dz}(t), \log \rho(t) \right)^T \quad (1)$$

Für den elektrischen Widerstand bestimmt man hier den Dezimal-Logarithmus, weil dieser bei Gesteinen häufig über mehrere Größenordnungen variieren kann. Um alle Eingangsgrößen bei der Mustererkennung gleich zu behandeln, werden die einzelnen Vektorkomponenten mit Hilfe der jeweiligen Mittelwerte und Streubreiten auf das Intervall (-1,1) normiert. Diese Normierung muss nach Abschluss der Analysen rückgängig gemacht werden.

Während des iterativen Lernprozesses werden per Zufall immer wieder Datenvektoren ausgewählt, an die Kohonen-Schicht weitergeleitet und eine Lernregel angewendet. Für diese Zwecke existiert für jedes Neuron  $i$  ein sogenannter Modellvektor  $\vec{m}_i(t)$  mit der gleichen Dimension wie die Datenvektoren. Zu Beginn werden die Komponenten der Modellvektoren mit Zufallszahlen initialisiert. Daraufhin wird bei jedem Iterationsschritt  $t$  das sogenannte Gewinner-Neuron ermittelt, dessen Modellvektor  $\vec{m}_w(t)$  den kleinsten euklidischen Abstand zum aktuell ausgewählten Datenvektor  $\vec{x}(t)$  aufweist:

$$\forall i, \|\vec{x}(t) - \vec{m}_w(t)\| < \|\vec{x}(t) - \vec{m}_i(t)\|. \quad (2)$$

Die nun angewendete Lernregel soll bewirken, dass der Modell-






Abb. 2:

- a) Synthetisch erzeugte Erdmodelle für verschiedene physikalische Parameter.
- b) Komponenten der Kohonen-Schicht sowie Verteilung des Vektorgradienten nach Abschluss der Lernphase.
- c) Bestimmung eines lithologischen Modells durch Anwendung des erlernten Wissens.
- d) Histogramme zeigen die petrophysikalische Signatur der verschiedenen abgeleiteten Klassen.

Fig. 2:

- a) Synthetic earth models showing different physical properties.
- b) Components of the Kohonen layer together with the distribution of vector gradients after finishing the learning phase.
- c) A lithological model is derived by application of the learned knowledge.
- d) Histograms reveal the petrophysical signature for each class.

vektor des Gewinner-Neurons sowie, in etwas abgeschwächter Form, die Modellvektoren in der unmittelbaren Umgebung dem Eingabevektor  $\vec{x}(t)$  ähnlicher werden. Weiter entfernte Neuronen sollen dabei unverändert bleiben. Dieses Verhalten wird durch folgende Operation erreicht:

$$\vec{m}_i(t+1) = \vec{m}_i(t) + \lambda(t) * n_{w_{ij}}(t) * (\vec{x}(t) - \vec{m}_i(t)) \quad (3)$$

Gleichung (3) bedeutet, dass alle Modellvektoren in Richtung des Eingabevektors korrigiert werden. Die Korrekturterme werden mit Hilfe einer am Gewinner-Neuron zentrierten Gauß-Funktion gewichtet (siehe Abb. 1):

$$n_{w_{ij}}(t) = \exp\left(-r_{w_{ij}}^2 / 2\sigma^2(t)\right), \quad (4)$$

Eine weitere Skalierung erfolgt mit der sogenannten Lernrate  $\lambda(t)$ . Mit zunehmendem Lernfortschritt werden sowohl die Lernrate als auch die Halbwertsbreite der Gauß-Funktion (Parameter  $\sigma(t)$ ) kontinuierlich verkleinert.

Die häufig wiederholte Anwendung von Gleichung (3) führt dazu, dass für ähnliche Datenvektoren immer wieder die gleichen Neuronen (oder deren Nachbarn) auf der Kohonen-Schicht als Gewinner ermittelt werden. In einem weiteren, mathematischen Sinn entspricht dieses Verhalten einer topologischen Abbildung zwischen dem n-dimensionalen Parameterraum der Daten und dem 2-dimensionalen Raum der Kohonen-Schicht. Abb. 2b zeigt für jede Komponente die Werteverteilung auf der trainierten Kohonen-Schicht nach Abschluss der Lernphase. Man berechnet nun bestimmte Ähnlichkeitsmaße, um Regionen mit vergleichbaren Merkmalen zu identifizieren und zu separieren. Eine gängige Methode ist die Bestimmung des mittleren Abstands zwischen den Modellvektoren benachbarter Neuronen, beispielsweise für jeweils neun Knoten:

$$u_i = \frac{1}{N} \sum \|\vec{m}_i - \vec{m}_j\|_{i \neq j} \quad (5)$$

Alternativ verwenden wir den Vektorgradienten als Maß für die Änderung der Modellvektoren in x- und y-Richtung auf der Kohonen-Schicht:

$$|\nabla \vec{m}_i| = \sqrt{(\partial \vec{m}_i / \partial x)^2 + (\partial \vec{m}_i / \partial y)^2}. \quad (6)$$

Die Gradientenverteilung in Abb. 2b (oben) zeigt Gebiete mit kleinen Gradienten (weiß), die bestimmte Charakteristika in den Eingangsdaten repräsentieren. Diese Regionen werden durch große Gradientenwerte (dunkle Funktionsberge) voneinander getrennt. Durch die Verwendung des Vektorgradienten konnten wir ein automatisches Verfahren zur Aufteilung der Kohonen-Schicht in unterschiedliche Klassen (Gesteinstypen) implementieren. Dabei werden die Funktionsberge als symbolische Wasserscheiden interpretiert, die man sinngemäß durch eine Flutung der Funktionstopographie detektieren kann (Bauer et al., 2012).

Abb. 2c illustriert, wie das erlernte Wissen auf alle Daten angewendet wird. Für jede Gitterzelle wird das Gewinner-Neuron auf der segmentierten Kohonen-Schicht ermittelt, und entsprechend seiner Klassenzugehörigkeit im Untergrundmodell farblich kodiert. In diesem Fall ergeben sich vier Lithologien, die in Schichten angeordnet sind. Das durch den Algorithmus abgeleitete lithologische Modell entspricht nahezu perfekt der vorgegebenen Struktur (siehe schwarze Schichtgrenzen in Abb. 2a und 2c). Die Histogramm-Verteilungen in Abb. 2d zeigen die petrophysikalischen Signaturen jeder Klasse. Interessanterweise konnte das neuronale Netz die unterschiedliche Signifikanz der verschiedenen Parameter erkennen – die Klassenaufteilung basiert vor allem auf den verschiedenen Vertikalgradienten der P-Geschwindigkeit, die anderen Merkmale zeigen weniger Differenzierung sowie Überlappungen zwischen verschiedenen Lithologien.

## Anwendungsbeispiele in der Geothermie

Bei der geothermischen Erkundung bedient man sich eines umfassenden Spektrums geowissenschaftlicher Teildisziplinen und Methoden, um das Entwicklungspotenzial eines Untersuchungsgebiets abzuschätzen und Detailinformationen über den Untergrund für die Planung künftiger Geothermie-Anlagen bereitzustellen. Wichtige Fragestellungen sind hierbei u. a. eine möglichst genaue Kenntnis des Temperaturfelds, die Erstellung eines geologisch-geophysikalischen Untergrundmodells, der Nachweis von Störungssystemen als natürliche Transportwege für warme Fluide sowie die Chemie der natürlichen Wässer und Gase. Vor allem bei der Kombination der verschiedenen Informationen für eine gemeinsame Interpretation sind neue Methoden gefragt.

Im *In-situ*-Geothermielabor Groß Schönebeck, nördlich von Berlin, erforschen GFZ-Wissenschaftlerinnen und -Wissenschaftler Teilaspekte von der Erschließung des geothermischen Reservoirs bis zur Energiewandlung in einem Kraftwerk unter realen Bedingungen. Beispielsweise wird untersucht, wie geophysikalische Methoden möglichst effizient für die geothermische Erkundung des Untergrunds eingesetzt werden können. Dabei werden magnetotellurische und seismische Experimente durchgeführt. Bei der Magnetotellurik wird die elektrische Leitfähigkeit der Gesteine im Untergrund mit natürlichen elektromagnetischen Feldern bestimmt. Die kontrollierte Anregung seismischer Wellen dient zur Ableitung der elastischen Gesteinseigenschaften im Untergrund. Beide Methoden ergänzen sich, weil die elektrischen Leitfähigkeiten primär durch die Porenraumeigenschaften der Gesteine und die elastischen Parameter vor allem durch die feste Gesteinsmatrix beeinflusst werden.

Anhand dieser Experimente wurde erstmalig untersucht, wie Ergebnisse aus seismischen und magnetotellurischen Verfahren mit Hilfe der selbstorganisierenden Karten gemeinsam inter-

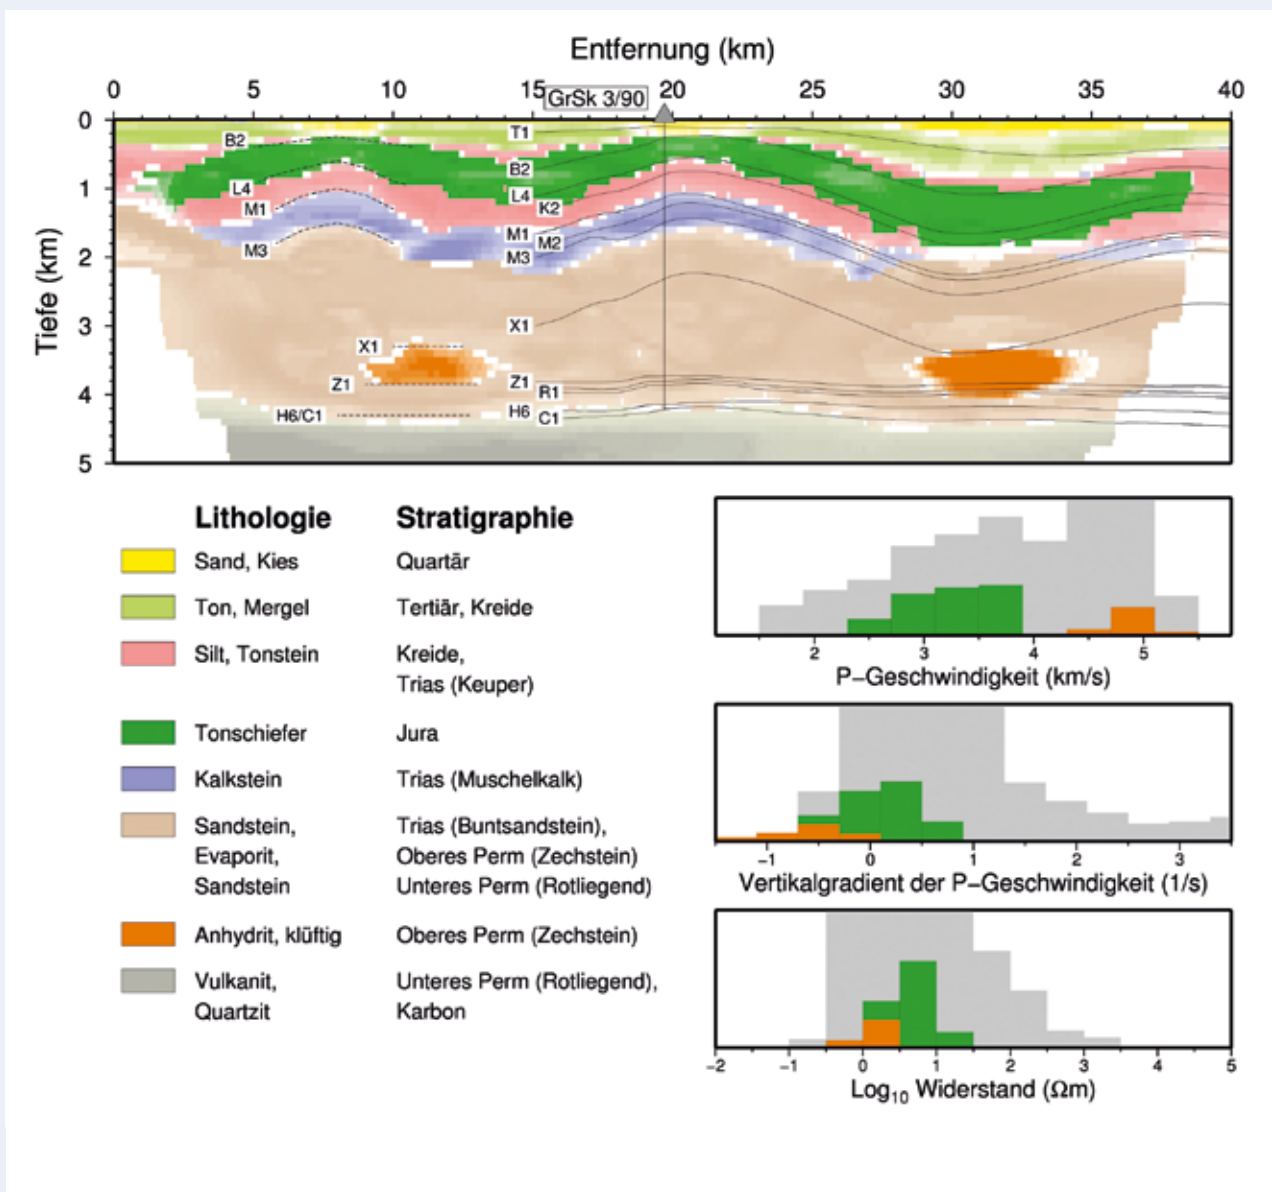


Abb. 3: Nordostdeutsches Becken: Ableitung eines lithologischen Modells durch gemeinsame Interpretation verschiedener geophysikalischer Daten mit Hilfe einer selbstorganisierenden Karte. Die Histogramme zeigen die physikalischen Eigenschaften ausgewählter Gesteinsklassen. (GrSk 3/90: Geothermiebohrung bei Groß Schönebeck)

Fig. 3: A lithological model was derived in the Northeast German basin from joint interpretation of multi-disciplinary geophysical data using self-organizing maps. Histograms show the physical properties of selected rock types.

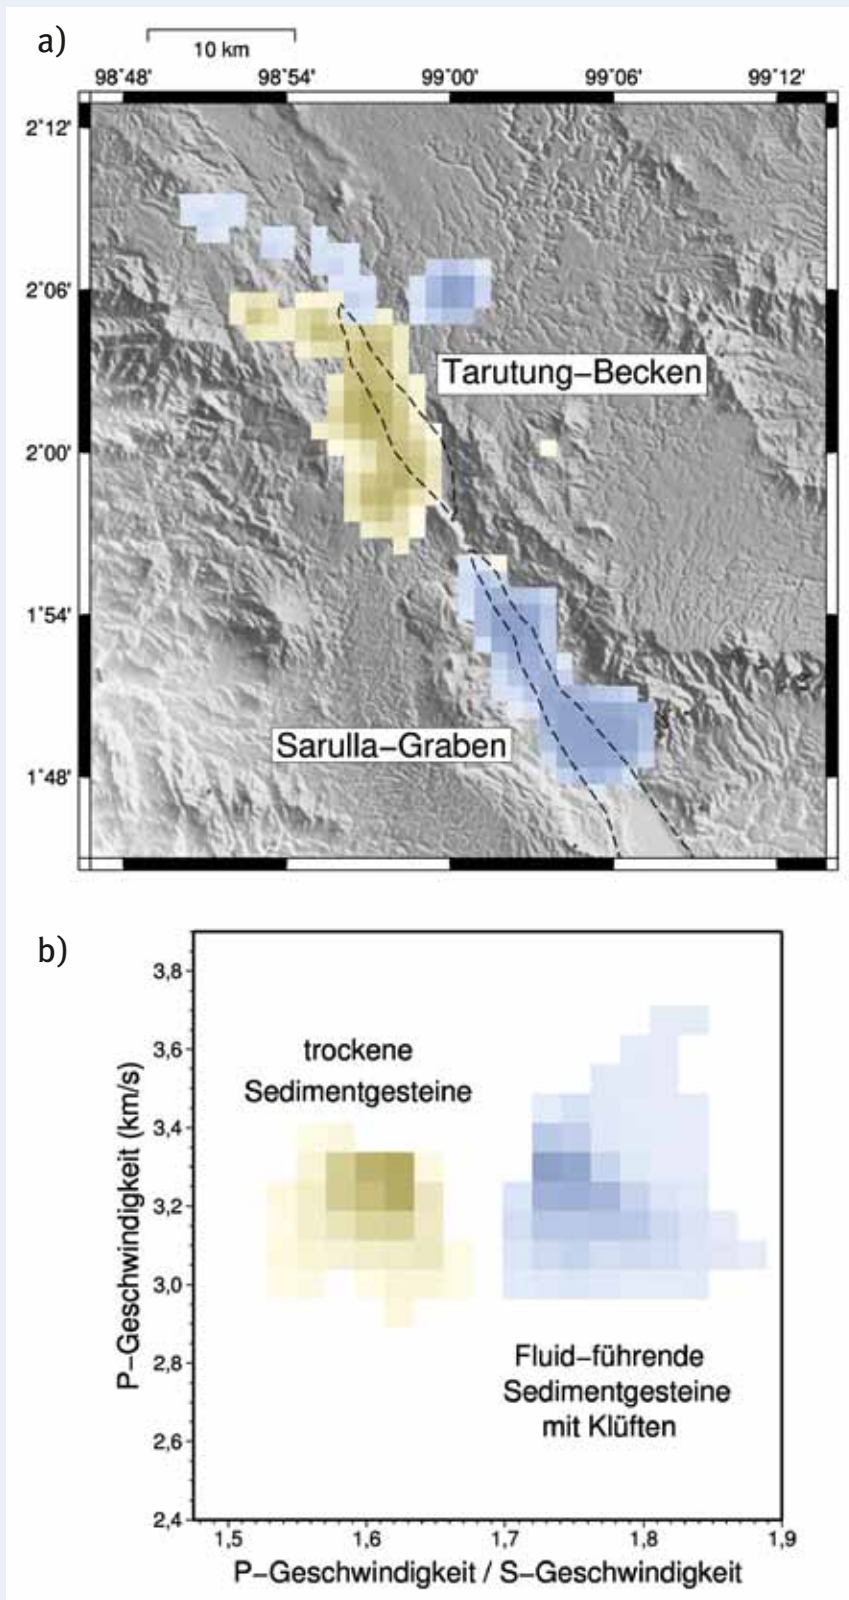


Abb. 4: Beispiel aus der geothermischen Erkundung auf Sumatra (Indonesien). a) Lokale Erdbeben werden für die Bestimmung seismischer Eigenschaften benutzt. Die gemeinsame Interpretation liefert ein lithologisches Modell des Untersuchungsgebiets. b) Die Unterscheidung markanter Gesteinstypen basiert auf der Kombination verschiedener Merkmale.

Fig. 4: Geothermal exploration in Sumatra (Indonesia). a) Local earthquakes were used to derive seismic properties. The joint interpretation provides a lithological model for the target region. b) The identification of distinct rock types is reached by combined analysis of different seismic properties.



pretiert werden können (Bauer et al., 2012). In Abb. 3 sieht man das daraus abgeleitete geologische Modell. Zu Grunde gelegt wurden elektrische Leitfähigkeiten aus der Magnetotellurik sowie P-Geschwindigkeiten und deren Vertikalgradienten aus der Seismik. Insgesamt wurden acht verschiedene Gesteinsklassen interpretiert. Die Verteilung im Untergrund zeigt Sedimentschichten, die seit dem Karbon im Norddeutschen Becken abgelagert worden sind. Im oberen Bereich sind deutliche Schichtaufwölbungen erkennbar, die durch Aufstiegsbewegungen der tieferen Salzschieben verursacht wurden. Die genaue Kenntnis der Salzstrukturen ist für die Modellierung des Temperaturfelds besonders wichtig, da dieses Gestein durch spezielle Wärmeleitfähigkeitseigenschaften gekennzeichnet ist.

Das GFZ ist weltweit aktiv an der Geothermie-Forschung beteiligt. Ein regionaler Schwerpunkt ist hierbei Indonesien, ein Land mit besonders großem Potenzial für geothermische Stromerzeugung. Auf Sumatra testeten wir, inwieweit man lokale Erdbeben für eine geothermische Vorerkundung nutzen kann (Muksin et al., 2013). Die durch viele kleine Beben angeregten elastischen Wellen liefern bei Anwendung von tomographischen Auswertverfahren detaillierte Abbilder des Untergrunds. Wir kombinierten verschiedene elastische Gesteinseigenschaften (P- und S-Geschwindigkeiten) für eine gemeinsame Interpretation mit Hilfe einer selbstorganisierenden Karte (Abb. 4). Dadurch konnten Regionen identifiziert werden, die für eine geothermische Nutzung besonders gut geeignet sind.

## Weitere Anwendungen und Ausblick

Wir verwenden den bei uns entwickelten Ansatz einer selbstorganisierenden Karte inzwischen routinemäßig bei unterschiedlichen Fragestellungen. Die Anwendungen sind Beiträge zu verschiedenen Forschungsschwerpunkten am GFZ: Gashydratforschung in Nordkanada (Bauer et al., 2008), geologisch-geophysikalische Interpretation im Umfeld eines magmatischen Komplexes in Namibia (Stankiewicz et al., 2010), Nachweis von fluid-gesättigten Regionen am Toten Meer (Weber et al., 2012) und lithologische Strukturuntersuchung an der San Andreas-Störung (Ryberg et al., 2012). In der Zukunft planen wir Anwendungen, bei denen komplette Signalformen analysiert und klassifiziert werden. Der Vorteil besteht in der Offenlegung von zusätzlichen Merkmalen durch das neuronale Netz, wodurch weitere Details bei der Interpretation sichtbar werden können.

## Literatur

- Bauer, K., Muñoz, G., Moeck, I. (2012): Pattern recognition and lithological interpretation of collocated seismic and magnetotelluric models using self-organizing maps. - *Geophysical Journal International*, 189, 2, 984-998, 10.1111/j.1365-246X.2012.05402.x.
- Bauer, K., Pratt, R. G., Haberland, C., Weber, M. (2008): Neural network analysis of crosshole tomographic images: The seismic signature of gas hydrate bearing sediments in the Mackenzie Delta (NW Canada). - *Geophysical Research Letters*, 35, L19306, 10.1029/2008GL035263.
- Kohonen, T. (2001): *Self-Organizing Maps*, (Springer series in information sciences ; 30), (Physics and astronomy online library), Berlin [u.a.], 501 p.
- Muksin, U., Bauer, K., Haberland, C. (2013): Seismic Vp and Vp/Vs structure of the geothermal area around Tarutung (North Sumatra, Indonesia) derived from local earthquake tomography. - *Journal of Volcanology and Geothermal Research*, 260, 27-42, 10.1016/j.jvolgeores.2013.04.012.
- Ryberg, T., Hole, J. A., Fuis, G. S., Rymer, M. J., Bleibinhaus, F., Stromeyer, D., Bauer, K. (2012): Tomographic Vp and Vs structure of the California Central Coast Ranges, in the vicinity of SAFOD, from controlled-source seismic data. - *Geophysical Journal International*, 190, 3, 1341-1360, 10.1111/j.1365-246X.2012.05585.x.
- Stankiewicz, J., Bauer, K., Ryberg, T. (2010): Lithology classification from seismic tomography: additional constraints from surface waves. - *Journal of African Earth Sciences*, 58, 547-552, 10.1016/j.jafrearsci.2010.05.012.
- Weber, M., Helwig, S. L., Bauer, K., Haberland, C., Koch, O., Ryberg, T., Maercklin, N., Ritter, O., Schulze, A. (2012): Near-surface properties of an active fault derived by joint interpretation of different geophysical methods - the Arava/ Araba Fault in the Middle East. - *Near Surface Geophysics*, 10, 5, 381-390, 10.3997/1873-0604.2012031.