

Klassifikation mineralischer Baurohstoffe mittels Bildverarbeitung und maschinellem Lernen

Katharina Anding¹, Daniel Garten², Gerhard Linß¹, Gino Pieper¹,
Elske Linß³

¹ Technische Universität Ilmenau,
Fakultät für Maschinenbau,
Fachgebiet Qualitätssicherung
Gustav-Kirchhoff-Platz 2, D-98693 Ilmenau
katharina.anding@tu-ilmenau.de
URL: <http://www.tu-ilmenau.de/qualitaetssicherung/>

² GFE - Gesellschaft für Fertigungstechnik und
Entwicklung Schmalkalden e.V.
Näherstiller Straße 10, D-98574 Schmalkalden
d.garten@gfe-net.de
URL: <http://www.gfe-net.de>

³ Bauhaus-Universität Weimar
Fakultät Bauingenieurwesen
Professur Aufbereitung von Baustoffen und Wiederverwertung
Coudraystraße 7, D-99423 Weimar
URL: <http://www.uni-weimar.de/Bauing/aufber/>

Zusammenfassung Im vorliegenden Beitrag wird ein Ansatz zur Automatisierung der bisher manuell durchgeführten qualitativen Beurteilung von Gesteinsgemischen vorgestellt. Zur Umsetzung der Automatisierung werden aktuelle Algorithmen aus den Bereichen der Bildverarbeitung und des Machine Learnings eingesetzt. Hierfür wurden Bilddatensätze mit einem Versuchsaufbau erzeugt und Merkmals- sowie Klassifikationsalgorithmen zur Eignung für die automatisierte Objektklassifikation verschiedener Gesteinsarten näher untersucht.

1 Einführung

Mineralische Baurohstoffe bestehen aus einer Vielzahl an Gemischen verschiedener Gesteinsarten und stellen die Grundstoffe der Bauindustrie dar. Zur qualitativen Beurteilung der Gesteinsgemische sind petrographische Untersuchungen notwendig. Bei größeren

Körnungen (Bsp.: Kiese bzw. Splitte) wird die herkömmliche Klassifikation manuell mit bloßem Auge und einfachen Hilfsmitteln wie Lupe und Auflichtmikroskop durchgeführt. Von besonderer Bedeutung für die Betonqualität und Langzeitstabilität von Bauwerken und Straßen ist die Erkennung von kritischen Zuschlagsstoffen, welche zu einer Betonzerstörung durch Treibreaktionen aufgrund chemisch reaktiver Gesteine im mineralischen Gemisch, wie Flinte, Opale, präkambrische Grauwacke und z.T. gesplittete Kiese, führen können.

Die Ergebnisse der durch einen hohen manuellen Aufwand charakterisierten Untersuchungen werden durch den Kenntnisstand und die Erfahrungen des Bearbeiters beeinflusst.

Ziel der Untersuchung ist die automatisierte Bestimmung verschiedener Gesteinsarten unter Verwendung maschineller Lernverfahren.

Die Problematik dieser Erkennungsaufgabe besteht in der großen Intraklassenvariabilität bei gleichzeitig äußerst niedriger Interklassenvariabilität. Dies äußert sich auch im sehr ähnlichen äußeren Erscheinungsbild verschiedener Gesteine. So erfordert die manuelle Klassifikation verschiedener Gesteinsarten ein hohes Maß an Expertenwissen und Erfahrungen und wird somit zumeist von Geologen bzw. Mineralogen durchgeführt.

2 Versuchsaufbau zur Bildaufnahme

Grundsätzlich stellt eine Erkennungsaufgabe von Objekten diverse Anforderungen an die Bildaufnahme. Wesentliche Faktoren sind zum einen eine gute Bildqualität in Form von problemadaptierter und homogener Ausleuchtung der Bildszena, guter Tiefenschärfe und ausreichender Auflösung (Gutbeispiel siehe Abbildung 1 rechts; Schlechtbeispiel siehe Abbildung 1 links) sowie zum anderen eine vereinzelte Aufnahme der Probenbestandteile zur Vermeidung von Überlappungen, Verdeckungen und Schattenbildung.

Bei jeder Erkennungsaufgabe gilt der Grundsatz, dass der Klassifikator auf den Merkmalsvektoren basiert und damit letztlich auf der Bildqualität der Objekte und dementsprechend nur so gut sein kann, wie es der Qualität der Ausgangsbilder entspricht.

Die Bilddatensätze der Untersuchung konnten unter Verwendung eines Versuchsaufbaus bestehend aus einer 3-fach-Farbzeilenkamera mit Teilerprisma sowie einer geeigneten Auflichtbeleuchtung generiert werden (siehe Abbildung 2). Als Objektiv kam ein achromatisch korrigiertes Makroobjektiv zum Einsatz. Als Beleuchtungseinrichtung diente eine LED-Zeilenleuchte mit einer hohen Homogenität entlang der Zeile und einem CRI-Wert der verwendeten LEDs von 95 [1]. Somit ist eine gute Farbwiedergabe der Objekte gegeben.




Abbildung 1: Bildqualität am Beispiel zweier Sandsteinobjekte




Abbildung 2: Versuchsaufbau zur Bildaufnahme von Gesteinsobjekten

3 Objektklassen der Erkennungsaufgabe und verwendeter Bilddatensatz

Der für die Untersuchungen verwendete Bilddatensatz besteht aus den acht Gesteinsklassen Flint, Grauwacke, einheimischer Kalkstein, nordischer Kristallin, Quarz, Quarzit, Rhyolith und Sandstein. Der Datensatz weist eine Gesamtanzahl von rund 8920 Objekten bei einer durchschnittlichen Objektanzahl pro Klasse von rund 1100 auf. Der Datensatz wurde mittels zufälliger Objektauswahl innerhalb jeder Klasse in drei Partitionen aufgeteilt. Alle Untersuchungen fanden mit einer 3-fach stratifizierten Kreuzvalidierung unter wechselnder Verwendung von jeweils 2 Partitionen zum Lernen und einer Partition zum Testen statt, um eine bessere Vorhersagegüte der Klassifikatoren treffen zu können.

4 Bildsegmentierung und Merkmalsextraktion

Bevor die Merkmalsextraktion auf den Bilddaten stattfinden kann, erfolgt die Segmentierung der Objekte vom Hintergrund. Ein homogener Hintergrund und die spezifische Charakteristik

der Histogramme der Analyseobjekte im Blaukanal erlauben eine einfache Schwellwertoperation zur Objektsegmentierung.

Aus den Objektregionen sind zur Klassentrennung geeignete Merkmale zu berechnen (Merkmalsextraktion), um den relevanten Informationsgehalt der Bilder im späteren Merkmalsvektor abbilden zu können.

So wurden unter Verwendung der Bildverarbeitungs- und Erkennungssoftware-Bibliotheken Halcon [2] sowie WEKA [3] verschiedene Farb-, Form- und Texturmerkmale hinsichtlich ihrer Diskriminanzfähigkeit in Kombination mit Support-Vektor-Maschinen (SVM), Entscheidungsbaumverfahren sowie statistischen und abstandsmessenden Klassifikationsverfahren näher untersucht. Ein hochdimensionaler Merkmalsvektor aus ca. 200 Bildmerkmalswerten bildet die Basis der Untersuchungen zur Wirkung von Merkmalsselektionsverfahren und Klassifikatorwahl.

5 Merkmalsselektion

Das Chi-Square-Filterverfahren untersucht die Verteilungseigenschaften einer statistischen Grundgesamtheit hinsichtlich einer bestimmten Verteilungseigenschaft [4]. Setino et al. [5] erkannten, dass die Diskretisierung ein geeignetes Werkzeug ist, um die Merkmalsselektion numerischer Merkmale durchzuführen. Beim Chi-Quadrat-Test wird die Diskretisierung mit Hilfe der Chi-Quadrat-Statistik durchgeführt. Die Chi-Quadrat-Größe ist dabei die zu bestimmende Testgröße, mit deren Hilfe ein Signifikanztest durchgeführt wird.

Mit diesem Merkmalsselektionsverfahren und unter Verwendung einer Support-Vektor-Maschine lassen sich aus den gegebenen 200 Merkmalswerten rund 70 relevante Merkmale detektieren, welche zur maximalen Gesamterkennungsrate für das gegebene Problem führen (siehe Abbildung 3). Unter schrittweiser Hinzunahme weiterer relevanter Merkmale kommt es zunächst zu einem signifikanten Erkennungsratenanstieg (bis ca. 30 Merkmale), im Anschluss zu einem geringeren Anstieg bis zu einem Maximum bei ca. 70 verwendeten Merkmalen und danach zu einem stagnierenden Verhalten bzw. z.T. zu einer leicht rückläufigen Erkennungsgüte (leicht sinkende Erkennungsraten). Dieses Verhalten deckt sich mit der Theorie und basiert auf dem sogenannten Peaking-Phänomen. In der Erkennungspraxis trifft man häufig das Problem an, dass nur eine geringe Anzahl von Datensatzbeispielen zur Verfügung steht, man für diese Objekte aber tausende Merkmale berechnen könnte. Die Verwendung einer zu großen Anzahl an Merkmalen führt dann zu einer schlechteren Erkennungsgüte als die Verwendung einer kleinen Anzahl an signifikanten Merkmalen.

Zu den 70 als relevant detektierten Merkmalswerten zählen hauptsächlich Textur- und Farbmerkmale, wie z.B. spezifische Histogrammwerte aller drei Kanäle (im Farbwertkanal H, Sättigungskanal S und Intensitätskanal I), aus der Cooccurence-Matrix berechnete Merkmale sowie Grauwertentropie und Grauwertanisotropiekoeffizient. Formmerkmale weisen zur Differenzierung nahezu keinen relevanten Informationsgehalt auf mit Ausnahme von z.B.: Rundheit und Konvexität. Im Ergebnis zeichnen sich Textur- und Farbmerkmale zur Lösung der Erkennungsaufgabe als am aussichtsreichsten ab.




Abbildung 3: Einfluss eines Merkmalsselektionsverfahrens auf die Klassifikationsperformance der LibSVM für den gegebenen Gesteinsdatensatz

6 Wahl eines geeigneten Klassifikationsverfahrens

Auf dem gegebenen Bilddatensatz wurden unter Verwendung der oben beschriebenen Kreuzvalidierung Untersuchungen zur Eignung verschiedener Klassifikationsverfahren durchgeführt. Dazu wurden sowohl SVMs der Softwarebibliothek Halcon [2] als auch Entscheidungsbaumverfahren J48 und Random-Forest, k-Nächster-Nachbar (kNN), Naive-Bayes und LibSVM der Data-Mining-Software Weka auf dem Datensatz unter Nutzung von 200-dimensionalen Merkmalsvektoren verwendet. Die Ergebnisse der verschiedenen Klassifikatoren liegen z.T. sehr weit auseinander (siehe Abbildung 4). So erreichen statistische Verfahren wie das Naive-Bayes-Verfahren, abstandsmessende Verfahren wie das Nächste-Nachbar-Verfahren (kNN) und einfache Entscheidungsbaumverfahren (J48) lediglich niedrige Gesamterkennungsraten im Bereich von 35 bis 58 %. Die beiden SVMs und das Random-Forest-Verfahren erreichen aufgrund ihrer Komplexität hingegen deutliche bessere Gesamterkennungsraten oberhalb der 70 %.

Um die Problematik der z.T. sehr stark ausgeprägten Ähnlichkeit zwischen bestimmten Objektklassen näher zu beschreiben, ist in Tabelle 1 eine Konfusionsmatrix (KFM) dargestellt. Auf der Hauptdiagonalen sind die korrekten Klassifikationen in Form der Einzelerkennungsraten angegeben. Oberhalb und unterhalb der Diagonalen sind die Fehlklassifikationen in Form der Verwechslungsquote zwischen zwei Klassen angegeben, welche besagt, wie hoch der prozentuale Anteil an der realen Klasse ist, die fälschlicherweise in eine andere Klasse fehlzugeordnet wurde. Anhand der Farbcharakteristik wird eine bessere Visualisierbarkeit des Anteils an Fehlzuordnungen zwischen zwei Klassen ermöglicht. Zu besonders hohen Verwechslungsraten kommt es zwischen den Klassenpaarungen:

- Flint (A) und Kristallin_nordisch (D),
- Flint (A) und Quarz (E),
- Grauwacke (B) und Quarzit (F),
- Kristallin_nordisch (D) und Quarz (E),
- Kristallin_nordisch (D) und Rhyolith (G),




Abbildung 4: Klassifikatorenvergleich unter Verwendung des Bilddatensatzes

In Abbildung 5 sind ausgewählte Beispielbilder der ähnlichen Klassen enthalten. Unter den gegebenen Bildaufnahmebedingungen dürfte eine Unterscheidung dieser Objekte selbst einem Geologen schwer fallen aufgrund der sehr großen phänotypischen Ähnlichkeiten einiger Objekte. So verwundert es nicht, dass eine saubere Trennung aller Objekte im Datensatz auch für ein maschinelles Lernverfahren eine schwierige Aufgabe darstellt. Somit kommt es beim gegebenen Erkennungsproblem zu geringeren Erkennungsraten aufgrund von hohen Intraklassenvariabilitäten bei gleichzeitig geringen Interklassenvariabilitäten. Aus diesem Grund ist zukünftig zur Erkennungsratensteigerung unter anderem eine Erhöhung der Bildauflösung vorgesehen.

Tabelle 1: Konfusionsmatrix des geeignetsten Klassifikators – Problematik Objektähnlichkeit

WEKA_LibSVM			radial basis function			DS-PartI+III: Lernen; DS-Part II: Testen							
			klassifiziert als								Einzel-ER [%]	Gesamt-ER [%]	
			(A)	(B)	(C)	(D)	(E)	(F)	(G)	(H)			
reale Objektklasse	Flint	(A)	66,8%	0,0%	2,7%	12,8%	12,4%	0,0%	4,9%	0,4%	66,8	76,0	
	Grauwacke	(B)	0,3%	85,5%	0,3%	0,9%	0,3%	10,6%	2,1%	0,0%	85,5		
	Kalkstein_einheimisch	(C)	0,6%	0,0%	90,8%	5,2%	0,3%	1,4%	1,1%	0,6%	90,8		
	Kristallin_nordisch	(D)	7,0%	0,6%	3,9%	55,8%	11,2%	3,3%	15,5%	2,7%	55,8		
	Quarz	(E)	4,2%	0,0%	1,2%	7,8%	84,6%	1,5%	0,5%	0,2%	84,6		
	Quarzit	(F)	0,3%	19,0%	1,7%	4,3%	3,5%	59,9%	6,6%	4,6%	59,9		
	Rhyolith	(G)	1,1%	2,4%	2,4%	8,5%	0,8%	4,9%	77,0%	2,8%	77,0		
	Sandstein	(H)	0,4%	2,6%	2,2%	4,1%	0,0%	5,6%	7,8%	77,2%	77,2		
Verwechslungsquote:			10 - 20%			Einzel-ER							
			5 - 10%										
			1 - 5%										
			<1%										




Abbildung 5: Beispielbilder sehr ähnlicher Objekte als Ursache für Fehlklassifikationen

7 Zusammenfassung der Ergebnisse

Im Rahmen eines durch das Bundesministerium für Wirtschaft und Technologie geförderten AIF-Projektes konnten Untersuchungen zur Eignung von Bilddatensätzen, Merkmals- sowie Klassifikationsalgorithmen zur automatisierten Objektklassifikation verschiedener Gesteinsarten durchgeführt werden. Die Untersuchungen zeigten, dass es sich bei der Differenzierung diverser Gesteinsarten um ein Erkennungsproblem hoher Komplexität handelt (hohe Intraklassenvariabilität gepaart mit geringer Interklassenvariabilität). Trotz der Komplexität konnten bereits gute Gesamterkennungsraten von 76 % unter Verwendung einer parameterangepassten SVM erreicht werden. Unter Verwendung eines Merkmalsselektionsverfahrens zur Dimensionsreduktion des Merkmalsvektors auf informationsrelevante Merkmalswerte konnten die Erkennungsraten noch gesteigert werden.

Der Versuchsaufbau unter Verwendung einer 3-fach-Farbzeilenkamera mit Teilerprisma sowie einer geeigneten Auflichtbeleuchtung ermöglicht bereits gute Bildaufnahmen. Für zukünftige Untersuchungen ist jedoch eine höhere Bildauflösung vorgesehen, um bestimmte Objekt-spezifisch gegebene Unterschiede besser erfassen zu können.

8 Unterstützende Mitarbeit

Grundlage des klassensortierten Bilddatensatzes bildete ein aufwendiger, von Hand sortierter Gesteinsprobenpool, welcher durch die Experten der Prüfgesellschaft für Straßen- und Tiefbau mbH & Co. KG in Bernburg zusammengestellt wurde. Unser besonderer Dank gilt daher Frau Kallies und Ihren Kollegen der PST Bernburg für die Bereitstellung dieses umfangreichen Probenmaterials. Für die Bildaufnahme der Gesteinsobjekte und die Bereitstellung des Bilddatensatzes gilt unser Dank dem Kollegen Martin Dambon sowie dem Studenten Sebastian Dal-Canton.

Literatur

- [1] Steinbeis-Transferzentrum Qualitätssicherung und Bildverarbeitung, Ilmenau, <http://www.stz-ilmenau.de/downloads/files/Linelight.pdf>, 2010.
- [2] Halcon, Reference Manual - Halcon 8.0.3, MVTec Software GmbH, www.mvtec.com, 2009.
- [3] Hall, M., Eibe, F., Holmes, G., Pfahringer, B., Reutemann, P. and Witten, I. H.: The WEKA Data Mining Software: An Update. SIGKDD Explorations, Vol. 11(1), 2009.
- [4] Guyon, I. and Elisseeff, A.: Feature extraction: foundations and applications, Springer Verlag Berlin, 2006.
- [5] Setino, R. and Liu, H.: Chi²: Feature selection and discretization of numeric attributes. In: Proceedings of the Seventh IEEE International Conference on Tools with Artificial Intelligence, 1995.