



KI for BauChain

KI-basierte Datenerfassung
und -weiterverarbeitung für
Baumaterial in einer digitalisierten
Bauprozesskette

Dr.-Ing. Davide Picchi
Prof. Dr. techn. Sigrid Brell-Cokcan

KI-basierte Baustofflogistik

Automatisierte Erfassung:
Volumen, Korngrößen und
Materialklassen

Kurzfassung

Der Fokus des Forschungsvorhabens „KI for BauChain“ liegt darin, zentrale Wertschöpfungsprozesse der Bauwirtschaft – insbesondere die Baustofflogistik – trotz digitaler Planung weitgehend analog, bruchstückhaft und mediengetrennt zu organisieren. Während auf Planungs- und Steuerungsebene moderne BIM-Werkzeuge eingesetzt werden, bricht die digitale Prozesskette an der Schnittstelle zu Handel, Logistik und ausführenden Unternehmen ab. Materialbestellung, Wareneingang, Lagerung und Bereitstellung werden auf der Baustelle häufig papierbasiert oder in isolierten Einzelsystemen geführt, wodurch Informationen über Menge, Typ, Zustand und Ort von Baustoffen unvollständig, verspätet oder gar nicht verfügbar sind.

Gerade vor dem Hintergrund, dass Baustoffbeschaffung im Mittel rund ein Fünftel der Projektgesamtkosten ausmacht und die Bauwirtschaft einen erheblichen Anteil der CO₂-Emissionen verursacht, führen diese Informationsdefizite zu relevanten wirtschaftlichen und ökologischen Fehlentwicklungen: Verzögerungen, Nacharbeiten, Überbestände, Fehlbestellungen und unnötige Transporte. Bereits geringe Störungen zu Beginn der Lieferkette pflanzen sich entlang des Bauablaufs fort und entfalten durch Termin- und Abhängigkeitsstrukturen überproportionale Wirkung. Ein durchgängig digitales, verlässliches Bild der Materialströme existiert bislang nicht, sodass weder eine vorausschauende Disposition noch eine echtzeitnahe, datenbasierte Prozesssteuerung möglich ist.

Besonders ausgeprägt sind diese Defizite bei Schütt- und Körnermaterialien. Sie sind für zahlreiche Anwendungen (Betonzuschläge, Tragschichten, Füll- und Ausgleichsmaterial etc.) unverzichtbar, lassen sich aber nicht als einzelne, chip-markierbare Objekte behandeln. Klassische Lösungsansätze – etwa RFID-Tags oder Barcodes – greifen hier nicht. Menge, Korngrößenverteilung, Form und Zustand solcher Materialien können mit vertretbarem Aufwand heute nur punktuell im Labor oder mit teurerer 3D-Messtechnik bestimmt werden. Damit fehlt genau dort eine praktikable, automatisierbare Lösung, wo wirtschaftlich und qualitativ besonders relevante Materialkategorien im Einsatz sind.

Gleichzeitig entstehen durch den Trend zu autonomen und „intelligenten“ Baustellen neue Anforderungen: Für eine KI-gestützte, echtzeitnahe Prozesssteuerung werden detaillierte, aktuelle Informationen über Materialart,

Volumen, Korngrößenverteilung und Zustand benötigt, um zum Beispiel Mischungsqualitäten zu sichern, Nachlieferungen rechtzeitig anzustoßen, Baumaschinen zu steuern oder Bauabläufe flexibel anzupassen. Ohne automatisierte, robuste Erfassung dieser Größen bleibt das Potenzial von BIM, Robotik und digitaler Bauprozesssteuerung weitgehend ungenutzt.

Hier setzt „KI for BauChain“ an: Es adressiert die Lücke zwischen hochpräzisen, aber teuren Speziallösungen (Laserscanner, UAV-LiDAR) und unzuverlässigen, manuellen Schätzverfahren, indem es kostengünstige, weit verbreitete Sensorik (insbesondere RGB- und OAK-D-Kameras auf mobilen Plattformen) mit modernen Verfahren der Computer Vision und des Deep Learning kombiniert. Die automatisierte Volumenbestimmung von Schüttguthaufen, die granulometrische Charakterisierung (Korngrößenverteilung) und die Klassifikation von Baustoffen in ihrem Rohzustand werden nicht als isolierte Teilprobleme behandelt, sondern explizit als Bausteine einer durchgängigen digitalen Prozesskette konzipiert.

Die mehrstufige Zielstruktur – Volumenbestimmung, Materialklassifikation, granulometrische Analyse – ist dabei nicht Selbstzweck, sondern leitet sich direkt aus den praktischen Anforderungen der Baustofflogistik ab: Nur wenn bekannt ist, welches Material in welcher Qualität, in welcher Menge und an welchem Ort verfügbar ist, lassen sich Beschaffung, Lagerung, Transport und Verarbeitung effizient und resilient planen. Durch die Integration der erfassten Informationen in semantische, BIM-beziehungsweise Linked-Data-basierte Prozessmodelle entsteht ein digitales Prozessabbild („digitaler Zwilling“ der Baustofflogistik), das eine agile, vorausschauende Steuerung der Baustelle erlaubt.

Ergebnisse

Die am Lehrstuhl für Individualisierte Bauproduktion der RWTH Aachen University durchgeführten Arbeiten liefern in ihrer Gesamtheit ein konsistentes, empirisch untermauertes Bild darüber, in welchem Umfang Computer-Vision- und Deep-Learning-Verfahren bereits heute zur Volumenbestimmung, granulometrischen Charakterisierung und Klassifikation von Baustoffen auf Baustellen einsetzbar sind und unter welchen Randbedingungen diese Verfahren zuverlässig arbeiten.

Volumenbestimmung von Schüttgütern mit Multi-View-Deep-Learning

Die wissenschaftliche Publikation „A Multi-View Approach for Bulk Material Volume Estimation“ (Picchi/Brell-Cokcan 2025) zeigt, dass das Volumen von Schüttguthaufen (z. B. Sand- und Steinhaufen) mit handelsüblichen RGB-Kameras und Multi-View-Deep-Learning-Modellen mit hoher Genauigkeit und ohne teure 3D-Messtechnik geschätzt werden kann.

Dazu wird zunächst ein synthetischer Datensatz aus 25 000 zufällig generierten Haufen in Blender erzeugt, deren Volumen exakt bekannt ist und zwischen $0,3 \text{ m}^3$ und 50 m^3 liegt. Pro Haufen werden 12 Ansichten von virtuellen Kameras aus 15 m Entfernung aufgenommen; vier davon werden für Training und Inferenz verwendet, wobei die Kamerapositionen leicht verrauscht werden, um Realbedingungen anzunähern. Die Haufen werden mit dem Segment Anything Model (SAM) segmentiert, um Hintergrund und Störobjekte zu entfernen, und die resultierenden Maskenbilder dienen als Eingabe für zwei Architekturen: ein Multi-View-CNN und einen Multi-View-Vision-Transformer (ViT).

Auf dem synthetischen Datensatz erreichen beide Modelle sehr hohe Gütemaße: Das beste Multi-View-CNN erzielt bei geeigneter Lernrate, ein Bestimmtheitsmaß (R^2) von 0,899 bis zu 0,987. Die Multi-View-ViT Architektur erreicht bei vergleichbarer Konfiguration ebenfalls ein Bestimmtheitsmaß (R^2)-Wert zwischen 0,978 und 0,987, womit sie das CNN leicht übertrifft.

Die Feldversuche auf einer Referenzbaustelle bestätigen die grundsätzliche Praxistauglichkeit der Ansätze, zeigen aber auch systematische Abweichungen gegenüber 3D-Laserscannern. Zur Validierung werden mehrere Sandhaufen mit einem Riegl VZ-400i in Form von Punktwolken vermessen, daraus Referenzvolumina bestimmt und anschließend mit den Schätzungen des Multi-View-CNN und des Multi-View-ViT verglichen.

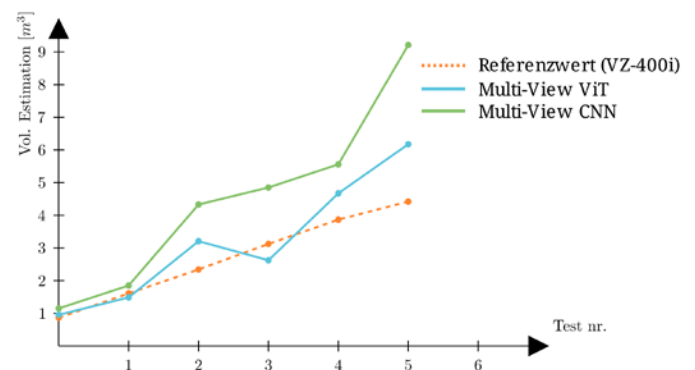


Abb. 1: Testresultat der implementierten Architekturen; Quelle: Davide Picchi

Während der ViT die Volumina konsistent näher an den Laserscanner-Werten trifft als das CNN (Abbildung 1) bleiben die Fehler in einem Bereich, der für operative Zwecke (Materialdisposition, grobe Bestandsführung) als „hinreichend genau“ eingestuft wird.

Die Arbeit betont ausdrücklich, dass das Ziel nicht die Substitution hochpräziser 3D-Messverfahren ist, sondern das Schließen der Lücke zwischen teuren, personalintensiven Scannern und unzuverlässigen manuellen Schätzungen durch ein kostengünstiges, robustes „Gut genug-Verfahren“ auf Basis von RGB-Kameras. Gleichzeitig werden zentrale Einschränkungen identifiziert: Die Bildaufnahme muss mit dem während des Trainings verwendeten Abstand (15 m) erfolgen, da Geometrieänderungen durch variable Distanzen sonst die Volumenschätzung verfälschen; außerdem stößt SAM bei benachbarten Schüttguthaufen unterschiedlicher Materialien an Grenzen und erfordert ggf. menschliche Kontrolle der Segmentierung.

Granulometrische Charakterisierung und Materialprüfung mit SAM + CNN-Regression

In der Arbeit „Material Examination and Classification Using Computer Vision“ (Guo 2024) wird ein vollständig bildbasierter Workflow zur Bestimmung der Korngrößenverteilung granularer Baustoffe sowie zur Identifikation des Materialtyps entwickelt und implementiert. Ziel ist es, klassische Methoden wie Siebversuche oder Laser-Diffraction, die arbeits- und geräteintensiv sind, um eine automatisierte, vor Ort einsetzbare Alternative zu ergänzen.

Datensatz, Segmentierung und Labelgenerierung

Ausgehend von 20 verschiedenen Baustoffgranulaten (Sand, Kies, Splitt, Marmorkiesel etc.) mit Partikelgrößen zwischen 0,075 mm und 80 mm werden hochaufgelöste Bilder aufgenommen (definierte Beleuchtung, konstante Distanz zum Material). Für jedes Material werden anhand der nominalen Korngrößenbereiche ausgewählt und in einem Datensatz von jeweils 1.000 Ausschnitten (224×224 Pixel) organisiert (Abbildung 2).




Abb. 2: Instanzsegmentierung zur Flächenermittlung der Korngröße; Quelle: Guo Baiyi

Da direkte Label für mittlere Korngröße (μ) und Standardabweichung (σ) in der Regel fehlen, werden diese über ein vorgeschaltetes Segmentierungs- und Analyseverfahren gewonnen: Mit einem SAM-Modell werden in jedem Bild einzelne Partikel maskiert, anschließend berechnet das Programm OpenCV über den „Minimum Enclosing Circle“ für jedes Partikel einen Durchmesser in Pixeln, der über einen Kalibrierfaktor in Millimeter umgerechnet wird. Aus allen Partikeldurchmessern eines Bildes werden die Größen (μ) und (σ) berechnet und als Regressionslabels separat abgelegt (Abbildung 2).

Die Arbeit zeigt, dass SAM in dem gewählten Setup insbesondere für Partikel im Bereich von 3–30 mm stabile

Segmentierungen liefert, während sehr kleine (< 3 mm) oder sehr große Körner (> 30 mm) zu Fehlsegmentierungen und damit systematischen Fehlern bei (μ) und (σ) führen können. Zudem wird die hohe Rechenlast von SAM als wesentlicher limitierender Faktor für Echtzeitanwendungen identifiziert.

Modellvergleich: ResNet50, VGG16 und Custom-CNN

Auf Basis der aus SAM+OpenCV gewonnenen Labels werden drei CNN-Architekturen als Regressor trainiert: ResNet50, VGG16 und ein eigens entworfenes CNN. Die Modelle werden mit identischer Bild-Normalisierung trainiert und anschließend auf einem Testdataset evaluiert.

Die Ergebnisse zeigen eine klare Überlegenheit der ResNet50-Architektur gegenüber den anderen konkurrierenden Architekturen (Abbildung 3). VGG16 erreicht etwas schlechtere, aber noch sehr gute Ergebnisse während das entworfene CNN bleibt deutlich hinter beiden Standardarchitekturen und wird daher als nicht konkurrenzfähig bewertet.

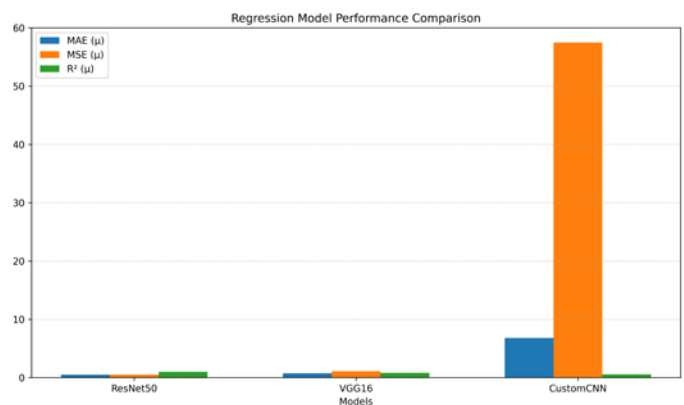


Abb. 3: Testergebnisse der drei CNN-Architekturen; Quelle: Guo Baiyi

Echtzeit-Tests mit OAK-D-Kamera

Für die Praxisrelevanz wird das beste Modell (ResNet50) mit OpenVINO auf einer Luxonis OAK-D Pro Auto Focus Kamera in Echtzeit getestet. In einem Laboraufbau mit drei Referenzmaterialien (6 mm, 9 mm, 20 mm) und variierenden Kameradistanzen (150–1050 mm) wird untersucht, wie stark die Vorhersagegüte von (μ) und (σ) von der Entfernung abhängt.

Die Ergebnisse zeigen ein deutliches Distanzfenster für zuverlässige Schätzungen: Im Bereich von circa 300–800 mm liefert das System stabile und mit den Referenzwerten gut übereinstimmende (μ) und (σ)-Vor-

hersagen; bei geringeren Distanzen versagen die Tiefe-Erfassung und das Sichtfeld der Kamera, bei größeren Distanzen reduziert die abnehmende Auflösung pro Partikel die Erkennungsqualität signifikant. Gleichzeitig verdeutlichen die Tests die Sensitivität gegenüber Beleuchtungsvariationen und die Notwendigkeit sorgfältiger Kalibrierung von Auflösung und Normalisierung bei der Übertragung des Modells von der Trainings- auf die Einsatzhardware.

Insgesamt zeigt die Arbeit, dass eine automatische, bildbasierte Bestimmung von Korngrößenverteilungen bis hin zu (μ) und (σ) mit hoher Genauigkeit möglich ist, wenn Segmentierung (SAM) und Regression (ResNet50) in einem sorgfältig abgestimmten Workflow-Design kombiniert werden und die physikalischen Randbedingungen (Partikelgröße, Distanz, Beleuchtung) berücksichtigt werden.

Materialklassifikation und ROS2-Integration auf mobilen Plattformen

Die Arbeit: „Development of a Computer-Based Vision System for Material Classification and Identification on Construction Sites“ (Landazuri 2024) adressiert die Aufgabe, Rohbaustoffe (z. B. Ziegel, Blöcke, Bewehrungsstahl, Schüttgüter) auf der Baustelle in Echtzeit zu klassifizieren und diese Funktionalität in ein ROS2-basiertes, robotisches System einzubetten.

Aufbau der Raw Construction Materials Database (RCMD)

Mangels geeigneter existierender Bilddatensätze zu Rohbaustoffen wird eine eigene Datenbank aufgebaut, die sich an den Kategorien der ÖKOBAUDAT-Datenbank orientiert und Materialien der Rohbauphase in vielfältigen Erscheinungsformen abbildet. Die finale RCMD Datenbank umfasst 10 947 Bilder in neun Klassen, unter anderem Bewehrungsstahl, Zement, Porenbeton-Blöcke, Hohlziegel, Hohlblocksteine, Dachziegel, Lava-Granulat, Sand und Kies (Abbildung 4).

Die Bilder werden aus drei Quellen gewonnen: existierenden Forschungsdatensätzen und eigenen Aufnahmen auf Baustoffhöfen sowie der Referenzbaustelle der RWTH Aachen. Sie werden manuell mit CVAT annotiert (Bounding Boxes, Polygone, Metadaten wie „single/pile“, „covered/uncovered“), anschließend auf 224×224 Pixel normiert und mit moderater Datenaugmentation (Rotation, Verschiebung, Helligkeit, Zoom, horizontale Spiegelung) verarbeitet.



Abb. 4: Beispiele von repräsentierten Klassen aus dem (RMCD) Dataset; Quelle: Vanessa Landazuri

Modellleistung in kontrollierten Umgebungen

Für die Klassifikation werden VGG16, ResNet50V2 und DenseNet121 mittels Transfer Learning auf die RCMD adaptiert. Auf dem 5-Klassen-Datensatz erreichen alle Modelle sehr hohe Testgenauigkeiten: VGG16: 98,01 %, ResNet50V2: 99,15 % und DenseNet121: 99,29 %. Auf dem erweiterten 9-Klassen-Datensatz sinken die Genauigkeiten erwartungsgemäß leicht, bleiben aber auf hohem Niveau: VGG16: 93,91 % und DenseNet121: 98,05 %. DenseNet121: erweist sich durchgängig als bestes Modell, mit Präzision und Recall > 0,97 für nahezu alle Klassen und F1-Werten um 98 %; die größten Herausforderungen bestehen bei visuell ähnlichen granulären Materialien (Gravel vs. Lava-Granulat) und bei Dachziegeln (Tabelle 1).

ROS2-Integration und On-Site-Evaluation

In Feldtests auf der Referenzbaustelle wird die Klassifikationsleistung unter realen Bedingungen untersucht (Luxonis OAK-D Pro Kamera, Raspberry Pi 4 (2 GB), Innok HEROS (2WD/4WD) als mobile Plattform), zunächst mit einer Zielklasse (Porenbeton-Blöcke), später mit mehreren Materialien (Hohlziegel, Hohlbetonsteine, Zement).

Die Arbeit kommt zu dem Schluss, dass ein kostengünstiges, ROS2-basiertes System zur Echtzeitklassifikation von Rohbaustoffen unter Baustellenbedingungen grundsätzlich realisierbar ist und mit DenseNet121 eine robuste Kernarchitektur zur Verfügung steht, das Zusammenspiel aus Modell, Datenbank, Kommunikationsarchitektur und Filterlogik jedoch fein abgestimmt werden muss, um den unterschiedlichen betrieblichen Zielsetzungen (maximale Zuverlässigkeit vs. maximale Erkennung) gerecht zu werden (Abbildung 5).

Model	Dataset	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
VGG16	5 Categories	98,01	97,38	97,2	98,01
VGG16	9 Categories	93,91	93,85	92,62	93,92
ResNet50v2	5 Categories	99,15	98,67	98,92	99,15
ResNet50v2	9 Categories	97,63	97,29	96,90	97,61
DenseNet121	5 Categories	99,29	99,20	98,85	99,29
DenseNet121	9 Categories	98,05	98,03	97,55	98,06

Tab. 1: Testresult der drei Architekturen; Quelle: Vanessa Landazuri




Abb. 5: Reale Tests auf der Referenzbaustelle der RWTH Aachen University; Quelle: Vanessa Landazuri

Autonome Erfassung großskaliger Baustellenszenen mittels mobiler terrestrischer Laserscansysteme

In diesem Arbeitsschritt wird die automatisierte Erfassung vollständiger 3D-Punktwolken auf Außenbaustellen entwickelt, um hochaufgelöste, geometrisch konsistente Datensätze als Grundlage KI-basierter Auswertungen bereitzustellen. Statt zeit- und personalintensiver manueller Messungen mit stationären terrestrischen Laserscannern kombiniert das System einen hochpräzisen Laserscanner mit einer unbemannten, bodengebundenen Plattform (Shevkar/Fahrendholz-Heiermann 2024).

Der Scanner wird auf dem mobilen Träger montiert, der innerhalb definierter räumlicher Grenzen autonom navigiert und algorithmisch ausgewählte Scanpositionen anfährt, um bislang unzureichend erfasste Bereiche mit geringer Punktdichte gezielt abzudecken. In einem iterativen Zyklus aus Navigation, Scanaufnahme, Registrierung und Neubewertung werden die einzelnen Scans laufend vorverarbeitet, geometrisch ausgerichtet und zu einer konsolidierten Gesamtpunktwolke zusammengeführt. Dadurch lässt sich die Zahl der benötigten Scanpositionen deutlich reduzieren, ohne die geometrische Abdeckung zu verschlechtern, und aufwendige manuelle Nachregistrierung entfällt.


Die resultierende, konsistente Punktwolke steht unmittelbar nach Abschluss des Scanprozesses für weitere Analysen zur Verfügung und bildet die methodische Voraussetzung für die nachgelagerte Zielgeometrie-Extraktion sowie für objekt- und szenenorientierte KI-Verfahren. Die autonome Erfassung stellt damit einen zentralen Baustein der Gesamtpipeline und die Voraussetzung für die Übertragung der entwickelten Methoden auf reale Baustellenszenarien dar.

Generalisierungsfähige Zielgeometrie-Extraktion aus heterogenen 3D-Punktwolken mittels klassisch trainiertem Deep-Learning-Modell

Für die Auswertung von 3D-Punktwolken werden im Projekt zwei unterschiedliche Scanstrategien unterschieden. Beim objektorientierten Scannen wird ein konkretes Ziel erfasst. Die scannende Person richtet den Scan gezielt auf eine bekannte Struktur aus. Die Umgebung wird mit erfasst, steht jedoch nicht im Fokus der Auswertung. Beim szenenorientierten Scannen wird hingegen die vollständige Umgebung aufgenommen, ohne

dass vorab festgelegt ist, welche Strukturen später analysiert werden sollen. Abbildung 6 zeigt beispielhaft zwei Scanstrategien anhand von Aufnahmen der Referenzbaustelle „Campus Melaten Aachen“. Die Positionen des eingesetzten Laserscanners Riegl VZ-400i sind durch rote Markierungen dargestellt. Die Farbgebung der Punktwolken visualisiert die lokale Punktdichte, wobei geringe Dichten blau und hohe Dichten grün codiert sind.

Objektorientiertes Scannen



Szenenorientiertes Scannen




Abb. 6: Darstellung der verschiedenen Scanstrategien im Anwendungsfall; Quelle: Luca Fahrendholz-Heiermann

Der beschriebene Ansatz ist ein objektorientiertes Scanverfahren mit dem Ziel, die Zielgeometrie automatisch aus einer aufgenommenen Punktwolke zu extrahieren. Dabei kennt nur die ausführende Person das gescannte Objekt; das KI-System erhält ausschließlich die Punktwolke. Die Trennung von Ziel- und Umgebungsgeometrie erfolgt durch das überwacht trainierte

3D-Deep-Learning-Modell RandLaNet, das direkt auf der Punktwolke arbeitet und lokale geometrische Merkmale sowie räumliche Nachbarschaften nutzt, um zusammenhängende Strukturen zu segmentieren (Fahrendholz-Heiermann 2026).

Das Modell wird mit annotierten Punktwolken trainiert, die unterschiedliche Ausprägungen der Zielgeometrie und variierende Umgebungen abdecken, sodass es auch bei wechselnder Punktdichte und Erfassungsgeometrie robust segmentiert. Im Anschluss an die Segmentierung werden alle Zielpunkte aus der Gesamtpunktwolke isoliert und durch klassische geometrische Verarbeitung (Zusammenfassen zusammenhängender Bereiche,

Rauschreduktion) zu einer konsolidierten Teilpunktwolke zusammengeführt. Diese isolierte Geometrie steht für weiterführende Auswertungen, etwa geometrische Analysen oder Volumenberechnungen, zur Verfügung und eignet sich insbesondere für Anwendungen, in denen gezielt einzelne Strukturen automatisiert aus Punktwolken extrahiert werden sollen. Der beschriebene Ablauf der Zielgeometrie-Extraktion ist in Abbildung 7 exemplarisch dargestellt. Gezeigt wird ein objektorientierter Scan eines Schüttguthaufens sowie das Ergebnis der automatisierten Separation der Schüttgutgeometrie aus der umgebenden Punktwolke.

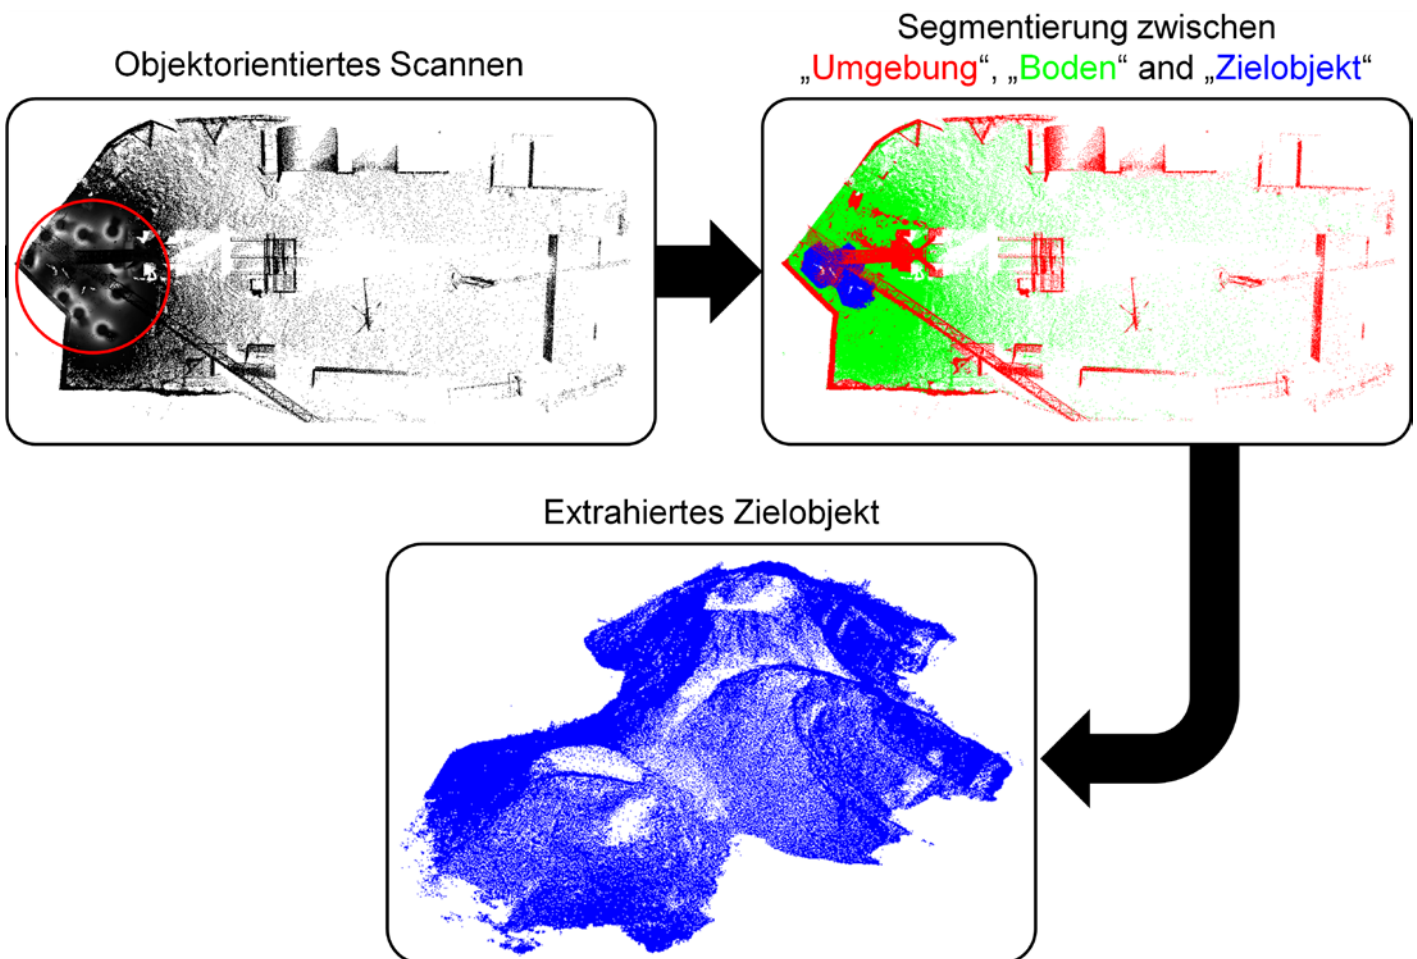


Abb. 7: Objektorientierter Scan eines Schüttguthaufens und resultierende Extraktion der Schüttgutgeometrie aus der 3D-Punktwolke; Quelle: Luca Fahrendholz-Heiermann

Trainingfreie Zielgeometrie-Extraktion aus szenenorientierten 3D-Punktwolken mittels Zero-Shot-Ansätzen

Beim szenenorientierten Scannen wird – im Gegensatz zum objektorientierten Ansatz – die gesamte Umgebung ohne Vorfestlegung auf bestimmte Zielstrukturen erfasst; welche Objekte relevant sind, wird erst nachträglich entschieden. Grundlage ist ein trainingfreier Ansatz zur Zielgeometrie-Extraktion, der vortrainierte Zero-Shot-Modelle der 2D-Bildverarbeitung (GroundingDINO und Segment Anything Model) nutzt, welche Objekte allein auf Basis textueller Beschreibungen identifizieren können, ohne zusätzliches Training.

Um diese Modelle für 3D-Punktwolken nutzbar zu machen, werden die Punktwolken zunächst von definierten Referenzpunkten aus in sphärische Darstellungen und anschließend in zylindrische Panoramabilder projiziert, wobei Tiefeninformationen integriert werden, um Konturen sichtbar zu machen. Die resultierenden Panoramen werden mit den Zero-Shot-Modellen zur Objekterkennung und anschließenden präzisen Segmentierung verarbeitet; die segmentierten Regionen werden danach in den 3D-Raum zurückprojiziert, sodass die entsprechenden Punkte in der Punktwolke als Zielgeometrie markiert sind (Abbildung 8).

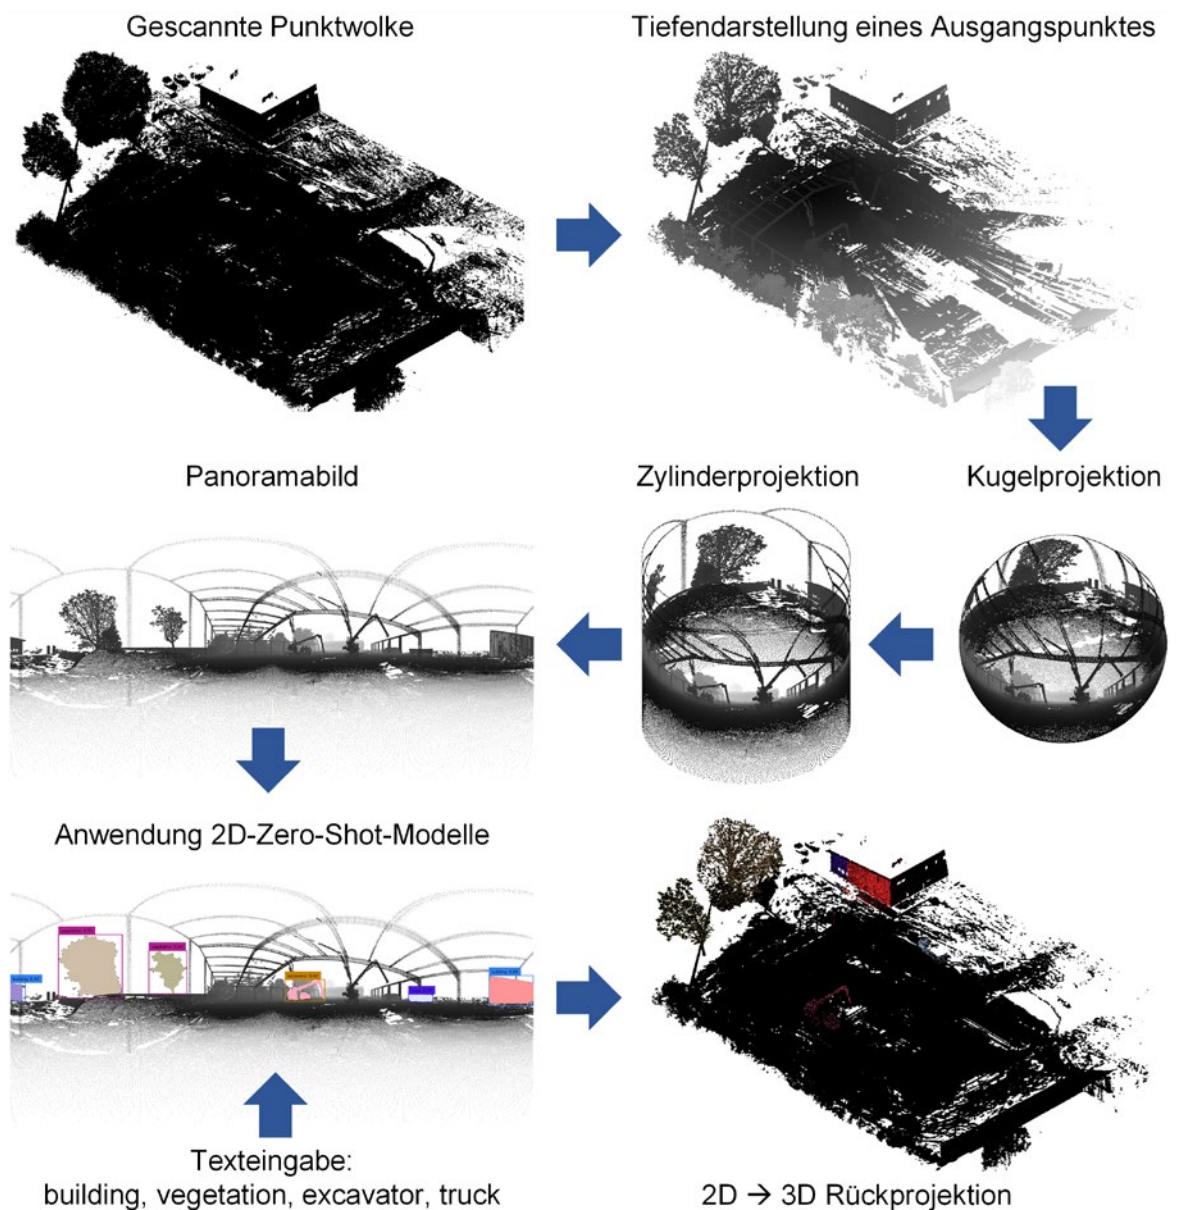


Abb. 8: Pipeline zur Anwendung von 2D-Zero-Shot-Modellen auf 3D-Punktwolken; Quelle: Luca Fahrenholz-Heiermann

3D-Rückprojektion aller Segmentierungen

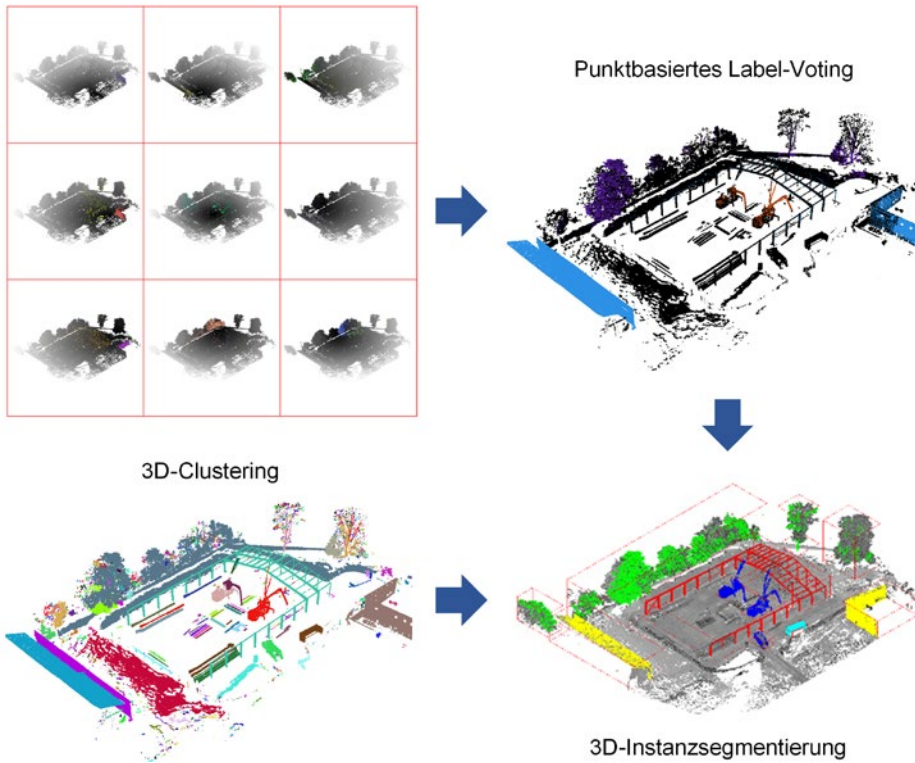


Abb. 9: Beispiel einer 3D-Instanzsegmentierung (unten rechts) durch Kombination der Rückprojektion der 2D-Segmentierungen in die 3D-Punktwolke (oben links) mit anschließendem punktbasierten Voting aller Labels (oben rechts) und 3D-Clustern (unten links);
Quelle: Luca Fahrenholz-Heiermann

Da eine einzelne Projektion nicht ausreicht, um alle Bereiche der Szene abzudecken, wird der Prozess mehrfach durchgeführt. Die Punktwolke wird dazu in ein 3D-Voxeligitter unterteilt. Die Mittelpunkte der Voxel dienen als Referenzpunkte für weitere Projektionen. Die Ergebnisse aller Projektionen werden zusammengeführt. Zur Konsolidierung der Ergebnisse wird ein punktbasiertes Voting eingesetzt. Jeder Punkt erhält das Label, das über alle Projektionen hinweg am häufigsten zugewiesen wurde. Anschließend erfolgt eine geometrische Clusterbildung, bei der zusammenhängende Punktbereiche identifiziert werden. Der Boden wird dabei separat behandelt, um die Objektsegmente klar abzugrenzen. Der gesamte Prozess der 3D-Instanzsegmentierung wird in Abbildung 9 schematisch dargestellt.

Das Ergebnis ist eine 3D-Instanzsegmentierung der Szene, bei der einzelne Objektgeometrien isoliert vorliegen. Die Methode erlaubt es, nachträglich gezielt nach bestimmten Strukturen in einer Szene zu suchen. Die extrahierten Geometrien können anschließend für weiterführende Analysen verwendet werden. Die Nutzung dieser Ergebnisse im Anwendungskontext wird in einem späteren Kapitel behandelt. Abbildung 10 zeigt das Ergebnis der szenenorientierten 3D-Instanzsegmentierung, bei der einzelne Objektgeometrien aus der Gesamtpunktwolke extrahiert und als separate Teilpunktwolken dargestellt werden (Fahrenholz-Heiermann 2026).




Abb. 10: Extraktion der klassifizierten Objekte aus der 3D-Punktwolke;
Quelle: Luca Fahrenholz-Heiermann

Übergreifende Bewertung

Zusammengefasst zeigen die erarbeiteten pragmatischen Lösungen komplementäre, aber konsistente Ergebnisse:

- Volumenbestimmung von Schüttgütern kann mit Multi-View-CNN/ViT und RGB-Kameras in den für die Praxis relevanten Genauigkeitsbereichen ohne teure 3D-Scanner umgesetzt werden.
- Die granulometrische Charakterisierung granularer Baustoffe (Korngrößenverteilung) ist mit SAM-basierter Segmentierung und ResNet50-Regression auf Basis 2D-Bilder mit hoher Präzision möglich, sofern Distanz- und Größenbereiche kontrolliert werden.
- Die Klassifikation von Baustoffen in ihrem Rohzustand kann mit modernen CNN-Architekturen (insbesondere DenseNet121) auch auf ressourcenbeschränkter Hardware und in Kombination mit ROS2-basierter Robotik zuverlässig in Echtzeit erfolgen.
- Die Zielgeometrie-Extraktion etabliert sich als zentrales methodisches Bindeglied aller Verfahren. Die konsequente Trennung von Zielgeometrie und Umgebung erhöht Robustheit, Wiederholbarkeit und Übertragbarkeit der nachgelagerten KI-Auswertungen.
- Die kombinierte Nutzung klassisch trainierter und trainingfreier KI-Ansätze ermöglicht eine robuste Abdeckung unterschiedlicher Anwendungsszenarien. Überwacht trainierte Modelle liefern stabile Ergebnisse für wiederkehrende Aufgaben, während Zero-Shot-Verfahren flexible, nachträgliche Analysen in szenenorientierten Datensätzen erlauben.

Damit liefern die Arbeiten nicht nur Nachweise für die technische Machbarkeit einzelner KI-Bausteine von „KI for BauChain“, sondern auch konkrete Kennzahlen zu erreichbarer Genauigkeit, Robustheit und Laufzeit unter realen Baustellenbedingungen, die für die weitere Systemintegration und die Auslegung eines durchgängigen digitalen Prozessabbilds der Baustofflogistik maßgeblich sind.

Nutzen für die Praxis

Die im vorigen Kapitel vorgestellten Arbeiten adressieren unterschiedliche, aber eng miteinander verknüpfte Teilprobleme der digitalen Baustofflogistik und zeigen, dass KI-basierte Bildverarbeitung bereits heute konkrete, praxisrelevante Mehrwerte liefern kann bei vergleichsweise geringen Investitionskosten und mit Hardware, die für die Branche realistisch verfügbar ist.

Im Folgenden wird der Nutzen für die Praxis jeweils dokumentbezogen und anschließend integrativ betrachtet.

Volumenbestimmung von Schüttgütern mit RGB-Kameras

Die wissenschaftliche Publikation: „Multi-View Approach for Bulk Material Volume Estimation“ zeigt, wie die bisher teure und personalintensive Volumenvermessung von Schüttgütern durch ein kostengünstiges, kamerabasiertes Verfahren ersetzt oder zumindest ergänzt werden kann. Daraus ergibt sich folgende nützlichen Aspekte für die Bauindustrie:

- **Einsparung von Spezialhardware und Personal**
Anstelle von terrestrischen Laserscannern oder UAV-LiDAR, die hohe Investitions- und Betriebskosten verursachen und spezialisiertes Personal erfordern, genügt eine handelsübliche RGB-Kamera zur Aufnahme mehrerer hochauflösender 2D-Ansichten der Halde. Dies senkt die Einstiegsbarrieren insbesondere für kleine und mittelgroße Unternehmen und ermöglicht eine häufigere beziehungsweise regelmäßige Bestandsaufnahme, weil die Vermessung nicht an den Einsatz externer Dienstleister gekoppelt ist.
- **Operativ ausreichende Genauigkeit („gut genug“) für Logistikerentscheidungen**
Die Volumenabschätzung mittels Multi-View-CNN und insbesondere Multi-View-Vision-Transformer erreicht im synthetischen und im Feldversuch Fehler, die im Bereich von wenigen Zehntel Kubikmetern liegen. Für viele operative Fragestellungen, zum Beispiel „Reicht der Sandhaufen noch für die nächsten zwei Tage?“ oder „Muss diese Woche nachbestellt werden?“, ist eine solche Genauigkeit hinreichend, ohne dass die extrem hohe Präzision eines Laserscanners benötigt wird. Damit wird eine wesentliche Lücke zwischen groben visuellen Schätzungen und hochpräziser 3D-Vermessung geschlossen.

→ **Unterstützung von Bestandsführung und Kosten-/Terminsteuerung**

Regelmäßige, auch von nicht-spezialisiertem Personal durchführbare Volumenmessungen ermöglichen eine engere Kopplung von Materialverbrauch, Lieferrhythmus und Baufortschritt und damit eine verlässlichere Termin- und Kostenplanung. Insbesondere die Reduktion unerkannter Materialengpässe oder Überbestände wirkt sich unmittelbar auf die Anzahl von Stillständen, Expressbestellungen und unnötigen Transporten aus.

Granulometrische Analyse und Materialprüfung vor Ort

Die Arbeit „Material Examination and Classification Using Computer Vision“ adressiert die granulometrische Charakterisierung (Korngrößenverteilung) von Baustoffen auf Basis von Bilddaten, ein Bereich, der traditionell Laborinfrastruktur und erhebliche Prüfzeiten erfordert. Aus der Arbeit ergeben sich folgende relevanten Praxisnutzen:

- **Alternative zu Siebversuchen und Laser-Diffraction im Feld**
Klassische Methoden der Korngrößenanalyse (Siebung, Laser-Diffraction) sind präzise, aber arbeits- und zeitaufwendig und erfordern stationäre Labore sowie geschultes Personal. Der vorgeschlagene Workflow aus SAM-Segmentierung, OpenCV-Feature-Extraktion und CNN-Regression erlaubt es, mittlere Korngröße μ und deren Standardabweichung σ allein aus Kamerabildern abzuleiten, ohne Zerstörung der Probe und mit deutlich verkürzter Durchlaufzeit.
- **Qualitätssicherung in Echtzeit**
Durch den Einsatz von Luxonis OAK-D Kameras und optimierten CNN-Modellen (ResNet50, VGG16) können Korngrößenkennwerte in Echtzeit direkt auf der Baustelle geschätzt werden. Damit wird zum Beispiel eine unmittelbare Prüfung möglich, ob geliefertes Zuschlagsmaterial dem spezifizierten Korngrößenspektrum entspricht oder ob Feinkornanteil und Kornform innerhalb zulässiger Toleranzen liegen. Dies reduziert das Risiko, ungeeignete Materialien in Mischungen einzubringen und nachträglich korrigieren zu müssen.

→ **Integration in autonome beziehungsweise halbautonome Systeme**

Die Arbeit zeigt, dass das System prinzipiell auf mobilen Robotern mit OAK-D Kamera betrieben werden kann, wodurch granulometrische Analysen in automatisierte Inspektionsrouten eingebunden werden können. Ein Robotersystem könnte etwa definierte Lagerplätze zyklisch anfahren und Daten zu Korngrößenverteilung und Materialtyp erfassen, die unmittelbar in ein digitales Materialmanagement einfließen.

Echtzeit-Materialklassifikation auf mobilen Plattformen

Die Arbeit „Development of a Computer-Based Vision System for Material Classification and Identification on Construction Sites“ adressiert die Frage, wie Rohbaustoffe bereits bei Anlieferung und Lagerung automatisiert erkannt und ihren Klassen zugeordnet werden können. Aus der Studie ergeben sich folgende konkrete Praxisnutzen für die Bauindustrie:

→ **Automatisierte Wareneingangskontrolle und Lagerdokumentation**

Das entwickelte System kombiniert eine OAK-D Pro Kamera, einen Raspberry Pi 4 und eine INNOK HEROS-Plattform mit einem CNN-Klassifikator (DenseNet121) und einer ROS2-basierten Kommunikationsarchitektur. Es ist in der Lage, verbreitete Rohbaustoffe (u. a. Bewehrungsstahl, Zement, Porenbeton, Hohlziegel, Hohlbetonsteine, Dachziegel, Sand, Kies, Lava-Granulat) mit Testgenauigkeiten von über 98 % im kontrollierten Umfeld und über 70 % in dynamischen On-Site-Tests zu identifizieren. In der Praxis können damit Wareneingänge automatisiert protokolliert, Lagerorte visuell erfasst und Materialbestände materialscharf in digitalen Systemen nachgeführt werden.

→ **Kosten- und ressourceneffiziente Automatisierung**

Es werden bewusst kostengünstige, handelsübliche Komponenten (OAK-D, Raspberry Pi, Standard-CPU auf Serverseite) eingesetzt, die auch unter Baustellenbedingungen robust arbeiten. Die hohe Klassifikationsleistung bei rein CPU-basierter Inferenz (ca. 0,06 s pro Bild für DenseNet121/ResNet50V2) zeigt, dass auf teure GPU-Infrastruktur verzichtet werden kann, was die Schwelle für eine breite Einführung senkt.

→ **Robuste Echtzeit-Funktion durch Systemlogik und Filtermechanismen**

Durch den vorgeschalteten MobileNet-Filter werden Frames mit Personen oder anderen Nicht-Baustoffobjekten verworfen, was die Zahl irrelevanter Klassifikationsanfragen reduziert und zugleich einen Beitrag zum Arbeitsschutz (Vermeidung ungewollter Personenanalyse) leistet. Ein Circular Buffer und eine Region-of-Interest-Logik (Sliding Window + Distanzfilter) sorgen dafür, dass bei begrenzter Rechenleistung immer die aktuellsten und relevantesten Bildausschnitte verarbeitet werden; die Frame-Drop-Rate konnte so deutlich reduziert werden, ohne die wahrgenommene Echtzeitfähigkeit zu beeinträchtigen.

→ **Grundlage für durchgängig digitale Materialflüsse**

Die Kombination aus RCMD-Datenbank, CNN-Klassifikator und ROS2-Systemarchitektur bietet einen direkt anschlussfähigen Baustein, um Materialidentitäten in BIM-Modelle, ERP-Systeme oder digitale Lieferscheine zu überführen. Dadurch wird der bislang medienbruchbelastete Übergang zwischen physischer Lieferung und digitaler Projektsteuerung geschlossen.

Integrativer Nutzen entlang der Baustofflogistik

In der Zusammenschau eröffnen die ausgeführten Arbeiten eine klare Perspektive für den praktischen Einsatz und gemeinsam bilden diese Bausteine die technische Grundlage, um die physische Realität der Baustoffströme, insbesondere für Schüttgüter, durchgängig sichtbar zu machen und in digital gestützte Prozesse einzubetten. Für die Praxis bedeutet dies konkret:

- Reduktion von Materialengpässen, Fehlbestellungen und Überbeständen
- Verringerung von Stillständen und Nacharbeiten durch verbesserte Materialverfügbarkeit und -qualität
- Senkung von Transportaufkommen und damit verbundenen Kosten und Emissionen
- Entlastung von Fachpersonal von manuellen, repetitiven Kontrolle- und Dokumentationsaufgaben

Damit liefern die vorgestellten Arbeiten am Lehrstuhl für Individualisierte Bauproduktion nicht nur technologische Demonstratoren, sondern belastbare Evidenz, dass KI-basierte Computer-Vision-Verfahren unter realen Baustellenbedingungen eingesetzt werden können und dort einen unmittelbaren, messbaren Nutzen entfalten.

Szenenorientierte Bestandsaufnahme und Lokalisierung von Ressourcen

Die kombinierte Anwendung der in den Abschnitten Generalisierungsfähige Zielgeometrie-Extraktion aus heterogenen 3D-Punktwolken mittels klassisch trainiertem Deep-Learning-Modell und Trainingfreie Zielgeometrie-Extraktion aus szenenorientierten 3D-Punktwolken mittels Zero-Shot-Ansätzen beschriebenen Methoden ermöglicht eine szenenorientierte, vollständig autonome Erfassung der Baustelle, bei der zunächst eine vollständige geometrische Momentaufnahme erzeugt wird, ohne zuvor bestimmte Zielobjekte festzulegen. Auf Basis dieser Daten können trainingfreie Zero-Shot-Verfahren eingesetzt werden, um nachträglich per Textanfrage gezielt nach Ressourcen wie Baumaschinen, Containern, Lagerflächen oder Materialansammlungen zu suchen, ohne erneute Scans oder Modellnachtrainings. Die gefundenen Objekte werden geometrisch isoliert, räumlich verortet und durch wiederholte Scans über die Zeit verfolgt, sodass Positions- und Bestandsänderungen sichtbar werden und Materialflüsse analysiert werden können. Praktische Nutzenaspekte sind insbesondere:

- Flexible nachträgliche Analyse ohne Vorabfestlegung auf Zielobjekte
- Räumliche Lokalisierung von Maschinen, Materialien und temporären Einrichtungen
- Unterstützung logistischer Planungs- und Dispositionsentscheidungen
- Mehrfachnutzung einmal erfasster Szenendaten für unterschiedliche Fragestellungen

Das Szenario ist besonders geeignet für komplexe, dynamische Baustellen mit häufig wechselnden Ressourcen und hohem Transparenzbedarf hinsichtlich der räumlichen Verteilung.

Wiederholte Mengenermittlung von Schüttgütern durch objektorientiertes autonomes Scannen

Das beschriebene Szenario nutzt eine zuvor erzeugte szenenorientierte Karte der Baustelle, um wiederkehrende Bestandsaufgaben gezielt objektorientiert auszuführen, insbesondere die zyklische Aktualisierung von Schüttgutmengen an bekannten Lagerplätzen. Ein autonomer mobiler Scanner navigiert dazu ausschließlich zu den bereits bekannten Positionen der Schüttgutlager, erfasst dort die Schüttgüter aus mehreren Blickrichtun-

gen und vermeidet so einen erneuten Vollscan der gesamten Baustelle. Die entstehende Punktwolke wird mit einem klassisch trainierten 3D-Deep-Learning-Modell verarbeitet, das die Schüttgutgeometrie automatisiert aus der Umgebung extrahiert; darauf aufbauend erfolgt eine aktualisierte Volumenberechnung. Ergänzend werden 2D-Projektionen der extrahierten Geometrie mit Zero-Shot-Modellen analysiert, um zu validieren, dass es sich weiterhin um Schüttgut handelt, ohne zusätzliche Trainingsläufe durchführen zu müssen. Praxisrelevante Vorteile sind eine zyklische Bestandsaktualisierung ohne vollständigen Szenenscan, eine automatisierte und methodisch konsistente Mengenermittlung, die Validierung der Zielgeometrie ohne erneutes Training sowie die deutliche Reduktion manueller Kontroll- und Dokumentationsaufwände. Das Szenario eignet sich insbesondere für Schüttgutlager mit regelmäßigem Materialumschlag, bei denen Mengenänderungen zeitnah in digitale Logistikprozesse übernommen werden müssen.

Methodik und Projektverlauf

Methodik

Methodisch verfolgt das ganze Projekt einen mehrspurigen Ansatz, der 2D-Bildverarbeitung, 3D-Punktwolkenanalyse, synthetische Datengenerierung und reale Felddaten systematisch kombiniert. Für die volumenbasierte Erfassung von Schüttgütern werden in Blender synthetische 3D-Haufen mittels Perlin-Noise erzeugt, aus denen ein großer Bilddatensatz generiert wird. Die Haufen werden mit dem Segment Anything Model (SAM) segmentiert und anschließend von einem Multi-View-CNN beziehungsweise einem Multi-View-Vision-Transformer verarbeitet, wobei beide Architekturen von Grund auf auf diesen Datensatz trainiert werden. Die Modelle werden schließlich mit Referenzvolumina aus 3D-Laserscans (Riegl VZ-400i) auf der Referenzbaustelle validiert.

Für die granulometrische Charakterisierung von Baustoffen werden hochauflösende RGB-Bilder von 20 verschiedenen Granulatprodukten (0,075–80 mm) unter kontrollierten Bedingungen aufgenommen, segmentiert (SAM) und mit OpenCV ausgewertet, um auf Einzelbildebene die mittlere Korngröße μ und Standardabweichung σ als Regressionslabels zu bestimmen. Auf dieser Grundlage werden verschiedene CNN-Architekturen (ResNet50, VGG16, Custom-CNN) trainiert und hinsichtlich MAE, MSE und R2 verglichen. Das leistungsfähigere Modell wird mittels OpenVINO auf einer OAK-D-Pro-Kamera eingesetzt und in Echtzeit getestet, wobei systematisch der Einfluss der Kameradistanz (150–1050 mm) auf die Vorhersagegüte untersucht wird.

Für die Klassifikation von Rohbaustoffen wird eine eigene Raw Construction Materials Database (RCMD) aufgebaut, deren Klassenstruktur an ÖKOBAUDAT angelehnt ist und neun typische Rohbaumaterialien unter realen Baustellenbedingungen (verschiedene Lagerzustände, Beleuchtungen, Hintergründe) abbildet. Darauf aufbauend werden VGG16, ResNet50V2 und DenseNet121 per Transfer Learning angepasst. Die Modelle werden zunächst offline evaluiert und anschließend in ein ROS2-basiertes System integriert, das eine OAK-D-Pro-Kamera, einen Raspberry Pi 4 und Innok-HEROS-Roboter umfasst.

Ergänzende Logikbausteine (MobileNet-Vorfilter für Nicht-Baustoffe, Circular Buffer, Sliding-Window-Regionen und Distanz-/Flächenfilter) dienen der Sicherstellung echtzeitfähiger und robusten Klassifikation in einer dynamischen Umgebung.

Aufbauend auf diesen Arbeiten werden zwei komplementäre Verfahren zur Zielgeometrie-Extraktion entwickelt. Zum einen wird eine klassisch trainierte 3D-Deep-Learning-Architektur, RandLaNet, eingesetzt, um im Rahmen objektorientierter Scanprozesse bekannte Zielgeometrien, insbesondere Schüttguthaufen, automatisiert aus Punktwolken zu extrahieren. Zum anderen wird eine trainingfreie Zero-Shot-Pipeline entworfen, bei der 3D-Punktwolken in panoramische 2D-Projektionen überführt, mit GroundedDINO textbasiert lokalisiert, mit SAM segmentiert und anschließend in den 3D-Raum zurückprojiziert werden. Die resultierenden Labels werden über mehrere Referenzpunkte hinweg aggregiert, mittels Voting konsolidiert und durch DBSCAN zu 3D-Instanzen zusammengeführt. Die so extrahierten Objektgeometrien bilden die Grundlage für eine nachgelagerte Analyse und gegebenenfalls eine feinere Klassifikation durch spezialisierte 3D-Netzwerke.

Projektverlauf

Zu Projektbeginn wurden RGB- und IR-Kameras beschafft, auf der Referenzbaustelle installiert und in Betrieb genommen, um sowohl das sichtbare als auch das Infrarotspektrum für die Detektion von Schüttgütern nutzbar zu machen. Aufgrund verzögerter Beschaffungsprozesse konnten die geplanten Kamera-basierten Arbeitspakete jedoch nicht in der ursprünglich vorgesehenen Reihenfolge gestartet werden, sodass einzelne algorithmische Arbeitspakete (AP3/AP4) vorgezogen und zunächst auf synthetischen Daten bearbeitet wurden. Parallel wurde der 3D-Laserscanner VZ-400i in Betrieb genommen und für Referenzmessungen auf der RWTH-Referenzbaustelle genutzt. Im weiteren Verlauf wurden zunächst die 2D-basierten Verfahren vollständig entwickelt und evaluiert: Für die Volumenbestimmung wurden synthetische Haufendatensätze generiert, SAM-basierte Segmentierungen implementiert und Multi-View-CNN/ViT-Modelle trainiert und anschließend durch Feldversuche gegen Laserscanner-Referenzen verifiziert. Für

die granulometrische Analyse wurden Bilddatensätze granularer Stoffe erzeugt, SAM+OpenCV-Pipelines zur Labelgenerierung, anschließend CNN-Regressoren entwickelt und in Labor- wie Feldversuchen (OAK-D-Pro) mit variierenden Distanzen erprobt. Parallel wurde die RCMD aufgebaut, annotiert und zur Ausbildung und Auswahl geeigneter Klassifikationsarchitekturen genutzt.

Der 3D-Strang wurde im Lauf des Projektes methodisch erweitert, indem der Fokus von einer reinen Punktwolkenklassifikation auf die automatisierte Extraktion von Zielgeometrien aus 3D-Punktwolken verschoben wurde. Hierzu wurden sowohl ein klassisch trainiertes 3D-Deep-Learning-Verfahren für objektorientierte Scanprozesse als auch ein trainingfreier Zero-Shot-Ansatz für szenenorientierte Analysen konzipiert und prototypisch umgesetzt. Aufgrund des hohen Aufwands für die Annotation der Punktwolken und der Komplexität des Hyperparametertunings liegen für diesen 3D-Strang zum jetzigen Zeitpunkt noch keine abschließenden Genauigkeits- oder Effizienzkennzahlen vor; der Fokus lag bislang auf Datengenerierung, Architekturwahl und Pipeline-Design.

Im weiteren Projektverlauf verzögerte sich die geplante Erfassung realer 3D-Punktwolken beim Industriepartner Leonhard Weiss GmbH aufgrund personeller Engpässe, sodass die Evaluierung der punktwolkenbasierten Verfahren auf die Referenzbaustelle und synthetische Szenarien beschränkt war. Vor diesem Hintergrund wurde der ursprünglich verfolgte Ansatz einer vollständig punktwolkenbasierten Schüttgutklassifikation mit PointNet++ zunächst zurückgestellt und ein vorgezogener, stärker anwendungsorientierter Arbeitspfad verfolgt, der auf der Kombination aus Zielgeometrie-Extraktion, Volumenbestimmung und trainingfreier Szenenanalyse basiert. Die verfügbaren Ressourcen wurden auf den Ausbau synthetischer Datengrundlagen, die Weiterentwicklung 2D-basierter KI-Verfahren sowie die Konzeption robuster 3D-Pipelines und deren Einbettung in das ROS2-System fokussiert, um trotz externer Randbedingungen belastbare und praxisrelevante Ergebnisse für Schüttgut-Identifikation und -Überwachung zu erzielen.

Literatur

Fahrendholz-Heiermann, J., 2026: Künstliche Intelligenz und 3D-Punktwolke zur Automatisierung der Prozessüberwachung und Qualitätskontrolle in der Bauindustrie, Dissertationsschrift, Lehrstuhl für Individualisierte Bauproduktion. Aachen.

Guo, B., 2024: Material Examination and Classification Using Computer Vision, Masterthesis, Lehrstuhl für Individualisierte Bauproduktion. Aachen.

Landazuri, V., 2024: Development of a Computer Based Vision System for Material Classification and Identification on Construction Sites, Masterthesis, Lehrstuhl für Individualisierte Bauproduktion. Aachen.

Picchi, D.; Brell-Cokcan, S., 2026: A multi-view approach for bulk material volume estimation. Construction Robotics, 10. Jg. (7). <https://doi.org/10.1007/s41693-026-00179-z>

Shevkar, P.; Fahrendholz-Heiermann, J., 2024: Autonomous 3D Scanning of Construction Sites Using Terrestrial Laser Scanner and UGV, 35. Forum Bauinformatik, fbi 2024: 163–170. <https://doi.org/10.15480/882.13544>

Projektbeteiligte

RWTH Aachen University,
Lehrstuhl für Individualisierte
Bauproduktion

Leonard Weiss GmbH

RIEGL International GmbH

Impressum

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

ZUKUNFT BAU
FORSCHUNGSFÖRDERUNG



Dieses Projekt wurde gefördert vom Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Auftrag des Bundesministeriums für Wohnen, Stadtentwicklung und Bauwesen (BMWSB) aus Mitteln des Innovationsprogramms Zukunft Bau.

Aktenzeichen: 10.08.18.7-22.15
Projektlaufzeit: 01.23 bis 12.25
Bundesmittel in €: 258.202,00

Zuwendungsempfängende:
Rheinisch-Westfälische
Technische Hochschule Aachen

Über Zukunft Bau

Mit dem Innovationsprogramm Zukunft Bau stärkt das BMWSB gemeinsam mit dem BBSR die Zukunfts- und Innovationsfähigkeit des Bausektors. Die Zukunft Bau Forschungsförderung schafft Vorbilder, die die Machbarkeit von neuen Ideen ausloten und die Baupraxis weiterentwickeln. Gefördert werden Forschungs- und Entwicklungsvorhaben, die einen Gebäudebezug als Schwerpunkt haben und einen substantiellen Beitrag zur Bewältigung aktueller und künftiger Herausforderungen im Baubereich erwarten lassen.

zukunftbau.de

Herausgeber

Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR)
im Bundesamt für Bauwesen und Raumordnung (BBR)
Deichmanns Aue 31–37
53179 Bonn

Wissenschaftliche Begleitung

Bundesinstitut für Bau-, Stadt- und Raumforschung
Referat WB 3 „Forschung und Innovation im Bauwesen“
Guido Hagel
guido.hagel@bbr.bund.de

Autorinnen und Autoren

Dr.-Ing. Davide Picchi 
RWTH Aachen University
Lehrstuhl für Individualisierte Bauproduktion
picchi@ip.rwth-aachen.de

Prof. Dr. techn. Sigrid Brell-Cokcan
RWTH Aachen University
Lehrstuhl für Individualisierte Bauproduktion

Lektorat

Prof. Dr. techn. Sigrid Brell-Cokcan

Stand

Dezember 2025

Grafisches Konzept

www.sans-serif.de

Gestaltung, Satz und Barrierefreiheit

www.nolte-kommunikation.de

Bildnachweis

Titelbild: Luca Fahrenholz-Heiermann

Vervielfältigung



Dieses Werk ist lizenziert unter der Creative Commons-Lizenz Attribution – Share Alike 4.0 (CC BY-SA 4.0). Diese Lizenz erlaubt unter Voraussetzung der Namensnennung des Urhebers und der Weitergabe unter gleichen Bedingungen die Bearbeitung, Vervielfältigung und Verbreitung des Materials in jedem Format oder Medium für beliebige Zwecke, auch kommerziell. Nähere Informationen zu dieser Lizenz finden sich unter: <https://creativecommons.org/licenses/by-sa/4.0/deed.de/>.

Die Bedingungen der Creative-Commons-Lizenz gelten nur für Originalmaterial. Die Wiederverwendung von Material aus anderen Quellen erfordert ggf. weitere Nutzungsgenehmigungen durch den jeweiligen Rechteinhaber.

Der Herausgeber übernimmt keine Gewähr für die Richtigkeit, die Genauigkeit und Vollständigkeit der Angaben sowie für die Beachtung privater Rechte Dritter. Die geäußerten Ansichten und Meinungen müssen nicht mit denen des Herausgebers übereinstimmen.

Zitierweise

Picchi, D.; Brell-Cokcan, S., 2026: KI for BauChain: KI-basierte Datenerfassung und -weiterverarbeitung für Baumaterial in einer digitalisierten Bauprozesskette. Herausgeber: BBSR – Bundesinstitut für Bau-, Stadt- und Raumforschung. Zukunft Bau – Forschung KOMPAKT 5/2026. Bonn.
<https://doi.org/10.58007/mete-f281>

Bonn 2026
ISSN 2944-067X

Dieses Werk ging aus folgendem Forschungsbericht hervor:

Picchi, D.; Fahrenholz-Heiermann, L., 2025: KI 4 BauChain: K.I. basierte Datenerfassung und -weiterverarbeitung für Baumaterial in einer digitalisierten Bauprozesskette. Lehrstuhl für Individualisierte Bauproduktion RWTH Aachen University. Aachen.

Hier geht es zum kostenfreien Forschungsbericht:

<https://doi.org/10.18154/RWTH-2026-00591>