

Intelligente Sortierung von Mauerwerkbruch mit Hilfe von maschinellen Lernmodellen

Walz, J.¹; Linß, E.¹; Hunhold, P.¹; Mehta, M.¹; Moayed, E.¹; Petereit, S.²; Giese, R.²

Korrespondenz

Jurij Walz
MFPA Weimar
Coudraystr. 4
99423 Weimar
Email: jurij.walz@mfpa.de

¹ Materialforschungs- und -prüfanstalt an der Bauhaus-Universität Weimar, Weimar, Deutschland
² Institut für Ziegelforschung Essen e.V., Essen, Deutschland

Abstract

Gegenstand der vorliegenden Untersuchungen ist die optische Unterscheidbarkeit verschiedener Ziegelarten mit Partikelgrößen < 8 mm, welche im Mauerwerkbruch enthalten sein können, mithilfe von Computer Vision und künstlicher Intelligenz. Dafür wurde ein Bilddatensatz von verschiedenen neuen und recycelten Ziegelarten mit Hilfe eines RGB-Kamerabasierten Bilderfassungssystems erstellt. Die Bilddaten wurden nach entsprechender Vorverarbeitung hinsichtlich signifikanter Merkmale ausgewertet, um anschließend mit verschiedenen Klassifikationsmodellen des maschinellen Lernens eine optimale Erkennungsroutine ermitteln zu können. Die erzielten Erkennungsraten zeigen, dass sowohl die klassischen Klassifikatoren als auch ein Faltungsneuronales Netzwerk hervorragende Ergebnisse erzielen können.

Keywords

Sortierung, Mauerwerkbruch, Ziegelbruch, Ziegelarten, Bauschutt, Sensorik, machine vision, machine learning

1 Problem- und Zielstellung

Im Jahr 2020 fielen in Deutschland 60 Millionen Tonnen Bauschutt aus dem Hochbau an [1]. Als langfristige Ziele ergeben sich dadurch die Reduktion des Abfallaufkommens, die Nutzung von Abfällen als alternative Ressource und die Erhöhung der Recyclingquoten. Die Substitution von Primär- durch Sekundärmaterialien schont die natürlichen Ressourcen.

Derzeit werden in Deutschland jährlich 20-23 Millionen Tonnen Baustoffe für Mauerwerk (Mörtel und Putz, Leichtbeton, Porenbeton, Kalksandstein und Ziegel) hergestellt. Die Menge der produzierten Ziegel, einschließlich Dachziegel, beträgt ca. 10-15 Millionen Tonnen [2]. Aktuelle Leitstrategien und ehrgeizige umweltpolitische Ziele fordern von den Herstellern mineralischer Bauprodukte zunehmend die Einführung von Stoffkreisläufen [3].

Mauerwerkbruch kann als sekundärer Bestandteil bei der Herstellung neuer Baustoffe verwendet werden. Ziegelbruch wird derzeit im Sportplatzbau, im Vegetationsbau, im Straßenbau als anteiliger Bestandteil von Frostschutz- und Schottertragschichten und im Hochbau als rezyklierte Gesteinskörnung für die Betonherstellung eingesetzt [2]. Sortenreine Ziegelrezyklate, die aus Mauerwerkbruch gewonnen werden, können nach einer Aufbereitung als Rezyklat wieder der Ziegelproduktion zugeführt werden. Voraussetzung dafür ist allerdings, dass keine Mörtelanhaftungen oder andere Verunreinigungen vorhanden sein dürfen [4], [5], [6].

Basierend auf den Untersuchungen in den Projekten [5], [7] wurde ein Merkblatt zum Einsatz von Recyclingziegeln in der Ziegelindustrie erstellt. Es empfiehlt reines hartgebranntes Material, reines/hartes Material, niedriggebranntes Material und Mauerwerksabfälle als geeignetes Einsatzmaterial für die Herstellung von Dach-, Vormauer- und Hochlochziegeln. Je nach Ziegelsorte können bis zu 25 M.- % wiederverwendet werden [7], [6].

Nach einer Mahlung können Mauerwerksabfälle auch als Zementkompositmaterial in der Zementindustrie verwendet werden [8]. Dabei ist es notwendig, niedrig- und hochgebrannte Ziegelsorten, Mörtel, Beton und andere Bestandteile voneinander unterscheiden und trennen zu können.

Optische Einzelkornsorrierungsverfahren bieten die Chance, auch sehr ähnliche Materialien deutlich zu unterscheiden [9], [10], [11]. Optische Sortierverfahren werden bei der Sortierung von Bau- und Abbruchabfällen noch nicht in großem Umfang eingesetzt. Die optischen Sortierverfahren basieren im Wesentlichen auf innovativen Detektionsroutinen, die in entsprechende Software integriert werden können.

Ziel der Untersuchungen ist die Entwicklung einer Erkennungsroutine zur Unterscheidung verschiedener Ziegelarten für die Erzeugung sortenreinen Ziegel- und Mauerwerkbruchs. Für die Erkennungsaufgabe werden Merkmale aus dem hochauflösenden Bild und Spektrum sowie Auswertelgorithmen aus dem maschinellen Lernen / Deep

Learning verwendet. Sehr wichtig ist das Aussortieren von Verunreinigungen, wie Mörtel, Gips, Beton usw.

In diesem Beitrag wird die Erkennung von Ziegelarten anhand von RGB-Bildern untersucht und innovative Methoden des maschinellen Lernens beschrieben. Damit wird die Grundlage für die Entwicklung von optischen Sortiervverfahren geschaffen. In den Untersuchungen sollen Erkennungsroutinen und Algorithmen zur korrekten Unterscheidung und Trennung verschiedener Ziegelarten anhand von Bildmerkmalen getestet werden. Es werden die Grundlagen geschaffen, um in Zukunft effektivere Sortiervverfahren beim Recycling von Ziegelrestmassen zu entwickeln.


2 Materialien und Methoden

2.1 Datensatz

Für die Untersuchungen wurde der Bilddatensatz anhand von Ziegeln und Mauerwerk in zwei Versionen erstellt. Die Datensätze weisen die gleiche Anzahl an Bildern und die gleiche Aufteilung nach Klassen auf, der einzige Unterschied besteht in der Korngröße der Partikel. Für den einen Datensatz liegt diese bei 4 – 8 mm und für den zweiten Datensatz bei 2 - 4 mm. Die Kategorisierung der Ziegelarten findet auf Grundlage physikalischer Parameter wie Dichte und Wasseraufnahme statt: I (sortenreines dicht gebranntes Material), II (hochgebranntes, hartes Material - Dachziegel und Vormauerziegel), III (niedrig gebranntes, weiches Material - Hochlochziegel). Kategorie V enthält Störstoffe und sonstige Materialien wie Beton, Mörtel, Gips und andere Baumaterialien.

Tabelle 1 gibt einen Überblick über den verwendeten Bilddatensatz. Insgesamt enthält ein Datensatz 11.500 RGB-Bildern von einzelnen Partikeln. Die Kategorie IV (Mauerwerkbruch aus Recyclinganlagen) wurde an dieser Stelle ausgeschlossen, da es sich hierbei um Materialgemische handelt und daher das Apriori-Wissen für das Anlernen der Klassifikatoren über die Kategorienzugehörigkeit fehlt.

Tabelle 1 Zusammensetzung des Datensatzes (I dicht gebranntes Material, II Dachziegel und Vormauerziegel, III niedrig gebrannte Ziegel und V sonstiges Material)

Kategorie	I	II	III	V
Anzahl	3.000	3.000	3.000	2.500
Beispielbilder				

Wie in Tabelle 1 veranschaulicht, stellt die große Heterogenität der Partikel innerhalb einer Klasse (Ziegelart) die Herausforderung dieser Studie dar. Die Ergebnisse aus früheren Untersuchungen haben gezeigt, dass mit Hilfe von Bildverarbeitungstechniken [12] und [13] mittels

neuer und moderner Klassifikationsalgorithmen (Deep Learning) hohe Genauigkeiten in der Unterscheidbarkeit der Materialien erreicht werden können.

2.2 Experimenteller Aufbau und Ablauf

Von allen Proben wurden Bilder mit einem statischen Bildaufnahmesystem namens "QualiLeo" aufgenommen. Mit diesem System ist es möglich, die zu untersuchenden Objekte auf verschiedene Arten zu beleuchten, z. B. mit Auflicht, Ringlicht und Durchlicht. Das Durchlicht wird verwendet, um Objekte vom Hintergrund abzugrenzen. Die eingebaute 12-MP-CMOS-Kamera ermöglicht die Erstellung von hochauflösenden Bildern von Objekten. Mit diesem Aufbau wurden verschiedene Beleuchtungsszenarien analysiert: Beleuchtung Nummer 1 mit komplett eingeschaltetem Ringlicht (L1). Hier werden alle Proben gleichmäßig beleuchtet. Bei Beleuchtung Nummer 2 wird direktes Licht von oben verwendet, das sogenannte Auflicht (L2). Damit soll die Einwirkung der unterschiedlichen Beleuchtungsszenarien auf die vorliegende Erkennungsaufgabe untersucht werden. Es wurden jeweils zwei Datensätze pro Korngröße mit beiden Beleuchtungsarten erstellt und analysiert. Das Hauptaugenmerk bei der Bildaufnahme liegt dabei auf den optischen Merkmalen wie Textur, Farbe und Form. Diese Merkmale bilden die notwendigen Informationen der Proben ab, die aus den Bilddaten in Form von numerischen Werten gewonnen werden.

Im nächsten Schritt findet die Segmentierung der Daten mittels einfachem Schwellwertverfahren statt, wodurch die Partikel vereinzelt vorliegen. Anhand dieser segmentierten Partikel werden anschließend relevante Merkmale extrahiert und in Merkmalsvektoren für jedes einzelne Partikel hinterlegt. Ein Merkmalsvektor enthält alle wesentlichen und relevanten Informationen und stellt somit den eigentlichen Input für den nachfolgenden Klassifikationsalgorithmus dar. Weiterhin durchlaufen die Merkmalsvektoren Reduktions- und Selektionsverfahren, da der berechnete Merkmalsvektor zu Beginn viele redundante Informationen sowie Rauschen enthalten kann. Anschließend findet die Trainingsphase statt. Mit dem gewählten Klassifikator wird ein Erkennungsmodell erstellt. Im letzten Schritt werden die Ergebnisse ausgewertet und die Erkennungsrate (ER) sowie die Standardabweichung (Stdev) ermittelt.

2.3 Methoden des maschinellen Lernens

Um die genauen Unterschiede in der Erkennungseffizienz zu untersuchen, werden klassische Ansätze maschinellen Lernens (ML) mit innovativen tiefen neuronalen Netzen - Deep Learning (DL) - verglichen. Hierfür wurden Klassifikatoren mit unterschiedlichen Eigenschaften und Komplexität verwendet, um die Untersuchungen so detailliert wie möglich zu gestalten. Diese werden im Folgenden vorgestellt. Alle Untersuchungen wurden in der Programmierungsumgebung Python implementiert.

Die erste Methode ist Random Forest (RF). Es ist eine Weiterentwicklung des traditionellen Entscheidungsbaummodells (DT). Der Klassifikator setzt sich aus mehreren nicht miteinander verbundenen Entscheidungsbäumen zusammen. Zunächst muss die Gesamtzahl der Bäume im Modell festgelegt werden. Für jeden Baum wird eine zufällig ausgewählte Stichprobe von Objekten mit Ersatz (Bootstrap)

gezogen. Bei der Festlegung der Verzweigungsregeln wird nur eine vorgegebene Anzahl von Merkmalen berücksichtigt. Diese werden bei der Erstellung eines neuen Entscheidungsbaums immer zufällig ausgewählt. Im Gegensatz zu einem traditionellen DT werden die Bäume im RF bis zur maximalen Größe erstellt. Auch das Trimmen wird in diesem Fall nicht verwendet. Bei allen Bäumen werden die Objekte in einem Datensatz nach der Out-of-Bag-Klassifikation sortiert. Für jeden Datenpunkt wird dann die Rate berechnet, mit der jeder Datenpunkt den spezifischen Klassen zugeordnet wurde. Jeder Baum im RF klassifiziert ein neues Objekt. Schließlich wird das Objekt der Klasse zugewiesen, das von der Mehrheit der Bäume bevorzugt wird [14].

Die Grundidee der Support-Vektor-Maschine (SVM) basiert auf der linearen Trennung von Datensatzpunkten in verschiedene Klassen. Ist diese gegeben, kann eine Trennlinie in einem zweidimensionalen Merkmalsraum oder eine lineare Hyperebene in einem mehrdimensionalen Merkmalsraum gezogen werden, die Klassen definiert und die Klassifizierung unbekannter Objekte ermöglicht [15]. Eine Hyperebene ist eine imaginäre Linie, die die Datenpunkte voneinander trennt. Je weiter die Datenpunkte von der Hyperebene entfernt sind, desto besser kann die Klassifizierung erfolgen. Wird ein neuer Datenpunkt zu einem bestehenden Datensatz hinzugefügt, entscheidet seine Orientierung gegenüber der Hyperebene darüber, zu welcher Klasse der neue Punkt gehört. Die lineare Trennbarkeit ist nicht immer gegeben. In solchen Fällen wendet die SVM den sogenannten Kernel-Trick an. Die Daten werden mit Hilfe einer Kernel-Funktion in höherdimensionale Merkmalsräume übertragen, bis eine lineare Trennung möglich ist. Dann wird die Trennebene bestimmt und die Daten werden wieder in den ursprünglichen Merkmalsraum übertragen. Nun ist die Trennebene nicht mehr linear und kann mehrere Klassen voneinander trennen [16].

Ein Perzeptron ist eine modellhafte Nachbildung eines Neurons, das zum einfachsten künstlichen neuronalen Netzen zusammengeschaltet wird. Rosenblatt führte diese Methode im Jahr 1958 ein [17]. Es umfasst einen direkten Graphen mit einzelnen Knoten, die als Neuronen dargestellt werden. Der Eingangsvektor wird in den Ausgangsvektor umgewandelt, sobald er ausgeführt wird. Die Gewichte der einzelnen Neuronen werden angepasst, was dazu führt, dass stärkere Neuronen (durch die Gewichtung) häufiger verwendet werden. Der Name Multilayer Perzeptron (MLP) rührt daher, dass es ein komplexes Problem mit verborgenen Schichten behandeln kann. Dies wirkt sich auf die Komplexität der Struktur und die Berechnungszeit aus.

Ein künstliches neuronales Netz ist eine computergenerierte Darstellung eines biologischen Systems von Neuronen und Nervenzellen [18]. Ein solches Netz ist aus vielen künstlichen Computer-Lerneinheiten, so genannten Neuronen, aufgebaut [19]. Sie wandeln die Eingangssignale in ein Ausgangssignal um. Dies bildet die Grundlage für jede Erkennungsaufgabe ab. Jedes neuronale Netz besteht aus drei Arten von Schichten: der Eingabeschicht, der verborgenen Schicht und der Ausgabeschicht. Die verborgene Schicht, die aus mehreren verbundenen Schichten beste-

hen kann, spielt dabei eine wichtige Rolle. Auch die Struktur der verborgenen Schichten variiert je nach Art der Anwendung des neuronalen Netzes, was zu unterschiedlichen Topologietypen führt [20]. Je mehr verborgene Schichten ein Netz hat, desto komplexere Systeme kann es abbilden. Eine große Anzahl von Schichten sorgt folglich dafür, dass das neuronale Netz "tief" (engl.: *deep*) ist [21]. Gleichzeitig führt eine große Anzahl von verborgenen Schichten bei der Implementierung von DL-Systemen zu rechenintensiven Aufgaben. Komplexe Probleme erschweren auch die Implementierung des Netzes. Lösungen solcher Erkennungsprobleme erfordern eine große Menge an Trainingsdaten, was die Trainingszeit erhöht [22]. Die Menge der Objektbeispiele kann in die Millionen gehen. Die DL-Strukturen werden bereits in einem breiten Spektrum von Anwendungen eingesetzt. Einer der wichtigsten Fälle ist die Mustererkennung in allen Bereichen. Speziell für die Bildverarbeitung wurde ein gefaltetes neuronales Netz (engl.: *convolution neuronal network* (CNN)) entwickelt [23]. Zur Verarbeitung der Bilder wird eine Matrix verwendet (Breite x Höhe x Farbkanäle). Da die Berechnung nicht auf manuell erstellten Merkmalen basiert, wird der Trainingsschritt direkt auf den Bildern oder Bildausschnitten ausgeführt [24]. Die Struktur der verborgenen Schichten ist das wichtigste Unterscheidungsmerkmal zu anderen Architekturen. Sie werden in drei Untergruppen eingeteilt: alternierende Faltungsschichten, Pooling-Schichten und voll verbundene Schichten. Das CNN erkennt zunächst ortsunabhängige Grundstrukturen wie Linien, Kanten und farbige Pixel. In späteren Schichten wird die Kombination dieser Strukturen und komplexeren Muster gelernt, die schließlich zu einem Objekt zusammengefasst und als Ganzes betrachtet werden [25]. Das Transferlernen mit einem so genannten vortrainierten Netz wird eingesetzt, um das Lernen zu beschleunigen und gleichzeitig den Rechenaufwand zu verringern. Das bedeutet, dass zuvor erworbene Netzwerkinformationen über eine bestimmte Aufgabe auf eine neue, ähnliche Aufgabe übertragen werden kann [26]. Für die Lösung der gestellten Aufgabe in dieser Studie wurde das vortrainierte CNN-Modell ResNet50 verwendet. ResNet50 ist eine Kurzbezeichnung für ein neuronales Netz, das in der Computer Vision eingesetzt wird [27]. Dieses Modell wurde bereits mit einem großen Datensatz, bestehend aus 40 Millionen Bildern aus 1000 verschiedenen Klassen, trainiert. Um dieses Netz zu verwenden, muss es nur mit einem eigenen begrenzten Datensatz neu trainiert werden. Eine weitere wichtige Eigenschaft des DL ist, dass es sich bei neuronalen Netzen um „*Black-box*“-Systeme handelt. Der Benutzer kann den Entscheidungsprozess nicht komplett nachverfolgen. Außerdem müssen viele Parameter für jede Aufgabe optimiert werden. Die Aktivierungsfunktion, die Lernrate und die Batchgröße sind Beispiele dafür. Es ist auch schwierig vorherzusagen, wie sich eine Parameteränderung auf die Ergebnisse auswirken wird.

Klassische ML-Ansätze werden mit innovativen DL-Netz verglichen, um Unterschiede in der Erkennungseffizienz an der zuvor beschriebenen Problemstellung zu untersuchen. Anhand der erreichten mittleren ER und Stdev werden alle Ergebnisse miteinander verglichen.

3 Ergebnisse und Diskussion

3.1 Einstellungen der Klassifikatoren

Der für ML-Klassifizierungsaufgabe verwendete Datensatz wird nach dem Zufallsprinzip in zwei Teilmengen mit einem Verhältnis von 80 % zu 20 % aufgeteilt. Die 20 % dienen als Testdatensatz, während die restlichen 80 % als Trainingsdaten verwendet wurden. Die Merkmalsextraktion ist der erste Schritt nach der Bilderfassung und Vorverarbeitung. Die nützlichen Informationen, die aus den Bilddaten in Form von numerischen Werten gewonnen werden, werden als Merkmale bezeichnet. In diesem Schritt werden die Rohbilddaten in aussagekräftige statistische Daten umgewandelt, die auf Bildmerkmalen wie Farbe, Textur und Form basieren, um als Eingabedaten (Merkmalsvektor) für die Klassifizierung mit ML-Algorithmen verwendet zu werden. GLCM [28] wurden zur Berechnung von Texturmerkmalen verwendet. Als Farbmerkmale wurden Farbhistogramme [29] verwendet. Hu-Moments [30] und Zernike-Moments [31], [32] wurden für Formmerkmalberechnung verwendet. Als nächstes findet Merkmalselektionsverfahren statt. Darunter wird eine Methode zur Optimierung des ML-Modells durch Auswahl der besten Teilmenge von Merkmalen aus allen berechneten Merkmalen verstanden. Das Hauptziel des Merkmalselektionsalgorithmus besteht darin, die Eingangsmerkmale zu bewerten, indem Merkmale ausgeschlossen werden, die keine wichtigen Daten enthalten oder die Verbesserung der Genauigkeit einer Klassifizierung keine Rolle spielen. Dieser Prozess erhöht die Verständlichkeit von Klassifizierungsmodellen und ermöglicht es dem Anwender, bessere Ergebnisse zu erzielen.

Die in der Studie verwendeten Klassifikatoren haben unterschiedliche Einstellungsparameter. Der RF-Klassifikator basiert auf Entscheidungsbäumen und die Anzahl der Bäume ist auf 25, 50, 100 und 150 festgelegt worden. Bei der SVM wurden der lineare, polynomiale und rbf Kernel verwendet und der γ -Parameter auf 0,02 gesetzt. Es wurde der Eins-gegen-alle-Klassifikationsmodus verwendet, womit ein Mehrklassenproblem auf ein binäres Problem reduziert werden kann. Die gewählte Implementierung erzeugt für jede Klasse einen Klassifikator, der dann mit allen übrigen Klassen verglichen wird. Für MLP wird eine Softmax-Aktivierungsfunktion verwendet. Sie eignet sich am besten für Klassifizierungsaufgaben mit mehreren unabhängigen Klassifizierungsausgaben. In der verborgenen Schicht wird die Anzahl der versteckten Einheiten auf 3 und 5 festgelegt.

Wie bereits erwähnt, wurde als DL-Methode ein vortrainiertes CNN verwendet. Es muss im Wesentlichen mit unserem eigenen Datensatz neu angepasst werden. Dadurch wird das Problem unzureichender Daten während der Trainingsphase eines neuen neuronalen Netzes vermieden und es werden mit einem vortrainierten Netzwerk je nach Problemstellung nur hunderte bis tausende von Bildobjekten pro Klasse benötigt. Die Trainingsphase kann zu diesem Zweck nur mit einer modernen GPU durchgeführt werden. Weitere Parameter wurden wie folgt festgelegt: die Batchgröße wurde auf 32 und die Anzahl der Epochen auf 30 festgelegt. ResNet50 verwendet eine adaptive Lernrate mit dem Optimierer Adam. Anstelle der konventionellen stochastischen Gradientenabstiegsmethode ist Adam ein Optimierungsalgorithmus, der zur iterativen Aktualisierung der Netzwerkgewichte auf der Grundlage der Trainingsdaten verwendet werden kann. Die Vorteile des Adam-Optimierers gegenüber anderen sind die schnellere

Rechenzeit und der geringere Bedarf an Parametern für die Abstimmung [30]. Die Lernrate beginnt bei 0,00005. Der Datensatz ist für die Verwendung mit DL in zwei Teile aufgeteilt. Der größte Teil der Daten (80 %) wird zum Training und zur Validierung verwendet, die restlichen 20 % zum Testen. Das Modell wird angepasst, indem die unteren Faltungsschichten des ResNet50-Modells, das bereits auf dem ImageNet-Datensatz trainiert wurde, eingefroren werden und dann eine neue, vollständig verknüpfte Schicht am Ende des Modells hinzugefügt und als vollständiges Modell auf dem vorliegenden Datensatz trainiert werden. Das Modell verfügt nun über allgemeine Merkmale wie Kanten, Linien usw. aus den zuvor trainierten ImageNet-Daten, und spezifische Merkmale werden aus dem Ziegeldatensatz. Der Dropout ist ein probabilistischer Ansatz, der Neuronen inaktiv schaltet und Daten dazu zwingt, auf anderen Pfaden zu fließen lassen, wodurch die Fähigkeit des Modells, Daten effektiv zu verarbeiten, verbessert wird. Standardmäßig ist der Wert auf 0 gesetzt. Es verringert auch die Überanpassung eines Modells. Während der Durchführung dieser Untersuchung wurde der Dropout-Werte des CNN-Modells auf 0,5 gesetzt.

3.2 Analyseergebnisse

Die Ergebnisse der Untersuchungen des Datensatzes in der Partikelgröße 4 - 8 mm sind in der Tabelle 2 zusammengefasst. Die Mehrheit der Klassifikatoren erreichten eine ER über 90 %. Nur der einfachste Klassifikator DT, im Vergleich zu anderen verwendeten Klassifikatoren, erreichte eine ER von 89,50 %. Das beste Ergebnis mit ER von 97,34 % erzielt das künstliche neuronale Netz ResNet50. Unter den klassischen Klassifikatoren schnitt mit 94,89 % der RF mit 150 Bäumen am besten ab.

Tabelle 2 Analyseergebnisse in der Partikelgröße 4 - 8 mm

ER und Stdev (%)	Datensätze			
	L1 (Ringlicht)		L2 (Auflicht)	
Klassifikator	ER	Stdev	ER	Stdev
DT	88,83	0,58	89,50	0,88
RF_25	94,15	0,51	94,30	0,56
RF_50	94,30	0,44	94,82	0,49
RF_100	94,66	0,35	94,73	0,28
RF_150	94,67	0,40	94,89	0,42
SVM_rbf	92,02	0,61	92,71	0,59
SVM_poly	88,37	0,66	90,16	0,41
SVM_linear	93,10	0,67	93,64	0,51
MLP_3	90,01	1,31	89,74	1,00
MLP_5	92,97	0,26	92,57	0,39
ResNet50	97,34	1,64	97,22	1,90

Die Untersuchungen am Datensatz mit der Partikelgröße 2 - 4 mm zeigen geringfügig schlechtere Ergebnisse. Dies

liegt an kleiner aufgenommenen Fläche der Ziegelpartikel und somit der erschwerten Bedingung für die Klassifikatoren. Auch hier liegen die meisten Ergebnisse über 90 % ER. Nur DT und MLP mit 3 versteckten Einheiten haben die ER bei 86,90 % und 89,05 %. Die gesamten Ergebnisse sind in der Tabelle 3 dargestellt.

Tabelle 3 Analyseergebnisse in der Partikelgröße 2 - 4 mm

ER und Stdev (%)	Datensätze			
	L1 (Ringlicht)		L2 (Auflicht)	
Klassifikator	ER	Stdev	ER	Stdev
DT	86,75	0,96	86,90	0,65
RF_25	92,38	0,45	92,39	0,31
RF_50	92,62	0,42	92,76	0,71
RF_100	92,90	0,43	92,93	0,62
RF_150	92,99	0,44	92,88	0,43
SVM_rbf	91,29	0,29	92,53	0,71
SVM_poly	88,90	0,65	91,26	0,75
SVM_linear	91,41	0,16	92,36	0,20
MLP_3	88,93	0,69	89,05	1,07
MLP_5	90,90	1,04	91,38	0,58
ResNet50	95,97	3,11	96,56	2,08

Die zwei besten Ergebnisse wurden auch bei dieser Untersuchung mit ResNet50 und RF mit 150 Bäumen erreicht. Bei ResNet50 liegt das Ergebnis bei 96,56 % und bei RF_150 bei 92,99 %. Die unterschiedliche Beleuchtung hatte nur einen geringen Einfluss auf die Erkennung. Beide Datensätze L1 und L2 zeigen sehr ähnliche Ergebnisse. Obwohl mit L2 wurde meist über alle Klassifikatoren geringfügig (unter einem Prozent) bessere ER erzielt. Weiterhin lässt sich sagen, dass alle erstellten Modelle einen stabilen Klassifizierungsprozess aufweisen und die Standardabweichung daher sehr niedrig ausfällt. CNN ResNet50 erzielte in den Untersuchungen immer die höchste ER, aber auch mit verhältnismäßig höheren Stdev von ungefähr zwei Prozent. Bei den klassischen Klassifikatoren liegt die Stdev meistens bei unter einem Prozent.

Die drei besten Klassifikatoren werden im Detail näher betrachtet und die ER der einzelnen Klassen miteinander verglichen. Die Ergebnisse sind in den nachfolgenden Abbildungen (Abbildung 1 und Abbildung 2) dargestellt. Es fällt sofort auf, dass bei der Kategorie II (Dachziegel und Vormauerziegel) die meisten Fehlvorhersagen auftreten. Hier liegt die ER nur mit ResNet50 deutlich über 90 %. Mit klassischen Klassifikatoren wird meist eine ER von unter 90 % erreicht. Die am sichersten erkennbare Kategorie ist die Nummer V mit sonstigen Materialien. Hier liegt die ER mit allen Klassifikatoren deutlich über 95 %.




Abbildung 1 ER-Betrachtung nach Kategorien mit drei verschiedenen Klassifikatoren mit 4 - 8 Partikelgröße (I dicht gebranntes Material, II Dachziegel und Vormauerziegel, III niedrig gebrannte Ziegel und V sonstiges Material)




Abbildung 2 ER-Betrachtung nach Kategorien mit drei verschiedenen Klassifikatoren mit 2 - 4 Partikelgröße (I dicht gebranntes Material, II Dachziegel und Vormauerziegel, III niedrig gebrannte Ziegel und V sonstiges Material)

4 Schlussfolgerungen

Die Klassifizierungsergebnisse, die mit den klassischen ML-Algorithmen für den Ringlicht- und den Auflicht-Datensatz erzielt wurden, zeigen, dass die optische Unterscheidung von verschiedenen Ziegelarten mit Partikelgröße < 8 mm umgesetzt werden konnte. Die Unterscheidung der betrachteten Ziegelarten, eingeteilt in 4 Kategorien, ist anhand von Bildmerkmalen mit sehr hohen Erkennungsraten möglich. In Verbindung mit sowohl klassischen als auch modernen ML-Ansätze können Klassifikatoren erstellt werden, welche die Ziegelart anhand von Bilddaten automatisiert bestimmen können. Ein wesentlicher Vorteil klassischer ML-Ansätze gegenüber modernen DL-Algorithmen besteht darin, dass die berechneten Merkmale erklärt werden können. Im Vergleich dazu ist es nicht möglich, ein CNN zu interpretieren, da es als Black-Box-Ansatz bezeichnet werden muss. Andererseits macht der Wegfall einiger Vorverarbeitungsschritte in der Bildverarbeitungskette, wie z. B. die Auswahl von Merkmalen, die Anwendung von tiefen Netzen einfacher als die klassischen Methoden. Ein weiterer Nachteil von DL besteht darin, dass eine große Menge an Trainingsdaten und eine Feinabstimmung verschiedener Parameter erforderlich ist, um einen DL-Algorithmus richtig auszuführen. Außerdem ist ein teurer Computer mit einem modernen Grafikprozessor erforderlich, um ein DL-Netz zu betreiben, und auch die Trainingszeit ist deutlich höher als bei klassischen Methoden.

Schließlich lässt sich sagen, dass solche Systeme die Recyclingindustrie dabei unterstützen können, die Effizienz und Genauigkeit der Sortierung zu erhöhen, eine schnellere Sortierung zu ermöglichen und Fehlklassifizierungen zu reduzieren. Sie kann auch dazu beitragen, die Recyclingquoten zu erhöhen. Der nächste Schritt besteht darin, die Erkennung an einem Demonstrator vorzustellen.

Danksagung

Das Forschungsprojekt „Automatisierte hyperspektrale Bildgebung und Bildanalyse für die Sortierung von Ziegel- und Mauerwerksbruch unter Verwendung von Verfahren des maschinellen Lernens“ wird von der AiF im Rahmen der industriellen Gemeinschaftsforschung (IGF) gefördert. Besonderer Dank gilt der AiF, die durch ihre finanzielle Unterstützung die Forschung zum o. g. Thema erst ermöglicht hat.

Literatur

- [1] Kreislaufwirtschaft Bau, „Mineralische Bauabfälle Monitoring 2020,“ Bundesverband Baustoffe-Steine und Erden e.V, Berlin, 2022.
- [2] A. Müller, Baustoffrecycling: Entstehung-Aufbereitung-Verwertung, Springer Vieweg, 2018.
- [3] Bundesverband der Deutschen Ziegelindustrie e.V., „STATUS QUO UND PERSPEKTIVEN- RE-USE UND RECYCLING VON ZIEGELN,“ Berlin, 2020.
- [4] M. Landmann, A. Müller, U. Palzer und e. al., „Leistungsfähigkeit von Aufbereitungsverfahren zur Rückgewinnung sortenreiner Materialfraktionen aus Mauerwerk – Teil 1 und 2,“ *Aufbereitungs-Technik/Mineral Processing, Heft 03 und Heft 04* , Bd. 55, pp. 62-72, 2014.
- [5] AiF- IGF Vorhaben 18889 BG, „Charakterisierung sortierter Ziegel-Recycling-Materialien anhand physikalischer und chemisch-mineralogischer Eigenschaften für die Generierung neuer Stoffströme,“ Schlussbericht, 2019.
- [6] S. Petereit, „Ressourceneffizienz - Ziegel aus alternativen Rohstoffen,“ Vortrag zum IZF-Seminar , Essen, 2019.
- [7] S. Sabath, „Charakterisierung sortierter Ziegel-RC-Materialien,“ Vortrag zum IZF-Seminar , Essen, 2019.
- [8] Verein Deutscher Zementwerke e.V., „Brechsand als Zementhauptbestandteil – Leitlinien künftiger Anwendung im Zement und Beton: Die Potenziale der Recyclingbrechsande: Von der Aufbereitung mineralischer Bauabfälle bis zur Herstellung ressourcenschonender Betone,“ Information Betontechnik, 2019.
- [9] E. Linß, M. Landmann und A. Karrasch, „Sorting of mineral construction and demolition waste by near-infrared technology,“ in *HISER International Conference*, Delft (The Netherlands), 2017.
- [10] AiF-ZIM Vorhaben FKZ ZF 4144903GR6, „Analyseverfahren zur automatisierten Qualitätssicherung für rezyklierte Gesteins-körnungen auf Basis hyperspektraler Bildinformationen im VIS und NIR,“ Schlussbericht, 2018.
- [11] E. Linß, D. Garten, A. Karrasch, K. Anding und P. Kuritcyn, „Automatisierte Sortieranalyse für rezyklierte Gesteinskörnungen,“ in *Fachtagung Recycling R'19*, Weimar, 2019.
- [12] P. Kuritcyn, K. Anding, E. Linß und G. Notni, „Using hybrid information of colour image analysis and SWIR-spectrum for high-precision analysis of construction and demolition waste,“ *Optical Characterization of Materials (OCM)*, Karlsruhe, Germany, 2019.
- [13] J. Walz, E. Linß und C. Könke, „Automatic image analysis of mineral construction and demolition waste (CDW) using machine learning methods and deep learning,“ *EG-ICE 2021 Workshop on Intelligent Computing in Engineering*, pp. 530-539, 2021.
- [14] L. Breiman, „Random forests,“ *Machine learning*, 45, pp. 5-32, 2001.
- [15] J. Cleve und U. Lämmel, Data Mining, München: De Gruyter Oldenbourg, 2014.
- [16] C. Cortes und V. Vapnik, „Support-vector networks,“ in *Machine Learning*, 1995, pp. 273-297.
- [17] F. Rosenblatt, „The Perceptron: A Probabilistic Model for Information Storage and,“ *Psychological Review*, 6, pp. 386-408, 1958.
- [18] W. Ertel, Grundkurs Künstliche Intelligenz: eine praxisorientierte Einführung, Wiesbaden: Vieweg + Teubner, 2016.
- [19] W. S. McCulloch und W. Pitts, „A logical calculus of the ideas immanent in nervous activity,“ *Bulletin of Mathematical Biology*, Nr. 52, pp. 99-115, 1990.
- [20] J. Biethahn, A. Hönerloh, J. Kuhl, M.-C. Leisewitz und V. Nissen, Betriebswirtschaftliche Anwendungen des Soft Computing, Vieweg+Teubner Verlag, 1998.
- [21] I. H. Witten, E. Frank, M. A. Hall und C. J. Pal, Data Mining: Practical Machine Learning Tools and Techniques, Cambridge: Morgan Kaufmann,, 2017.
- [22] G. Marcus, „Deep Learning: A Critical Appraisal,“ 2018.
- [23] Y. LeCun, B. L. Y. Bengio und P. Haffner, „Gradient-based learning applied to document recognition,“ *Proceedings of the IEEE*, pp. 2278-2324, 1998.

- [24] M. Sesselmann, R. Stricker und M. Eisenbach, „Einsatz von Deep Learning zur automatischen Detektion und Klassifikation von Fahrbahnschäden aus mobilen LiDAR-Daten,“ *AGIT - Journal für Angewandte Geoinformatik*, Nr. 5, pp. 100-114, 2019.
- [25] Quoc V. Le; Google Brain; Google Inc, „A Tutorial on Deep Learning Part 2: Autoencoders, Convolutional Neural Networks and Recurrent Neural Networks,“ Mountain View, CA, 2015.
- [26] L. Torrey und J. Shavlik, „Transfer learning,“ *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*, pp. 242-264, 2010.
- [27] S. Targ, A. Diogo und K. Lyman, „Resnet in resnet: Generalizing residual,“ arXiv preprint arXiv:1603.08029, 2016.
- [28] R. M. Haralick, „Statistical and structural approaches to texture,“ *Proceedings of the IEEE*, 67(5), pp. 786-804, 1979.
- [29] N. G. Nguyen, R. S. Poulsen und C. Louis, „Some new color features and their application to cervical cell classification,“ *Pattern recognition*, 16(4), pp. 401-411, 1983.
- [30] M.-K. Hu, „Visual pattern recognition by moment invariants,“ *IRE transactions on information theory*, 8(2), pp. 179-187, 1962.
- [31] F. Alt L., „Digital pattern recognition by moments,“ *Journal of the ACM (JACM)*, 9(2), pp. 240-258, 1962.
- [32] A. B. Bhatia und E. Wolf, „On the circle polynomials of zernike and related orthogonal sets, volume 50,“ in *Mathematical Proceedings of the Cambridge Philosophical Society*, Cambridge University Press, 1954, pp. 40-48.
- [33] D. P. Billington, *The tower and the bridge: the new art of structural engineering*, Princeton University Press, 1985.
- [34] R. van Eijk und J. Brouwers, „Stimulating The Use Of Secondary Materials In The Construction Industry: The Role Of Certification.,“ *International journal of construction marketing*, Vol. 3, No. 2, , pp. 43-50, 2002.
- [35] DIN EN 12620, „Gesteinskörnungen für Beton,“ Beuth, 2008.
- [36] DIN EN 933-11, „Gesteinskörnungen - Teil 11: Einteilung der Bestandteile in grober recycelter Gesteinskörnung,“ Beuth, 2011.
- [37] O. Mont und A. Plepys, „Sustainable consumption progress: should we be proud or alarmed?,“ *Journal of Cleaner Production - J CLEAN PROD*, pp. 531-537, 2008.
- [38] Kreislaufwirtschaft Bau, „Mineralische Bauabfälle Monitoring 2018,“ Bundesverband Baustoffe–Steine und Erden e.V, Berlin, 2021.
- [39] K. Van Dijk, „Closing the clay brick cycle,“ 2004.
- [40] EQAR, „RECYCLING Magazin,“ DETAIL Business Information GmbH, 02 10 2016. [Online]. Available: <https://www.recyclingmagazin.de/2016/10/02/352716/>. [Zugriff am 03 01 2020].
- [41] HALCON Operator-Referenz, „www.mvtec.com,“ MVTec Software GmbH, 2017. [Online]. Available: https://www.mvtec.com/doc/halcon/12/de/toc_region_features.html. [Zugriff am 10 12 2019].