

Timothy Berthold



# Künstliche Neuronale Netze zur räumlichen Interpolation von Korn- größenverteilungen mariner Sedimente

# **Künstliche Neuronale Netze zur räumlichen Interpolation von Korngrößenverteilungen mariner Sedimente**

Von der Fakultät für Bauingenieurwesen und Geodäsie  
der Gottfried Wilhelm Leibniz Universität Hannover  
zur Erlangung des Grades

**Doktor der Ingenieurwissenschaften  
Dr.-Ing.**

**genehmigte Dissertation von**  
M. Sc. Timothy Berthold

**Schriftenreihe des Instituts für Risiko und Zuverlässigkeit  
Band 2**

Referent: apl. Prof. Dr.-Ing. Volker Berkhahn  
Korreferent: Prof. Dr. rer. nat. Insa Neuweiler  
Tag der Promotion: 18.09.2018

Schriftenreihe des Instituts für Risiko und Zuverlässigkeit

Band 2

**Timothy Berthold**

**Künstliche Neuronale Netze zur  
räumlichen Interpolation von Korngrößen-  
verteilungen mariner Sedimente**

Shaker Verlag  
Aachen 2018

### **Bibliografische Information der Deutschen Nationalbibliothek**

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

Zugl.: Hannover, Leibniz Univ., Diss., 2018

Copyright Shaker Verlag 2018

Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder vollständigen Wiedergabe, der Speicherung in Datenverarbeitungsanlagen und der Übersetzung, vorbehalten.

Printed in Germany.

ISBN 978-3-8440-6291-5

ISSN 2566-8595

Shaker Verlag GmbH • Postfach 101818 • 52018 Aachen

Telefon: 02407 / 95 96 - 0 • Telefax: 02407 / 95 96 - 9

Internet: [www.shaker.de](http://www.shaker.de) • E-Mail: [info@shaker.de](mailto:info@shaker.de)

# Abstract

The knowledge of the constitution of the seabed forms the basis for solving many problems from the fields of habitat mapping, fishing management, environmental monitoring, as well as marine and coastal engineering. Within this context, there is a need for spatially high resolution information concerning the surface sediments on the seabed. Usually, the sediments are described by a grain-size distribution, which quantifies the particles regarding some grain-size fractions. The grain-size data can be obtained from given sediment samples quite accurately by different analysis procedures. However, the process of collecting the samples is very costly so that it can only be performed at some locations.

The given problem – estimating the sediment characteristics on the basis of a finite set of given values – can be interpreted as a spatial interpolation problem. Within this thesis, a model for the spatial interpolation of grain-size distributions is developed. The model is based on a multilayer perceptron, which is trained by the backpropagation algorithm. The model is developed in two steps: first, a model for the approximation of a single grain-size distribution is introduced. Since a grain-size distribution has to satisfy specific assumptions, the model has to consider those as well. This is established by choosing an adequate network topology and by deriving weight constraints. The model is extended in a further step, in order to capture the spatial variation of the grain-size distributions. In order to evaluate the constrained model, it is applied to real world data and is compared to an equivalent unconstrained version of the model. It turns out that the constrained model is only slightly less accurate compared to the unconstrained model. Concerning the training speed, no significant difference between the models have been observed. However, the main advantage of the constrained model is the guarantee that it produces valid results.

Furthermore, two approaches are presented for extending the model in order to take into account additional information in terms of side-scan sonar data. The first approach is based on incorporating the additional information in terms of a covariate. The second approach utilizes the additional information in order to adjust the decision boundaries of the model in that way that they match the boundaries, which are given by the side-scan sonar image.

Comparing the three models by applying them to real world measurements reveals that the extended models show a more plausible interpolation than the model which does not consider the side-scan sonar data.

Keywords: artificial neural networks, multilayer perceptron, network topology, surface sediments, grain-size distribution, spatial interpolation method, side-scan sonar data



# Kurzfassung

Die Kenntnis über die Beschaffenheit des Meeresbodens bildet die Grundlage zur Lösung vieler Fragestellungen aus den Bereichen der Biotopkartierung, des Fischereimanagements, der Meeresumweltüberwachung, des Meeressingenieurwesens und des Küsteningenieurwesens. In diesem Kontext gibt es großen Bedarf für räumlich hochaufgelöste Informationen bezüglich der Oberflächensedimente auf dem Meeresboden. Eine gängige Beschreibungsform für Sedimente ist die Korngrößenverteilung, die die Zusammensetzung des Sediments anhand der Größe der einzelnen Partikel quantifiziert. Mit der Analyse von Greiferproben lassen sich die Anteile der einzelnen Kornfraktionen relativ genau bestimmen. Diese Art der Beprobung ist allerdings aufwändig und kann nur punktuell durchgeführt werden.

Das zugrunde liegende Problem – aus punktuell bekannten Daten eine flächendeckende Beschreibung abzuleiten – kann als räumliches Interpolationsproblem aufgefasst werden. Im Rahmen dieser Arbeit wird ein Modell zur räumlichen Interpolation von Korngrößenverteilungen entwickelt. Dieses basiert auf einem Multilayer-Perceptron, das anhand des Backpropagation-Lernverfahrens trainiert wird. Die Entwicklung des Interpolationsmodells erfolgt in zwei wesentlichen Schritten: Zunächst wird ein Modell zur Approximation einer einzelnen Korngrößenverteilung entwickelt. Ein wesentlicher Aspekt dabei ist, dass die approximierten Korngrößenverteilung den Bedingungen einer Verteilungsfunktion genügen muss. Dies wird durch die Wahl einer geeigneten Netztopologie und die Herleitung von Restriktionen bzgl. der Verbindungsgewichte in dem Modell sichergestellt. In einem zweiten Schritt wird das Modell um den Aspekt der räumlichen Interpolation erweitert. Das entwickelte Modell wird an einem Beispieldatensatz erprobt und mit einem unrestringierten Modell verglichen. Dabei stellt sich heraus, dass die Approximationsgüte des restringierten Modells nur unwesentlich geringer ist, als die des unrestringierten Modells. Hinsichtlich der Trainingsgeschwindigkeit sind ebenfalls keine wesentlichen Unterschiede zwischen beiden Modellen festzustellen. Die wesentliche Verbesserung bei dem restringierten Modell besteht darin, dass es im Gegensatz zum unrestringierten Modell zulässige Ergebnisse liefert.

Darüberhinaus werden zwei Ansätze zur Erweiterung des Modells präsentiert, mit denen Seitensichtsonardaten als zusätzliche Information berücksichtigt werden können. Der erste Ansatz basiert auf der Berücksichtigung der Seitensichtsonardaten als zusätzliche erklärende Variable. Im Gegensatz dazu besteht die Grundidee des zweiten Ansatzes darin, die Grenzen der Regionen, in denen sich ähnliche Sedimenttypen befinden, an den Grenzen der Regionen im Seitensichtsonarbild auszurichten.



---

Bei einem Vergleich der Modelle an Daten aus einem Untersuchungsgebiet kann festgestellt werden, dass die interpolierten Korngrößenverteilungen zwischen den Beprobungsstandorten einen plausibleren Verlauf aufweisen, wenn die Seitensichtsonardaten berücksichtigt werden.

Schlagworte: Künstliche Neuronale Netze, Multilayer-Perceptron, Netztopologie, Oberflächensediment, Korngrößenverteilung, räumliches Interpolationsverfahren, Seitensichtsonardaten

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
<b>2</b>	<b>Sedimentologische Daten</b>	<b>5</b>
2.1	Oberflächensedimente	5
2.1.1	Grober Aufbau des Meeresbodens	5
2.1.2	Definition und Entstehung von lithogenen Sedimenten	6
2.1.3	Erfassung und Beschreibung von Oberflächensedimenten	7
2.2	Korngrößenverteilung	11
2.2.1	Korngrößenanalyse am Beispiel des Siebverfahrens	11
2.2.2	Darstellungsformen von Analyseergebnissen	13
2.3	Flächendeckende Informationsgewinnung mit Seitensichtsonaren	18
2.3.1	Akustische Grundlagen	20
2.3.2	Aufbau und Funktionsweise des Seitensichtsonars	26
<b>3</b>	<b>Künstliche Neuronale Netze</b>	<b>35</b>
3.1	Maschinelles Lernen	35
3.1.1	Definitionen	36
3.1.2	Überwachtes Lernen	38
3.2	Aufbau und Funktionsweise	41
3.2.1	Grundkomponenten eines KNN	42
3.2.2	Informationsverarbeitung in einem vorwärtsgerichteten Netz	45
3.3	Multilayer-Perceptron	46
3.3.1	Perzeptron	46
3.3.2	Topologie eines Multilayer-Perceptrons	51
3.3.3	Backpropagation	52
<b>4</b>	<b>KNN-basiertes Interpolationsmodell</b>	<b>53</b>
4.1	Problemdefinition und Lösungsansätze	54
4.1.1	Approximations- und Interpolationsaufgabe	54
4.1.2	Ansätze zur räumlichen Interpolation	55
4.1.3	Absolute vs. relative Position	59
4.2	Geometrische Interpretation der Netztopologie	63
4.2.1	Einleitendes Beispiel	63
4.2.2	Minimalkonfiguration	67
4.2.3	Mehrschichtige Netze	69

4.2.4	Darstellung unterschiedlicher Höhen . . . . .	72
4.3	Interpolation von Korngrößenverteilungen . . . . .	76
4.3.1	Diskussion unterschiedlicher Ansätze . . . . .	76
4.3.2	Approximation einer Korngrößenverteilung . . . . .	77
4.3.3	Räumliche Interpolation von Korngrößenverteilungen . . . . .	85
<b>5</b>	<b>Berücksichtigung von Seitensichtsonardaten</b>	<b>97</b>
5.1	Motivationsbeispiel . . . . .	98
5.2	Erweiterungen des Modells . . . . .	100
5.2.1	SSS-Daten als zusätzliche erklärende Variable . . . . .	100
5.2.2	Hybrider Ansatz . . . . .	104
5.3	Evaluierung . . . . .	107
5.3.1	Definition des Untersuchungsszenarios . . . . .	107
5.3.2	Gütekriterien . . . . .	110
5.3.3	Darstellung und Interpretation der Ergebnisse . . . . .	113
<b>6</b>	<b>Zusammenfassung und Ausblick</b>	<b>123</b>
	<b>Literatur</b>	<b>127</b>

# Abbildungsverzeichnis

2.1	Schematische Darstellung des Kreislaufes der Gesteine. . . . .	7
2.2	Schematischer Aufbau bei der Siebanalyse. . . . .	12
2.3	Darstellung einer Korngrößenverteilung. . . . .	15
2.4	In der Arbeit verwendete Darstellung der Korngrößenverteilung. . . . .	19
2.5	Schematische Darstellung zur Ausbreitung einer Schallwelle in einer Raumdimension. . . . .	21
2.6	Schematischer Aufbau eines Seitensichtsonars. . . . .	27
2.7	Beispiel für eine Seitensichtsonaraufnahme. . . . .	30
2.8	Zwei Spezialfälle bei der Schallreflexion. . . . .	32
3.1	Typische Aktivierungsfunktionen im Kontext von KNN. . . . .	43
3.2	Signalverarbeitung in einem Neuron . . . . .	43
3.3	KNN mit Ein- und Ausgabeneuronen. . . . .	44
3.4	Grundsätzlicher Aufbau eines Perzeptrons. . . . .	47
3.5	Ein Perzeptron, das die Funktion $x_1 \wedge x_2$ sowie $x_1 \vee x_2$ darstellt. . . . .	48
3.6	Darstellung der logischen Funktion XOR mit einem Perzeptron. . . . .	50
3.7	Schematische Darstellung eines Multilayer-Perzeptrons. . . . .	51
4.1	Beispiel für eine Interpolation unter Berücksichtigung der absoluten Positionen. . . . .	59
4.2	Exemplarische Netztopologie zur Berücksichtigung von relativen Positio- nen. . . . .	60
4.3	Exemplarischer Interpolationsverlauf bei der Berücksichtigung von rela- tiven Positionen. . . . .	60
4.4	Exemplarischer Interpolationsverlauf bei der Berücksichtigung des nächs- ten Nachbarn. . . . .	61
4.5	Exemplarischer Interpolationsverlauf bei der Berücksichtigung aller Nach- barn. . . . .	62
4.6	Netztopologie als logische Schlussfolgerung bei der Berücksichtigung aller Nachbarn. . . . .	63
4.7	Lage der Trainingsdaten für die Bathymetrie-Approximation im Bereich des Jade-Weser-Ästuars. . . . .	64
4.8	Schematischer Aufbau des Modells zur Approximation der Bathymetrie. . . . .	64
4.9	Approximation einer Bathymetrie ( $z = f(x, y)$ ) mit unterschiedlichen Netztopologien. . . . .	65

4.10	Fehlervläufe der Trainingsprozesse für die Bathymetrie-Approximationen.	66
4.11	Resultierende Funktion für die 2-1-Topologie mit $w_b = w_y = 0$ und $w_x = 1$ .	68
4.12	Geometrische Interpretation des Ausgabeneurons als Anstieg bzw. Geländekante beim Minimalbeispiel.	69
4.13	Einfluss der Gewichte auf die Steilheit und Lage des Anstiegs.	70
4.14	Schematische Darstellung eines dreischichtigen MLP zur Interpolation einer Bathymetrie.	70
4.15	Beispiel: Netztopologie zur Abbildung einer Rinne.	71
4.16	Beispiel: Netztopologie zur Abbildung einer Rinne mit Knick.	71
4.17	Beispiel eines KNN mit 3 2S-Neuronen, das den Definitionsbereich der Gesamtfunktion $z = f(x, y)$ in Regionen zerlegt.	72
4.18	Realisierung eines Sprunges mit zwei beliebigen Höhenniveaus.	73
4.19	Rinne mit zwei unterschiedlich hohen Ufern	74
4.20	Eingaberaum für die Oder-Verknüpfung in der zweiten Stufe.	75
4.21	1-n-1-c-Modell zur Approximation einer Korngrößenverteilung.	79
4.22	Approximation der Korngrößenverteilung mit unterschiedlichen Netz-Topologien.	80
4.23	Approximation der Korngrößenverteilungen unter Berücksichtigung der Nebenbedingungen.	84
4.24	Darstellung der kumulativen relativen Häufigkeiten als empirische Verteilungsfunktion.	84
4.25	Datenübersicht für das Beispielszenario zur Approximation räumlich verteilter Korngrößenverteilungen.	87
4.26	Änderung der „Landschaft“ $f^c$ in Abhängigkeit der Korngröße $\phi$ .	88
4.27	3-n-1-c-Modell als Minimalkonfiguration zur Approximation räumlich verteilter Korngrößenverteilungen.	88
4.28	Repräsentative Approximationsergebnisse des 3-n-1-c-Modells mit einer 3-10-1-c-Topologie.	89
4.29	Vergleich der Approximationsgüte des 3-15-1-c- und des 3-15-1-u-Modells.	91
4.30	Interpretation der restringierten Hyperebene im Fall von 2 und 3 verdeckten Neuronen.	91
4.31	Netztopologie des entwickelten Modells zur Interpolation räumlich verteilter Korngrößenverteilungen.	92
4.32	Vergleich der minimalen mittleren Trainingsfehler für das 3-m-n-1-c- und 3-m-n-1-u-Modell.	93
4.33	Vergleich des restringierten und unrestringierten Modells mit dem geringsten Trainingsfehler.	94
4.34	Approximationsergebnisse des restringierten und unrestringierten Modells.	95
5.1	Untersuchungsgebiet Minsener Oog mit gemessenen Rückstreuintensitäten und Standorten von Greiferproben.	99
5.2	Ausgewählte Korngrößenverteilungen im nordwestlichen Teil des Untersuchungsgebietes.	100

---

5.3	Zwei Ausschnitte der Rückstreuintensitäten mit je $40 \times 40$ Pixeln. . . . .	101
5.4	Netzstruktur des 4-m-n-1-c-Modells. . . . .	102
5.5	Grundidee beim 4-m-n-1-c-Modell: Erweiterung des Eingaberaumes um die Seitensichtsonardaten. . . . .	104
5.6	Grundidee beim 3-m-n-2-c-Modell: Ausrichtung der Regionengrenzen anhand der Seitensichtsonardaten. . . . .	105
5.7	Netzstruktur des hybriden 3-m-n-2-c-Modells. . . . .	106
5.8	Verwendete Daten im Untersuchungsgebiet Minsener Oog. . . . .	109
5.9	Rückstreuintensitäten gefiltert mit einem Medianfilter ( $r = 153$ m). . . . .	110
5.10	Zwei Korngrößenverteilungen aus dem Untersuchungsgebiet. . . . .	111
5.11	Obere und untere Grenze für den möglichen Verlauf der wahren Verteilungsfunktion. . . . .	112
5.12	Visualisierung der Fehlermetrik $E_{int}$ als Fläche zwischen $\tilde{f}$ und dem möglichen Verlauf der Verteilungsfunktion. . . . .	112
5.13	Gemittelte Approximationsgüten bei einer Modellwahl bzgl. des minimalen Testfehlers. . . . .	115
5.14	Gemittelte Approximationsgüten bei einer Modellwahl bzgl. des minimalen Trainingsfehlers. . . . .	116
5.15	Verlauf der Profillinie. . . . .	117
5.16	Approximierter $\phi_{50}$ der drei Modelle entlang der Profillinie (Modellwahl: minimaler Testfehler). . . . .	118
5.17	Approximierter $\phi_{50}$ der drei Modelle entlang der Profillinie (Modellwahl: minimaler Trainingsfehler). . . . .	119



# Tabellenverzeichnis

2.1	Korngrößenskalen und Bezeichnungen von Kornfraktionen im Vergleich.	10
2.2	Darstellung der Korngrößenanalyseergebnisse in Form von einer Tabelle.	14
4.1	Anzahl von Regionen für verschiedene Fälle und Dimensionen. . . . .	73