

DeepSpaceBIM 4.1

Der digitale Bauassistent der Zukunft

Ergebnisse des Teilprojekts der Technischen Universität Darmstadt
Berichtszeitraum: 01.10.2018-31.08.2021



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Zuwendungsempfänger
Förderkennzeichen
Laufzeit des Vorhabens

Technische Universität Darmstadt
19F2057E
01.10.2018 bis 31.08.2021

Autoren des Berichts

Philipp Achenbach
Dr. Dirk Balfanz
Dr. Stefan Göbel
Dr. Cigdem Turan

Projektkonsortium des
Gesamtvorhabens

M.O.S.S. Computer Grafik Systeme GmbH
Robotic Eyes GmbH
DMT GmbH & Co. KG
Technische Universität Darmstadt
Steinmann Kauer Consulting GbR
Drees & Sommer

Das Verbundvorhaben „DeepSpaceBIM 4.1“, wurde mit Mitteln des Bundesministeriums für Verkehr und digitale Infrastruktur (BMVI) im Rahmen der Förderrichtlinie mFund (Modernitätsfonds) gefördert. In diesem Auszug des abschließenden Sachberichts werden die Arbeiten des Teilprojektes der Technischen Universität Darmstadt dargestellt. Die Verantwortung für den Inhalt des Berichts liegt bei den Autoren.

Gefördert durch:



Bundesministerium
für Verkehr und
digitale Infrastruktur

aufgrund eines Beschlusses
des Deutschen Bundestages

Darmstadt, im November 2021

Inhalt

1 Kurzdarstellung	3
1.1 Aufgabenstellung	3
1.2 Ausgangslage und Voraussetzungen.....	4
1.3 Planung und Ablauf des Vorhabens	5
1.3.1 Gliederung und Ablauf des Vorhabens	5
1.3.2 Zielerreichung und Präsentation der Ergebnisse im Projekt	6
1.4 Anknüpfung an den wissenschaftlichen und technischen Stand.....	7
1.4.1 SiGeKo-Trainingssimulation	7
1.4.2 Objekterkennung / „Bestandsaufnahme und Sicherheitsaspekte“	9
1.4.3 Baufortschrittserfassung.....	9
2 Eingehende Darstellung	10
2.1 Erzielte Ergebnisse.....	10
2.1.1 SiGeKo-Trainingssimulation	10
2.1.1.1 Methoden.....	10
2.1.1.2 Konzept I “Baustellensicherheit”	11
2.1.1.3 Konzept II “Gewerkeübergreifende Gefahren”	11
2.1.1.3 Konzept III “Baustellenbegehung”	12
2.1.1.4 Technische Validierung	12
2.1.2 Deep Learning	14
2.1.2.1 Grundlagen	15
2.1.2.2 Verwendete Methoden zur Objekterkennung	16
2.1.2.3 Verwendete Methoden zur Baufortschrittserfassung.....	18
2.1.2.4 Ergebnisse Objekterkennung	19
2.1.2.5 Ergebnisse Baufortschrittserfassung	19
2.1.2.6 Technische Validierung der Objekterkennung.....	21
2.1.2.7 Technische Validierung der Baufortschrittserfassung	21
2.1.3 Integration in den „Digitalen Bauassistenten“	22
A Anhang	23
A.1 Literatur	23
A.2 Bildverzeichnis	25

1 Kurzdarstellung

1.1 Aufgabenstellung

Bauen ist in hohem Maß von mobilen Szenarien geprägt. Die vor Ort verantwortlich Handelnden der Vertragsparteien sind bei komplexen Bauvorhaben insbesondere in akuten ad-hoc Entscheidungssituationen gestörter Arbeitsabläufe schnell an den menschlichen Möglichkeitengrenzen. Denn unter hohem Zeitdruck die große Anzahl abhängiger Abläufe sowie die gegenseitigen Beeinflussungen zu überschauen und umgehend sachgerechte, kostenminimale Korrekturentscheidungen zu treffen, ist praktisch zumeist nicht umsetzbar. Die für ein Bauvorhaben erforderlichen Informationen und Daten entstehen zeitgleich und zeitversetzt an unterschiedlichen Stellen (in der Zentrale und auf der Baustelle) und müssen für Besprechungen zur Koordinierung und Arbeitsvorbereitung an verschiedenen Orten in aktuellem Datenstand zugreifbar sein. Dieses Modernisierungspotenzial auf BIM-Baustellen wurde im Projekt durch vier Bestandteile eines „digitalen Bauassistenten“ aufgezeigt und als exemplarische Integration umgesetzt:

- „Deep Vis“ / Visualisierung von „vermessungsgenauen Augmented Reality (AR) BIM-Planungsdaten“: Durch die visuelle Überlagerung von 3D-Planungsdaten mit dem tatsächlichen Baubestand mittels AR sollte ein schneller Soll-Ist-Vergleich ermöglicht werden.
- „Deep Space“ / Multi-Cloud-Kopplung von 3D-GIS- und BIM-Daten: Ziel war es hier, den bidirektionalen Austausch von Daten aus beiden Welten zu ermöglichen und dadurch auf Basis bereits vorhandener Daten die Prozesse in der jeweils anderen Umgebung zu unterstützen.
- Sowie die von der Technischen Universität Darmstadt beigetragenen Bestandteile: „Deep Learning“ und „Deep SIM“ (Serious Gaming).

Im Bereich „**Serious Gaming**“ (**Deep SIM**) sollte es durch eine im Projekt entwickelte Software angehenden Sicherheits- und Gesundheitsschutzkoordinator*innen (SiGeKos) möglich sein, sich auf den bevorstehenden Alltag im Berufsleben vorzubereiten und Grundlagen für die anstehende Abschlussprüfung zu erwerben. Für bereits ausgebildete SiGeKos sollte sie zur Auffrischung dienen. Die SiGeKo-Trainingssimulation sollte weitergehend auch die allgemeine Sicherheitseinweisung auf Baustellen unterstützen und zur Erhöhung der Achtsamkeit für Aspekte der Sicherheit auf Baustellen beitragen.

Im Bereich „**Deep Learning**“ wurde untersucht, in welcher Weise Verantwortliche auf der Baustelle durch assistierende Verfahren des maschinellen Lernens (ML) / der künstlichen Intelligenz (KI) in ihren Entscheidungen unterstützt werden können. Im Fokus standen dabei die automatisierte Erkennung des Baustatus bzw. Baufortschritts und die Erkennung ggfs. (sicherheits-)kritischer Situationen im Bauinnenraum.

Konkret bearbeitete Fragestellungen im Bereich „Deep Learning“ waren:

- Objekterkennung / „Bestandsaufnahme und Sicherheitsaspekte“:
Hier ging es um das mobile, automatisierte Erfassen bestimmter Objekte/Objektklassen mit dem Ziel einen Bestandsstatus zu erstellen. Besondere Beachtung hatte im Projekt die Erkennung von sicherheitsrelevanten Sachverhalten bzw. Objekten auf der Baustelle.
- „Baufortschrittserfassung“:
Bei der Erfassung des Baufortschritts war das Ziel nicht die Erkennung von einzelnen Objekten, sondern das automatisierte Erkennen der gebauten Gebäudeelemente und der Abgleich mit den Plandaten z. B. aus dem BIM. Als exemplarisches Beispiel wurde im Projekt die Wanderkennung und die Erkennung von Durchbrüchen für Türen und Fenster gewählt.

Die nachfolgenden Darstellungen beziehen sich jeweils auf diese, durch die TU Darmstadt im Projekt vertretenen Themenbereiche.

1.2 Ausgangslage und Voraussetzungen

Das Baugewerbe ist nach wie vor einer der gefährlichsten Arbeitsbereiche. Laut Quellen der BG Bau ereignen sich auf deutschen Baustellen jede Woche ca. 2.100 Unfälle (Stand 2016/2017), von denen im Mittel sogar zwei einen tödlichen Verlauf nehmen [BGBAU2017]. Allein in Deutschland lag die Zahl der meldepflichtigen Arbeitsunfälle je 1000 Vollzeitbeschäftigte im Jahr 2019 bei über 57 [DGUV2020]. Neben dem Leid der Betroffenen und ihrer Angehörigen verursachen diese Vorfälle zudem jährliche Kosten in Höhe von 1,6 Milliarden Euro [BGBAU2017].

Um Risiken zu minimieren und ein sicheres Arbeitsumfeld zu schaffen dient ein breites Instrumentarium von gesetzlichen Vorgaben und Normen zur Organisation und Durchführung von Bauarbeiten, zu Maschinen und ihrer Verwendung sowie zu persönlichen Schutzmaßnahmen von am Bau Beschäftigten. Zu solchen Vorgaben gehören u. a. das Tragen von persönlicher Schutzausrüstung oder die Einhaltung von Arbeitsrichtlinien zur Nutzung von Werkzeug oder Maschinen. Die Beaufsichtigung der am Bau Beschäftigten hinsichtlich Einhaltung solcher Sicherheitsvorgaben durch Vorgesetzte oder spezielle Funktionsträger wie Sicherheits- und Gesundheitsschutzkoordinator*innen ist ein wesentliches Element zur Vermeidung von Unfällen. Dennoch kann dieses Monitoring nie lückenlos sein, zwangsläufig müssen der Aufmerksamkeit der Verantwortlichen immer wieder kritische, unfallträchtige Situationen entgehen. Hier setzt die Idee der technischen Unterstützung dieses Monitorings durch Verfahren der automatisierten Erkennung sicherheitsrelevanter Objekte oder Situationen an → Objekterkennung / „Bestandsaufnahme und Sicherheitsaspekte“.

Diese Möglichkeit einer (teil-)automatisierten Bestandsaufnahme gilt natürlich nicht nur für dedizierte Einzelobjekte, sondern ebenso für Gebäudebestandteile und könnte hier die heute noch aufwändigen Nacherfassungen (z. B. im Bestand oder im Baufortschritt) unterstützen und effizienter gestalten. Diesem Ansatz gehen wir nach in der → „Baufortschrittserfassung“.

Neben den Regularien für z. B. sichere Geräte und Verfahrensweisen und deren Beaufsichtigung nimmt die spezifische Schulung und Organisation des Baustellenpersonals eine zentrale Rolle zur vorausschauenden Unfallvermeidung ein. Als zwei Beispiele seien hier Australien und Deutschland

genannt: In Australien müssen Arbeiter*innen auf einer Baustelle eine Schulung absolvieren, die auf mögliche Gefahrenstellen einer Baustelle hinweist und als Sicherheitseinweisung dient. Als Zertifikat für diese Schulung erhalten die Arbeiter*innen die sogenannte "White Card", mit der sie berechtigt sind auf Baustellen zu arbeiten [WHITECARD2007, WHITECARD2020]. In Deutschland hingegen ist ab einer gewissen Baustellengröße ein sogenannter Sicherheits- und Gesundheitsschutzkoordinator, kurz SiGeKo, vorgeschrieben. Zu dessen Aufgaben gehört, das Bauvorhaben, den Bauablauf und die späteren Arbeiten an der baulichen Anlage zu jeder Zeit sicher zu gestalten.

Die Aufgabe von Sicherheits- und Gesundheitsschutzkoordinator*innen (SiGeKos) besteht darin, den Gesundheitsschutz der auf einer Baustelle anwesenden Personen zu überwachen und zu gewährleisten. Ein SiGeKo wird vom Bauherrn bestimmt und ist notwendig, wenn Personen aus unterschiedlichen Gewerken auf dem Bau tätig sind. Der Aufgabenbereich erstreckt sich über den Bereich der Planung und Ausführung des Bauvorhabens. Der SiGeKo ist definiert in den „Regeln zum Arbeitsschutz auf Baustellen (RAB)“ Nr. 30 (RAB 30) als Konkretisierung der Baustellenverordnung (§3 „Koordinierung“), entsprechend den Vorgaben des Bundesministeriums für Wirtschaft und Arbeit [BaustellV, RAB30]. Dazu gehört, erforderliche Maßnahmen der Arbeitssicherheit und des Gesundheitsschutzes im sogenannten SiGe-Plan festzulegen, zu koordinieren und ihre Einhaltung zu überprüfen. Die Aufgaben des SiGeKo können beispielsweise von Architekt*innen, Ingenieur*innen oder staatlich geprüften Techniker*innen übernommen werden. Sie müssen aber über die in RAB 30, Ziffer 4 und 5 definierten Qualifikationen und Nachweise verfügen. Dazu gehören baufachliche Kenntnisse, arbeitsschutzfachliche Kenntnisse und Koordinatorenkenntnisse, sowie berufliche Erfahrung in Planung und/oder Ausführung von Bauvorhaben. In RAB 30, Ziffer 4, heißt es u. a.: „Er [der SiGeKo] muss die Fähigkeit besitzen, Arbeitsabläufe systematisch, vorausschauend und gewerkeübergreifend zu durchdenken, sich anbahnende Gefährdungen zu erkennen und die gebotenen Koordinierungsmaßnahmen zu treffen.“ Hier setzt unser Konzept einer technischen Trainingsumgebung für SiGeKos an → SiGeKo-Trainingssimulation.

1.3 Planung und Ablauf des Vorhabens

1.3.1 Gliederung und Ablauf des Vorhabens

DeepSpaceBIM startete am 01.10.2018 und arbeitete bis zum 31.08.2021, inkl. einer 3-monatigen, kostenneutralen Projektverlängerung aufgrund der erschwerenden Randbedingungen durch die COVID-19 Pandemie. Der zeitliche Ablauf des Projektes wurde an den Projektmeilensteinen ausgerichtet:

- Meilenstein M1 (01.10.2018): Projektstart
- Meilenstein M2 (April 2019): Analyse der IST-Situation und Anforderungsspezifikation
- Meilenstein M3 (Mai 2020):
Präsentation integrationsfähiger Teilkomponenten (Beta) für den „Digitalen Bauassistenten“
- Meilenstein M4 (Mai 2021): Präsentation „Digitaler Bauassistent“
- Meilenstein M5 (31.08.2021): Projektabschluss

Inhaltlich strukturiert wurde die Projektarbeit zum einen durch die in Abschnitt 1.1 genannten vier Kernthemen, zum anderen durch fünf Use Cases, welche die Unterstützung des Bauprozesses

durch den digitalen Assistenten in unterschiedlichen Bau-Phasen und Situationen konzipierten und präzisierten. Diese Use Cases beinhalten entsprechend die Umsetzung und Integration der genannten vier Kernthemen:

- Use Case 1: Variantenassistent
- Use Case 2: Vermessungsassistent
- Use Case 3: Serious Gaming
- Use Case 4: Baufortschrittskontrolle
- Use Case 5: Deep Learning

Die SiGeKo-Trainingssimulation (Bereich „Deep SIM“) wurde hierbei im Use Case 3 umgesetzt. Der Bereich „Deep Learning“ untersuchte parallel über alle Projektphasen hinweg im Use Case 5 die Möglichkeiten für assistierende Verfahren des maschinellen Lernens (ML) / der künstlichen Intelligenz (KI) in verschiedenen Anwendungsbereichen. Als Projektergebnis zum Meilenstein 2 wurden die identifizierten, erfolgversprechenden Ansätze der KI-Assistenz im weiteren Projektverlauf für die Anforderungen des Use Case 4 entwickelt und dort insbesondere in den digitalen Bauassistenten integriert.

Der Abgleich der Projektansätze und Zwischenergebnisse mit potenziellen Nutzungsszenarien fand anhand mehrere Beispielprojekte im Rahmen von, über die Projektlaufzeit verteilten, Reality Checks statt. Drei Reality Checks wurden bis zum Meilenstein M3 durchgeführt (Serie A), drei weitere bis zum Meilenstein M4 (Serie B). Die dabei genutzten Beispielprojekte umfassten ein städtebauliches Projekt bei Frankfurt (Innovationscampus Spring Park Valley), den Forschungs- und Industriepark TXL Urban Tech Republik auf dem Gelände des ehemaligen Flughafens Berlin Tegel, Büro- und Industriegebäude „Obere Waldplätze“ in Stuttgart Vaihingen, die Planung einer Flugfelderweiterung am Flughafen München und Windparkplanung.

1.3.2 Zielerreichung und Präsentation der Ergebnisse im Projekt

Die im vorigen Abschnitt dargestellten Projekt-Meilensteine wurden für das Gesamtprojekt sowie für das Teilvorhaben der TU Darmstadt fristgerecht und erfolgreich erreicht. Die dargestellte Planung entspricht der corona-bedingten kostenneutral um drei Monate verlängerten Projektlaufzeit. Gegenüber der ursprünglichen Planung waren hier nur die Meilensteine M4 um plus zwei Monate und M5 entsprechend um plus drei Monate angepasst. Die Themen der TU Darmstadt waren dabei wie folgt vertreten:

- Reality Check A.1 in Frankfurt/Bad Vilbel (August 2019, Fokus Spring Park Valley): Vorstellung der ersten grundlegenden Ansätze zur SiGeKo-Trainingssimulation (Use Case 3) und der Untersuchungsrichtungen bzgl. möglicher KI-Unterstützung (Use Case 5)
- Reality Check A.2 in Berlin (Januar 2020, Fokus TXL Urban Tech Republic): Keine Beteiligung der TU Darmstadt.
- Reality Check A.3 corona-bedingt virtuell (April 2020, Fokus auf Baustelle „Obere Waldplätze“ in Stuttgart): Vorstellung der Konzepte zur SiGeKo-Trainingssimulation (Use Case 3); Vorstellung erster erzielter Ergebnisse zur Baufortschrittskontrolle und Kontrolle des Rohbaus und der angedachten Unterstützung durch KI zusammen mit dem Partner Robotic Eyes (Use Case 4, Use Case 5).

- Reality Check B.1 corona-bedingt virtuell (März 2021): Fokus-Workshop zur detaillierten Vorstellung und Diskussion der SiGeKo-Trainingssimulation.
- Reality Check B.2 corona-bedingt virtuell (Januar 2021, Fokus auf Infrastrukturgroßprojekte am Beispiel eines Windrads/Windparks): Vorstellung des Status zur Baufortschrittskontrolle und Kontrolle des Rohbaus inkl. KI-Integration durch den Partner Robotic Eyes (Use Case 4), keine Beteiligung der TU Darmstadt.
- Reality Check B.3, corona-bedingt hybrid Stuttgart/virtuell (Mai 2021, Fokus auf Baustelle „Obere Waldplätze“ in Stuttgart): Detaillierte Vorstellung der Projektergebnisse zur SiGeKo-Trainingssimulation (Use Case 3). Detaillierte Vorstellung der Projektergebnisse zur Baufortschrittskontrolle und Kontrolle des Rohbaus sowie der integrierten Unterstützung durch KI zusammen mit dem Partner Robotic Eyes (Use Case 4, Use Case 5).

1.4 Anknüpfung an den wissenschaftlichen und technischen Stand

1.4.1 SiGeKo-Trainingssimulation

Unter *“Serious Games”* (englisch für ernsthafte Spiele) versteht man digitale Spiele, die neben der Unterhaltung noch mindestens einen weiteren Zweck verfolgen, das *“characterizing goal”*. Dieses Ziel kann beispielsweise ein bestimmter Lerneffekt sein, eine Verhaltensänderung (beispielsweise in Bezug auf den Lebensstil, Bewegung oder Ernährung) oder das Ziel, für gesellschaftlich relevante Themen wie Sicherheit, Klima oder Energie zu sensibilisieren. Genre, Technologie, Plattform und Zielgruppe sind nicht näher definiert und variieren.

Das Verhältnis der Unterhaltungsaspekte zu den Aspekten des charakterisierenden Ziels sollte dabei generell ausgeglichen sein, da die Inhalte authentisch und glaubwürdig, aber auch unterhaltsam vermittelt werden sollen. Formale Vorgaben in Abgrenzung zu reinen Unterhaltungsspielen sind aber nur schwer möglich.



Abbildung 1:
Ausschnitt aus dem White-Card-Game, bei dem der Spieler gerade eine Gefahrenstelle melden soll. (Quelle: [O'Rourke 2014])

Ziel der SiGeKo-Trainingssimulation war die Entwicklung eines Serious Games für den Bereich Baustellensicherheit, genauer für das Training von Sicherheits- und Gesundheitsschutzkoordinatoren (SiGeKo). Diese Trainingssimulation soll sie in ihrer Vorbereitung auf die vorgeschriebenen Prüfungen zum SiGeKo unterstützen und sie auf den bevorstehenden Alltag im Berufsleben einstimmen. Daneben sollte sie auch in der allgemeinen Sicherheits- einweisung auf Baustellen und der Erhöhung der Achtsamkeit in Bezug auf Sicherheit auf Baustellen behilflich sein.

Wie bereits erwähnt benötigt in Australien jeder Baustellenmitarbeiter ein Zertifikat, welches bescheinigt, dass die Arbeiter*innen eine Schulung in Baustellensicherheit erhalten haben, die *“White Card”*. Zum besseren Training und zu Schulungszwecken hat die Victoria University (Australien) das *“White Card Game”* entwickelt. Bei diesem schlüpfen die Spielenden in die Rolle

einer Bauarbeiterin, die neu auf einer Baustelle beginnt. Nach einer kurzen Einweisung besteht die Aufgabe darin, Gefahrenstellen zu identifizieren und Vorschläge zur Behebung der Gefahren zu geben. Kurze Animationen visualisieren, welche Konsequenzen auftreten, wenn eine Gefahrenstelle nicht oder nicht rechtzeitig behoben werden kann. Nach erfolgreicher Behebung der Gefahrenstelle, muss diese noch an die verantwortliche Person (z. B. die Vorarbeiterin) berichtet werden. Das Spiel will damit nicht nur erreichen, dass die Spielenden wachsamer in Bezug auf mögliche Gefahrenstellen werden, sondern trainiert auch, solche Vorgänge der richtigen Ansprechperson zu melden [O'Rourke2014].



Abbildung 2: Ausschnitt aus dem Spiel Trouble Tower in welchem der Spieler gerade mit dem richtigen Feuerlöscher einen Brand löschen muss. (Quelle: [Greuter2013])

Eine weitere australische Universität, die RMIT University Melbourne, hat das Computerspiel „Trouble Tower“ entwickelt. Dies widmet sich der Baustellensicherheit im Allgemeinen und ist auf kein spezielles Gewerk oder spezielle Funktionen ausgerichtet. Ziel ist es Studierende der Bauindustrie zu motivieren, etwas über die Gefahren auf Baustellen und deren Bewältigung durch Anwendung von Arbeitsschutzmaßnahmen zu lernen. Der Unterricht im Klassenzimmer ist dabei oft nicht ansprechend und wirksam genug und wird dann leider später häufig durch das Lernen aus Erfahrung, also das Lernen am (eigenen) Schadenfall ergänzt.

Die Entwickler konfrontieren daher in diesem Quiz die Spielenden mit den 30 häufigsten Gefahren auf Baustellen. Die Spielenden müssen auf einer virtuellen Baustelle (dem Trouble Tower) Gefahren analysieren und durch die Anwendung von Arbeitsschutzkontrollen beseitigen. Die Lösung der jeweiligen Aufgaben ist dabei nicht immer eindeutig und situationsabhängig. So kann zum Beispiel ein Feuerlöscher auf Wasserbasis einen Papierbrand löschen und hier die Brandgefahr beseitigen, gleichzeitig aber auch bei einem elektrischen Brand selbst eine zusätzliche Gefahr durch Stromschläge darstellen. Um das aktuelle Level zu beenden, müssen die Spielenden sämtliche Gefahren melden, da auch im realen Baustellenbetrieb das Baustellenpersonal angehalten ist, (alle) Gefahren zu melden. Durch diese Meldung erhalten die Spielenden einen Überblick über die gesamte Gefahrenlage und ein Feedback. Um die Gefahrensituationen besser einschätzen zu können, geben adaptierte Anweisungen zu sicheren Arbeitsmethoden und Sicherheitsdatenblättern Hinweise zur Lösung der jeweiligen Probleme. Die Hinweise beinhalten auch Bilder der Gefahren, damit ein Bezug zur Realität hergestellt werden kann und eine höhere Eindringlichkeit erzielt wird. Um die Spiel-Leistung zu bewerten, bekommen die Spielenden auf der linken Seite des Bildschirms die aktuelle Produktionsleistung der Baustelle angezeigt. Durch Behebung von Gefahrenstellen steigt diese, so dass der Zusammenhang zwischen Gefahrenkontrolle und Produktivität verstärkt wird. [Greuter2013]

1.4.2 Objekterkennung / „Bestandsaufnahme und Sicherheitsaspekte“

Die Beaufsichtigung der am Bau Beschäftigten hinsichtlich Einhaltung solcher Sicherheitsvorgaben durch Vorgesetzte oder spezielle Funktionsträger wie Sicherheits- und Gesundheitsschutzkoordinator*innen ist ein wesentliches Element zur Vermeidung von Unfällen. Dennoch kann dieses Monitoring nie lückenlos sein, zwangsläufig müssen der Aufmerksamkeit der Verantwortlichen immer wieder kritische, unfallträchtige Situationen entgehen.

Technische Unterstützung dieses Monitorings wurde daher bereits früh als ein mögliches Anwendungsgebiet von künstlicher Intelligenz und digitaler Bildverarbeitung gesehen. Im Fokus von Forschungsarbeiten standen u. a. Methoden zur Erkennung und Überwachung des Einsatzes von Sicherheitsausrüstung. In [Wang2019] wurden Computer-Vision- und Deep-Learning-Techniken eingesetzt, um die Interaktion zwischen Arbeiter*innen und Ausrüstung zu überwachen. Es wurde versucht Gefahrenzonen zu identifizieren und aus den Aufenthaltsorten der Arbeitenden und ihrer Bewegungsrichtung Rückschlüsse auf eine Gefährdung zu ziehen. In [Jeelani2018] wurde die Verwendung visuell basierter Analysen untersucht, um die Leistung der Arbeiter*innen bei der Gefahrenerkennung zu verstehen, so dass ein Feedback für ein personalisiertes Training gegeben werden kann. [Delhi2020] entwickelten ein Framework, um die Einhaltung der Vorschriften für persönliche Schutzausrüstung durch Arbeitende in Echtzeit zu erkennen. Hierbei wurden vorab trainierte Modelle (neuronale Netze) verwendet.

Die Notwendigkeit zur Echtzeiterkennung von sicherheitsrelevanten Objekten und Ausrüstungsgegenständen präferiert die Verwendung Bilddaten gegenüber Punktwolken, da letztere eine hohe Rechenleistung erfordern. Zudem sind Objekte aufgrund der begrenzten Dichte der Punktwolken oft nicht hinreichend sicher identifizierbar. Obwohl wir die Verwendung von Punktwolken zur Erkennung flächiger Bauteile der Baustelle, wie Wände und Decken sowie von Wandöffnungen für Türen und Fenster untersucht haben, haben wir uns deshalb entschieden, zur Erkennung sicherheitsrelevanter Objekte Bilder zu verwenden. Es wurde ein schnelles und einbettbares neuronales Modell entwickelt, welches die Integration der Objekterkennung in eine mobile Echtzeit-Anwendung ermöglicht. Der Algorithmus, der während des Trainingsprozesses des Erkennungsmodells angewandt wird, erlaubt es, das Modell um neue Objektklassen zu erweitern.

1.4.3 Baufortschrittserfassung

Die zunehmende Verfügbarkeit digitaler Gebäudedaten, d. h. sowohl digitaler Planungsdaten wie in BIM-Modellen als auch im Baufortschritt erfasster digitaler Daten bietet heute prinzipiell geeignete Voraussetzungen für die Anwendung neuester, datenintensiver Auswerteverfahren zum (teil-) automatischen Monitoring des Baufortschritts auf Baustellen. Wie im vorigen Abschnitt dargestellt, lassen sich mittels Verfahren der Computer Vision echtzeitfähige Bildauswertungsalgorithmen zur Objekterkennung erstellen. Datentypen wie 3D-Punktwolken enthalten demgegenüber insbesondere wertvolle Geometrieinformation, die ggü. der direkten Nutzung von 2D-Bildern bessere Aussagen über die über räumliche Ausprägung von Gebäudeelementen oder (größeren) Objekten erlauben. Wenn BIM-Daten vorliegen, die den aktuellen Soll-Zustand eines Gebäudes darstellen, können diese für die automatische Analyse des Baufortschritts als Referenz verwendet werden. In der Literatur gibt es eine Reihe von Studien, die Geometrieinformationen aus 3D-Vermessungen auf

Baustellen einbeziehen, um den Fortschritt zu überwachen [Kim2013, Lin2019] sowie die Klassifizierung mit Geometrieinformationen zu verbessern [Yuan2020].

In DeepSpaceBIM haben wir Ansätze wie in den bestehenden Studien weiterentwickelt und einen Algorithmus entwickelt, der 3D-Punktwolkendaten nutzt um Wanddurchbrüche, d. h. „Löcher“ für Fenster und Türen auf der Baustelle zu erkennen und zu vermessen. Dies erlaubt es, die Lage der Wandöffnungen mit den BIM-Daten zu vergleichen und ihre korrekte Lokalisierung bzgl. der Gebäudeteile und ihre Positions- und Größengenauigkeit zu beurteilen.

2 Eingehende Darstellung

2.1 Erzielte Ergebnisse

2.1.1 SiGeKo-Trainingssimulation

Eine SiGeKo-Trainingssimulation soll der Ausbildung, Weiterbildung und dem Training von Sicherheits- und Gesundheitsschutzkoordinator*innen (SiGeKos) dienen. Im Projekt sollte auch überprüft werden, ob eine Verwendung zur allgemeinen Sicherheitseinweisung auf Baustellen und zur Erhöhung der Achtsamkeit in Bezug auf die Baustellensicherheit in Frage käme. Die Software an sich sollte einfach auf marktüblichen Computersystemen zu installieren sein und einfach zu bedienen sein, so dass auf eine zusätzliche Einführung in die Benutzung des Programms verzichtet werden könnte. Die Mitarbeiter der Forschungsgruppe „Serious Games“ der Technischen Universität Darmstadt haben daher verschiedene Konzepte entworfen, wie diese Anforderungen erfüllt werden können. Zum Zwecke der Evaluation dieser Konzepte wurden in Zusammenarbeit mit Drees & Sommer drei Workshops mit SiGeKos organisiert.

2.1.1.1 Methoden

In einem iterativen und agilen Gesamtansatz haben wir nach ersten Recherchen die besten Ansätze aus bereits bestehenden Serious Games im Bereich Baustellensicherheit ausgewählt, um sie auf das uns vorliegenden Anwendungsszenario einer SiGeKo-Trainingssimulation anzuwenden.

Unsere Gestaltungs-Annahme war hierbei, dass die angehenden SiGeKos die Simulation alleine in einer ruhigen Umgebung benutzen und die Simulation als Vorbereitung für die Abschlussprüfung oder als Training für die Arbeit auf der Baustelle dient. Grundkenntnisse im Umgang mit Computerprogrammen und -spielen werden vorausgesetzt, sodass lediglich Einführungen in für unser Konzept relevante Mechanismen nötig sind.

Im Abschluss jeder iterativen Konzept- und Entwicklungsphase wurde ein Workshop mit SiGeKos durchgeführt. Ihre Berufserfahrung im tatsächlichen Arbeitsablauf von SiGeKos erlaubte wertvolles, qualitatives Feedback über die vermittelten Inhalte. Feedback über Spielsteuerung, Spielkonzept und Spielumsetzung wurde zusätzlich sukzessive und entwicklungsbegleitend innerhalb der Forschungsgruppe durch Testspieler*innen eingeholt. Insgesamt fanden drei Iterationszyklen statt in welcher die initiale Spielidee verbessert und an die Bedürfnisse der SiGeKos angepasst wurde.

Konkret wurden im Rahmen des Projektes DeepSpaceBIM 4.1 nachfolgende drei Konzepte getestet und evaluiert (Abschnitte 2.1.1.2 bis 2.1.1.4).

2.1.1.2 Konzept I “Baustellensicherheit”

Das erste Konzept orientierte sich stark an der Spielmechanik des bereits vorgestellten Spiels “White Card Game”. Die Trainingsumgebung soll hier einer realen Baustelle entsprechen.



Abbildung 3: Ausschnitt aus der prototypischen Umsetzung von Konzept I, hier zu sehen der Fragendialog bei einer identifizierten Gefahrenstelle. (Quelle: TU Darmstadt)

Die Benutzerin kann sich zu einem festen Zeitpunkt frei in einer virtuellen, dreidimensionalen Baustelle bewegen und die Baustelle inspizieren. Wird eine potenzielle Gefahrenstelle oder ein Fall von Regelverstoß gegen die im SiGe-Plan definierten Arbeitsschutzrichtlinien entdeckt, so kann sie diese markieren. Ein Overlay öffnet sich und ermöglicht per Multiple-Choice auszuwählen, welches Fehlverhalten vorliegt bzw. wie die Gefahrenquelle zu beseitigen ist. Beispiele solcher Gefahrensituationen wären Arbeiter*innen ohne Helm oder ohne festes Schuhwerk, fehlende bzw. ungenügende Absperrung der Baustelle oder Mängel an Gerüsten. Die Gefahrenstellen richten sich nach BG Bau und stellen Sicherheitsaspekte einer Baustelle im Allgemeinen dar. Ein angehender SiGeKo kann sich so auf die bevorstehenden Prüfungen vorbereiten. Ebenso können ausgebildete SiGeKos ihr Wissen auffrischen.

2.1.1.3 Konzept II “Gewerkeübergreifende Gefahren”

Durch das Feedback des ersten Workshops konnten wir erfahren, dass dieses Konzept eine gute Schul- und Trainingssoftware für Baustellensicherheit im Allgemeinen darstellt und daher gut für die Sicherheitsanweisung aller Baustellenarbeiter*innen dienen könnte. Aufgrund des zugrunde gelegten allgemeinen Gefahrenstellenkatalogs der BG BAU [BGBAU], konnten jedoch spezielle Aspekte des für SiGeKos relevanten Inhaltes nicht richtig vermittelt werden. Dies betrifft in erster Linie den planerischen und vorausschauenden Ansatz. Wir haben daher ein weiteres Konzept entworfen, bei welchem die SiGeKos eine Baustelle von Anfang bis Ende betreuen und die auf der Baustelle tätigen Gewerke überwachen und koordinieren. Gewerke und gewerkeübergreifende

Gefahren sind hierbei abstrahiert dargestellt. Im Vergleich zum ersten Konzept verfolgt dieses Konzept einen strategischen Ansatz und wird aus der Vogelperspektive gespielt.



Abbildung 4: Ausschnitt aus der prototypischen Umsetzung von Konzept II, hier zu sehen der eingestellte bevorzugte Weg zu den Sanitärbereich für das Gewerk der Glaser. (Quelle: TU Darmstadt)

2.1.1.3 Konzept III “Baustellenbegehung”

In einem letzten Schritt, als Synthese der vorangegangenen Konzepte, haben wir zur Abschwächung der starken Abstraktion von Gewerken und gewerkeübergreifenden Gefahren im Konzept II unseren dritten Ansatz wieder stärker an das erste Konzept angelehnt. Es wurden dazu mehr gewerkeübergreifende Gefahren nach Konzept II integriert und ebenso Muster-Baustellen nach realem Vorbild verwendet.

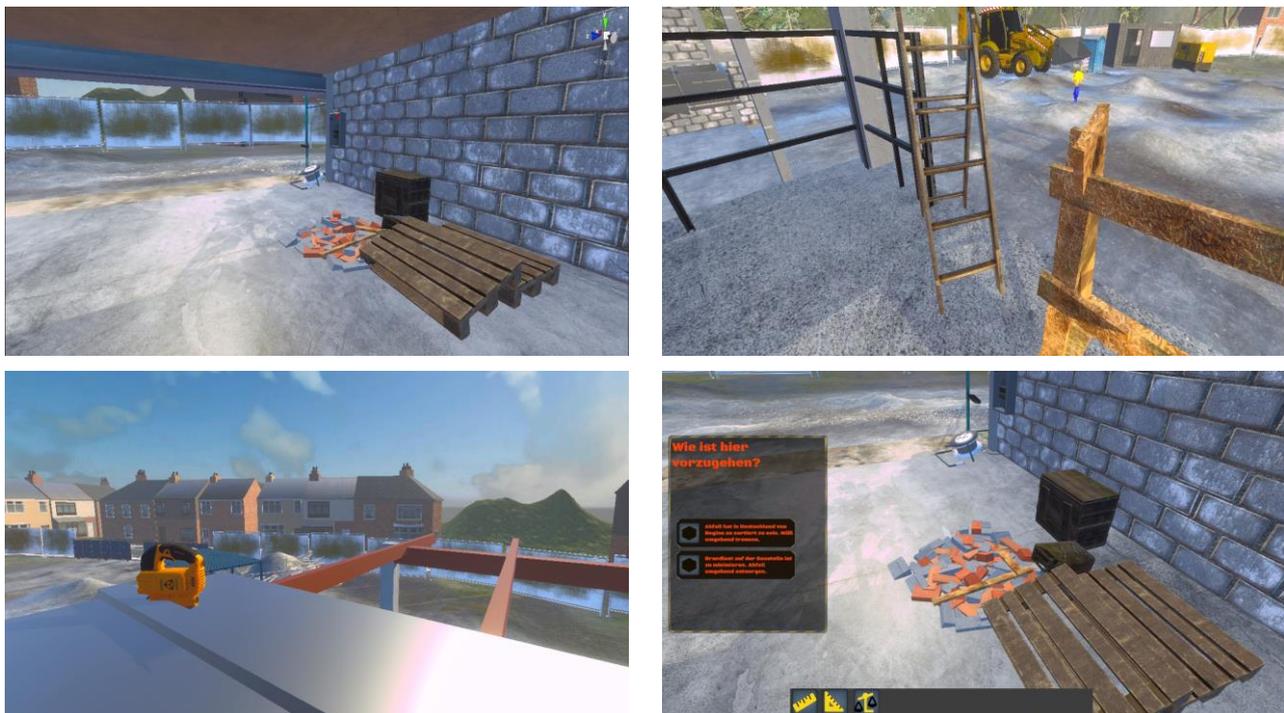


Abbildung 5: Ausschnitt aus der prototypischen Umsetzung von Konzept III, hier zu sehen einige Gefahrenstellen + Fragendialog. (Quelle: TU Darmstadt)

Für die Gefahrenstellen wurden nun nicht nur ausschließlich Gefahren nach BG Bau verwendet, sondern auch reale Gefahrenstellen aus SiGeKo-Protokollen geschildert. Vor dem Hintergrund der „Musterbaustellen“ haben wir darüber hinaus untersucht inwieweit sich diese realitätsnah

automatisiert generieren lassen, auf der Grundlage von BIM-Modellen existierender Baustellen [Kastner-Guhl2020].

2.1.1.4 Technische Validierung

Wie dargestellt, wurden im Zuge dreier projektbegleitender Workshops prototypische Umsetzungen der vorgestellten Konzepte durch SiGeKos evaluiert. Die untersuchten Konzepte und Funktionsumfänge waren dabei:

- Workshop 1 (02. Dezember 2019, Drees & Sommer / TU Darmstadt, Frankfurt):
Konzept I "Baustellensicherheit": Erkennung von Verstößen der Baustellensicherheit, Interaktiver Fragen-Dialog, „Eigene Baustelle“ als Importmöglichkeit, Gefahren nach BG-Bau, Ego-Perspektive
- Workshop 2 (10. März 2021, Drees & Sommer / TU Darmstadt, online):
Konzept II "Gewerkeübergreifende Gefahren": Abbildung von Planungsphasen, eher strategische Fragestellungen, Abstraktion von Gewerke und gewerkeübergreifenden Gefahren, Vogelperspektive
- Workshop 3 (27. April 2021, Drees & Sommer / TU Darmstadt, online):
Konzept III "Baustellenbegehung": Weiterentwicklung von Konzept I, integrierte gewerkeübergreifende Gefahren nach Konzept II, Muster-Baustellen nach realem Vorbild

Konzept III kann hierbei als eine Weiterentwicklung von Konzept I betrachtet werden, wohingegen Konzept II eine komplette Neuentwicklung darstellt. Ausschlaggebend hierfür waren die Ergebnisse des ersten Workshops. Eine wesentliche Erkenntnis war, dass Konzept I sich eher an der Baustellensicherheit im Allgemeinen orientiert, jedoch die gewerkeübergreifenden und vorausschauenden Aspekte der Tätigkeit eines SiGeKos fehlen. Daher wurde Konzept II von Grund auf neu konzipiert und enthielt im Gegensatz zu Konzept I planerische Aspekte: Die Baustelle wurde hier über den kompletten Zeitverlauf betrachtet und nicht mehr zu einem festen Zeitpunkt. Die Spieleransicht war nun nicht mehr in der Ego-Perspektive, sondern wie es bei Planspielen und Tycoons üblich ist, aus der Vogelperspektive.

In einem zweiten Workshop kam die Evaluation des Konzepts II zu dem Ergebnis, dass die planerischen Aspekte nun angemessene Berücksichtigung fanden, der Abstraktionslevel der Darstellung der Gewerke aber zu hoch sei und den Bezug zur Realität erschwere. In der Konsequenz wurden die als passend evaluierten Ansätze der ersten beiden Konzepte im Konzept III zusammengeführt, das technisch als eine Weiterentwicklung des ersten Konzepts umgesetzt wurde, da dieses für die Integration der Ansätze geeigneter war.

Viele praktische Beispiele, die dem tatsächlichen Arbeitsablauf eines SiGeKos entnommen wurden, konnten durch reale SiGe-Protokolle, die nun zur Verfügung standen, ergänzt werden. Diese Beispiele nach realem Vorbild wurden im Konzept III eingearbeitet und haben – nach Meinung der Experten aus dem dritten Workshop – den gewünschten spezifischeren Ansatz ergeben. Das Konzept kann nun die Achtsamkeit in Bezug auf allgemeine Baustellensicherheit erhöhen, verfügt aber zudem auch über die Tiefe, spezifische Arbeitsabläufe und Wissen eines SiGeKos abzufragen. Die SiGeKo-Simulationsumgebung entsprechend des finalen dritten Konzepts, könnte sowohl in einer professionalisierten Form zu Schulungs- oder Trainingszwecken im Rahmen der SiGeKo-

Ausbildung, als auch zur unterstützenden Sicherheitseinweisung im Baustellenbetrieb eingesetzt werden. Natürlich ersetzt ein derart virtuelles Training nicht die praktische Erfahrung, die für die Ausübung der SiGeKo-Tätigkeit unabdingbar ist, es veranschaulicht jedoch immersiv exemplarische Abläufe und dient der allgemeinen Erhöhung der Achtsamkeit in Bezug auf Baustellensicherheit.

Wie bereits erwähnt, wurde im Projektverlauf auch die Möglichkeit der Generierung dynamischer Baustellenumgebungen auf der Grundlage gegebener BIM-Modelle untersucht [Kastner-Guhl 2020]. Die vollautomatische Anlagenplatzierung auf Basis von BIM-Modellen ist in der aktuellen Forschung noch weitgehend ungelöst. Es gibt viele halbautomatische Generierungsansätze, die zunächst eine BIM-Bearbeitungssoftware als Autorentool verwenden, bevor das veränderte BIM-Modell in die Platzierungsalgorithmen eingespeist wird. Dies widerspricht jedoch dem Ziel der Laufzeitimportfähigkeit, da jedes BIM-Modell von einem Experten angepasst werden muss, bevor es im Werkzeug verwendet werden kann. Während einige in dieser Arbeit vorgestellte Ansätze implementiert werden konnten, nutzten die implementierten Ansätze meist keine im Modell vorhandenen BIM-Informationen. Eine vollautomatische Platzierung dieser Assets erscheint auch in naher Zukunft nicht realisierbar, da im Rahmen der aktuellen Forschung keine vielversprechenden Ansätze identifiziert werden konnten. Während also das Konzept der On-Demand-Trainingsbaustellengenerierung auf Basis von realen Baustellen prinzipiell ein vielversprechender Ansatz ist, erwies sich die tatsächliche Umsetzbarkeit eines solchen Konzepts aktuell jedoch nicht als praxistauglich, sondern als Gegenstand weiterer Forschungsarbeit.

2.1.2 Deep Learning

Im Bereich „Deep Learning“ wurde durch das Arbeitsgebiet „Künstliche Intelligenz und Maschinelles Lernen“ der Technischen Universität Darmstadt untersucht, in welcher Weise Verantwortliche auf der Baustelle durch assistierende Verfahren des maschinellen Lernens (ML) / der künstlichen Intelligenz (KI) in ihren Entscheidungen unterstützt werden können. Die Ziele wurden dabei im Projekt anhand der Arbeiten zur Anforderungsspezifikation des Gesamtprojektes und erster Kommentare aus den Reality Checks präzisiert und an diese Erfordernisse angepasst. Wesentlich war auch die Einschätzung der potenziellen Anwendbarkeit jenseits von sehr eng definierten Technologiedemonstrationen. Hierbei spielten die reale Datenverfügbarkeit zur Anwendung der jeweiligen ML/KI-Verfahren aber auch die potenziellen FuE-Aufwände für eine belastbare Funktion der angedachten Funktionalitäten eine wichtige Rolle.

So wurde in der Startphase des Projektes auch die Möglichkeit untersucht, inwieweit existente KI-Ansätze genutzt werden könnten für eine automatisierte, kamerabasierte Erkennung von Gefahrensituationen auf Baustellen. Als Referenz haben wir hierzu den umfangreichen „Bausteine“-Katalog mit Sicherheitshinweisen der BG BAU genutzt [BGBAU]. Die Auswertung ergab, dass nahezu alle beschriebenen sicherheitsrelevanten Baustellensituationen die Beurteilung mehrerer, nicht trivial erschließbarer Situationsparameter erfordern. Diese sind geschulten Bauarbeiter*innen zwar leicht vermittelbar, nicht jedoch geradlinig durch KI-Systeme erfassbar. Als Beispiel sei die sichere Verwendung von Leitern genannt. Hier gilt es u. a. die zu überbrückende Höhe, den Leiterüberstand, den Untergrund, den Anstellwinkel und auch die auf der Leiter beförderte Nutzlast zu berücksichtigen. Zwar gäbe es für die meisten genannten Parameter potenzielle Ansätze diese aus (3D-)Kameradaten zu ermitteln, allerdings erforderte ein einsetzbares System zumindest eine

eigene Forschungsarbeit, während der Katalog der BG BAU hunderte von Bausteinen enthält. Wie im genannten Fall der Nutzung von Leitern, umfassen diverse Bausteine dabei auch Bestimmungen über physikalische Eigenschaften wie z. B. dort das Gewicht eines zu transportierenden Objekts, auf die ein KI-System durch eine einfache Beobachtung der Umgebung mit einer Kamera oder einem Lidar-Scanner gar keinen direkten Zugriff hat.

Die Wartung solcher spezialisierten Anwendungen kann zudem sehr aufwändig sein, da es eine Vielzahl von Vorschriften für bestimmte Fälle gibt, die sich im Laufe der Zeit auch ändern. Obwohl es zum Beispiel relativ einfach ist, das Vorhandensein eines Feuerlöschers zu erkennen, sind die Vorschriften für seine Kennzeichnung nicht einheitlich und ändern sich im Laufe der Zeit. Das bedeutet z. B., dass sich die Beschilderung direkt auf dem Feuerlöscher oder am Rand einer Wand befinden kann und sogar je nach Jahr der Installation unterschiedlich aussehen darf.

Eine generell automatisierte Erkennung dieser Bausteine wurde von uns daher zum aktuellen Zeitpunkt im Rahmen vertretbarer FuE-Aufwendungen als nicht darstellbar eingestuft. Einfachere Beispiele, namentlich die Erkennung des Vorhandenseins spezifischer Objekte (z. B. Feuerlöscher oder Schutzhelme auf dem Kopf von Personen) schließt dies aber nicht aus.

Im Rahmen der Anforderungsspezifikation in DeepSpaceBIM erhielten schließlich die automatisierte Erkennung des Baustatus bzw. Baufortschritts und die Erkennung ggf. (sicherheits-)kritischer, einfacher Situationen im Bauinnenraum den Vorrang vor z. B. Materialflussuntersuchungen, Dokumentenhandling, dem Monitoring der „freien“ Baustelle im Außenfeld und der genannten, weitgefassten automatisierten Ableitung von Gefahrensituationen nach Baustein-Katalog. Konkret bearbeitete Fragestellungen waren:

- Objekterkennung / „Bestandsaufnahme und Sicherheitsaspekte“: Hier geht es um das mobile, automatisierte Erfassen bestimmter Objekte/Objektklassen mit dem Ziel einen Bestandsstatus zu erstellen. Besondere Beachtung hatte im Projekt die Erkennung von sicherheitsrelevanten Sachverhalten bzw. Objekten auf der Baustelle.
- „Baufortschrittserfassung“: Bei der Erfassung des Baufortschritts ist das Ziel nicht die Erkennung von einzelnen Objekten, sondern das automatisierte Erkennen der gebauten Gebäudeelemente und der Abgleich mit den Plandaten z. B. aus dem BIM. Als exemplarisches Beispiel wurde im Projekt die Wandererkennung und die Erkennung von Durchbrüchen für Türen und Fenster gewählt.

Die entscheidenden Datenquellen in DeepSpaceBIM für diese anvisierten Automatisierungen waren zum einen Punktwolkendaten und zum anderen Bild-/Videodaten jeweils von Gebäudeteilen. Punktwolkendaten wurden zum Beispiel vor einer Auswertung in hoher Qualität durch spezielle Geräte wie dem Pilot 3D vom Projektpartner DMT erfasst. In Live-Situationen, bei denen während der Begehung Erkennungsalgorithmen Verwendung finden sollten, waren es hingegen Standard-Geräte wie z. B. Tablets, die sehr wohl qualitative Bild- und Videodaten liefern, jedoch daraus nur Punktwolken niedrigerer Qualität erzeugen können.

2.1.2.1 Grundlagen

Im Rahmen des Projektes wurden insbesondere die Ansätze des sogenannten "Deep Learning" genutzt, welche sich als sehr mächtiges und anwendungstaugliches Werkzeug erwiesen haben.

Dabei werden künstliche neuronale Netze verwendet. Wir verwenden hierbei als Grundlage für unser Netzwerk vortrainierte Modelle, um den aktuellen Stand der Technik auszunutzen und führen anhand spezifischer Trainingsdaten eine Feinabstimmung bzw. ein weiteres Training durch. Schließlich sind diese Netze imstande mit hoher Erkennungsrate in unserem Fall z. B. Objekte oder auch räumliche Gegebenheiten zu detektieren. Um dies lernen zu können, müssen die Neuronalen Netze allerdings zuvor mit Beispieldaten (Daten, bei denen die Zuordnungen bekannt sind) trainiert werden, zumeist mit vielen tausend Beispielen, um gute Erkennungsraten zu erzielen.

Anfängliche Versuche haben zunächst bestätigt, dass aufgrund ihrer jeweiligen spezifischen Charakteristika einerseits die Punktwolkendaten (weiträumige Abdeckung und hohe Auflösung) insbesondere für die Analyse des Baufortschritts i.o.g.S. besser geeignet sind, andererseits bei der Live-Identifikation konkreter Objekte Bild-/Videodaten bessere Ergebnisse erzielen. Eine Untersuchung der algorithmischen Kombination von Punktwolken und Bilddaten zur Objekterkennung bzw. Fortschrittsanalyse hat zwar die prinzipielle Anwendbarkeit gezeigt, zumindest in unserem Anwendungsfall jedoch keine klaren Vorteile erbracht [Precht2019].

Im Folgenden werden unsere Ansätze detailliert vorgestellt.

2.1.2.2 Verwendete Methoden zur Objekterkennung

In diesem Teil der Arbeit haben wir ein Framework entwickelt für die automatische Erkennung sicherheitsrelevanter Objekte in Echtzeit. Die zugrundeliegenden Deep Learning Algorithmen nutzen Transfer Learning. Hierbei werden mittels ähnlicher oder übergreifender Objektklassen vortrainierte neuronale Netze als Startpunkt genutzt (insbesondere durch Verwendung frei zugänglicher Bibliotheken) um sie dann durch gezieltes, aber vergleichsweise weniger aufwendiges Training an die konkreten Anwendungsfälle bzw. Objektkategorien anzupassen. Für den präsentierten Anwendungsfall haben wir die drei Klassen Feuerlöscher, Notausgangsschild und Hammer berücksichtigt, wie in Abbildung 6 dargestellt. Weitere Klassen können in den Trainingsprozess aufgenommen werden, indem Bilder der betreffenden Klasse gesammelt und nachtrainiert werden.

Der Ausgangspunkt des Transfer-Learnings, das vortrainierte Modell, wurde von "TensorFlow 1 Detection Model Zoo" [TENSORFLOW] bereitgestellt. Dieses wurde mit den Bildern einer Reihe von Klassen feinabgestimmt. Dazu wurde die neueste Version des MobileNet, MobileNetV3-Large, im Framework verwendet. Im Vergleich zu MobileNetV2 ist es genauer und schneller. Die Details zur Architektur sind in [Howard2019] zu finden. Als Trainingsdaten haben wir die frei zugänglichen Datensätze ImageNet [IMAGENET2017] und FireNet [FIRENET] verwendet. Insgesamt gab es hier eine Anzahl von 670 Bildern in unseren Objektbereichen.

Die Standardeinstellung des Frameworks litt unter einem Overfitting-Problem, d. h. das Modell war zunächst nicht in der Lage zu generalisieren, was anhand des Klassifikationsverlustes sichtbar war. Wir lösten das Overfitting-Problem durch Datenerweiterung, um die Komplexität der Daten zu erhöhen, durch Änderung der Gewichte für den Klassifikationsverlust, durch Erhöhung des Gewichts für den Regularizer, um die Modellkomplexität zu kontrollieren und durch Größenänderung des Bildes, um detailliertere Informationen zu erhalten.



Fire Exit Signal



Fire Extinguisher



Hammer

Abbildung 6: berücksichtigte Objektklassen (Quelle: Bild links und mittig [FIRENET], Bild rechts [IMAGENET2017])

Da die Aufgabe darin besteht, die Bounding Box der Objekte zu finden (Lokalisierung), haben wir die mittlere durchschnittliche Präzision (mAP) und den durchschnittlichen Recall (AR) verwendet, um die Robustheit des trainierten Modells zu bewerten. mAP spiegelt wider, wie gut die Lokalisierung der Bounding Box ist, während AR angibt, wie viele der vorhandenen Objekte positiv erkannt werden. Das mit drei Klassen trainierte Modell hatte eine mittlere durchschnittliche Präzision (mAP) und einen durchschnittlichen Rückruf (AR), wie in Abbildung 7 dargestellt. Die X-Achse (Number of Epochs) zeigt die Anzahl der Trainingsdurchläufe mit jeweils allen Trainingsbildern an.

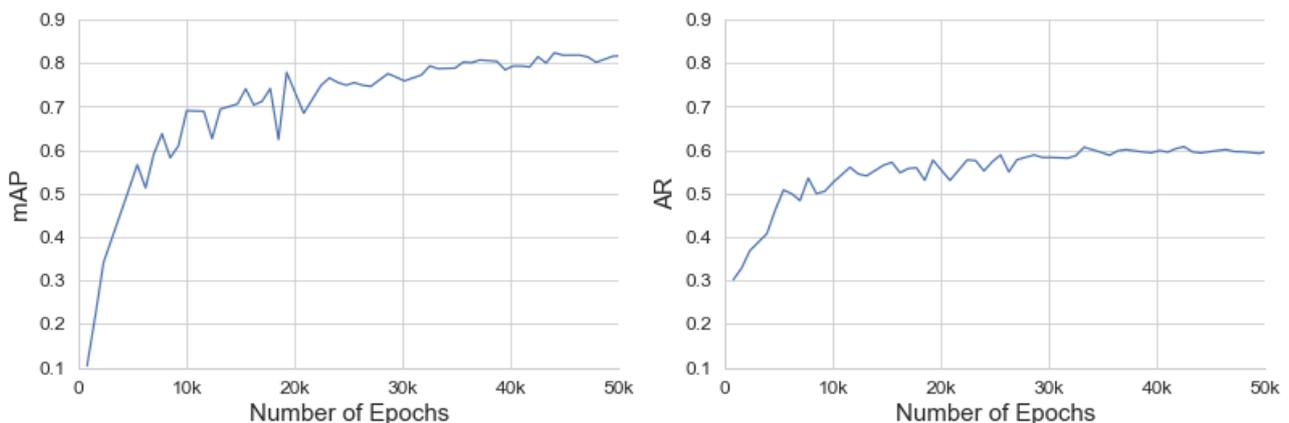


Abbildung 7: Finale Testergebnisse (mAP und AR) für die Objekterkennung mit drei Objektklassen. (Quelle: TU Darmstadt)

Wie man sieht, erreicht am Ende des Trainings (nach 50.000 Durchläufen) mAP 80 %, während AR nicht über 60 % steigt. Dieses Verhalten zeigt, trotz deutlicher Verbesserung, noch immer die Auswirkungen des Overfittings. Das Modell könnte mit einem robusteren Algorithmus und einem vergrößerten, repräsentativeren Datensatz weiter verbessert werden. Diese würde allerdings erheblichen zusätzlichen Aufwand insbesondere in der Erfassung und Aufbereitung von zusätzlichen Trainingsdaten bedeuten.

2.1.2.3 Verwendete Methoden zur Baufortschrittserfassung

Der in DeepSpaceBIM entwickelte Ansatz zur Erkennung von Wanddurchbrüchen für Fenster und Türen arbeitet mit 3D-Punktwolkendaten. Er nutzt Bildverarbeitungstechniken zur Erkennung der Dichte der Punktwolken und setzt Optimierungsalgorithmen ein, um relevante Wände und passende Wandöffnungen im vorgegebenen Größenbereich zu finden. Neuronale Netze kommen hierbei nicht zum Einsatz. Ein Beispiel der Ergebnisse für die Locherkennung ist in Abbildung 8 zu sehen.

Unser Vorgehen zerlegt das Problem der Locherkennung in 3D-Punktwolken in zwei Teilprobleme: Erkennung von Wänden in 3D-Punktwolkendaten und Locherkennung in 2D-Wänden. Die für den Menschen u. a. aufgrund seines Weltwissens einfach lösbaren Aufgaben benötigen für Machine Learning Verfahren entsprechend eine Reihe von expliziten Vorannahmen um zu eindeutigen Ergebnissen zu gelangen. In unserer prototypischen Umsetzung haben wir insbesondere folgende drei Einschränkungen getroffen, die in den meisten Gebäuden erfüllt sind und auch den realen:

- Alle im Scan sichtbaren Wände sind vertikal, wobei wir die Z-Achse des Punktwolkenrahmens als nach oben weisend definieren. Diese Annahme setzt voraus, dass das Scangerät "oben" ausweist.
- Alle Wände sind gerade. Wir unterstützen in diesem Ansatz keine gekrümmten Wände.
- Es sind rechteckige Öffnungen in Wänden, deren minimale und maximale Größe im Voraus festgelegt werden kann.

Wir beginnen zunächst mit der Erkennung von Wänden in 3D-Punktwolken, indem wir das Problem der Projektion von Wandebenen auf die XY-Ebene (statt auf die Z-Ebene) reduzieren. Bei dieser Projektion ist die Punktdichte entlang von Wänden höher als anderswo, da alle Punkte an der Wand auf eine einzige Linie projiziert werden. Daher können wir eine Dichteschätzung der projizierten Punkte nutzen um die Lage und Ausrichtung der Wände in der XY-Ebene zu ermitteln. In dieser Arbeit haben wir uns für einen Histogramm-Ansatz zur Schätzung der Dichte entschieden.

Nach der Wanderkennung müssen die Durchbrüche ermittelt werden. Dazu wird die Belegungskarte (Occupancy Grid Map) der Wandpunkte berechnet nach 2D-Projektion der Punkte auf die jeweilige Wandebene und einer Entrauschung, um durch Ungenauigkeiten entstehende winzige Löcher und ausgefranste Kanten zu entfernen. Aufgrund unserer dritten Annahme können Wanddurchbrüche erkannt werden, indem rechteckige, nicht belegte Zonen mit geeigneten Größen in den Belegungskarten gefunden werden. Hierzu wird

Verhältnis zwischen der Fläche der Bounding Box jeder zusammenhängenden, nicht belegten Region und der Fläche der Region selbst berechnet. Für eine perfekt rechteckige Region ist dieses Verhältnis genau 1, während weniger rechteckige Formen ein Verhältnis kleiner als 1 ergeben. Unsere Auswertung hat gezeigt, dass ein Verhältnis $> 0,9$ ein zuverlässiger Indikator für eine rechteckig geformte Region ist.



Abbildung 8: Punktwolke mit erkanntem Türdurchbruch, hier: rot markiert. (Quelle: TU Darmstadt)

Anschließend prüfen wir, ob die Bounding Box der Region die Größenbeschränkungen der gesuchten Wanddurchbrüche erfüllt. Wenn dies der Fall ist, fügen wir die Bounding Box zu den identifizierten Wanddurchbrüchen hinzu. Schließlich projizieren wir die identifizierten Löcher zurück in den ursprünglichen 3D-Punktwolkenrahmen und erhalten so die Position und die Abmessungen der erkannten Wanddurchbrüche. Diese können später zum Vergleich mit dem BIM-Modell des Gebäudes verwendet werden, wenn es eine Zuordnung zwischen dem BIM und den Punktwolken gibt.

2.1.2.4 Ergebnisse Objekterkennung

Obwohl wir in unserem Test-Set eine hohe Erkennungsgenauigkeit erreichen konnten (siehe Abbildung 7), liegen bei realen Szenen die Erkennungsraten typischerweise niedriger, aufgrund höherer Vielfalt und größerer Komplexität in natürlichen Szenen gegenüber Test-Sets, die immer nur eine Auswahl darstellen. Bei den Experimenten zur Abschluss-Demonstration haben wir diesen Effekt nicht beobachtet, aber wir erwarten eine Abnahme der Robustheit des trainierten Modells unter realen Bedingungen. Außerdem enthalten öffentlich zugängliche Datensätze, die wir bewusst zur Vereinfachung des Trainings genutzt haben, oft keine oder nur wenige Bilder von den jeweils im Anwendungsfokus stehenden domänenspezifischen Klassen, hier z. B. Objekte von Baustellen. Der von uns genutzte FireNet-Datensatz stellt diesbzgl. eine Ausnahme dar. FireNet ist ein Trainingsdatensatz, der speziell für die visuelle Erkennung von Feuerschutzausrüstung erhoben wurde.

Die Anwendung von Erkennungsmodellen, die mit kontrollierten Daten trainiert wurden, in der normalen, unkontrollierten Anwendungsumwelt ist ein aktiver Forschungsbereich. Eine deutliche Vergrößerung der Testbasis, z. B. um Trainingsdaten mit komplexen oder auch selten vorkommenden Eigenschaften ist dabei ein möglicher Ansatz die Performance zu erhöhen. Zugleich ist dieser Weg jedoch oft mit hohen Kosten für die Testdatenerfassung und -aufbereitung verbunden. Eine Verwendung von automatisierten Verfahren zur bildbasierten Objekterkennung ist damit zwar prinzipiell auch im Bauumfeld möglich. Gleichwohl unterliegt ein solcher Einsatz wesentlichen Einschränkungen, die im Vorfeld zu bewerten sind. Der Aufwand für das spezifische Training der bereits vortrainierten Verfahren, hängt wesentlich davon ab, welche Objektklassen erkannt werden sollen. Gibt es spezialisierte Trainingsdaten bereits (siehe FireNet) kann ein Einsatz gelingen, gibt es sie nicht, stellen Testdatenstellung und Training ein eigenständiges Projekt dar, dessen Wirtschaftlichkeit zu prüfen ist. Im sicherheitskritischen Einsatz ist zu beachten, dass eine Automatisierung aufgrund der notwendig immer verbleibenden Fehlerrate herkömmliche personelle und organisatorische Maßnahmen nicht ersetzen (z. B. SiGeKos, Sicherheitskontrollen etc.) kann, aber dennoch in Kombination mit diesen eine wichtige Unterstützung sein kann.

Im konkreten Anwendungsbeispiel ist also eine automatisierte, nebenläufige Bestandserfassung von z. B. Feuerlöschern und Notausgangskennzeichen eine Hilfe in einer dynamischen Sicherheitsbeurteilung, für eine formal belastbare Dokumentation (z. B. für eine Sicherheitszertifizierung) dürfte sie jedoch nicht ungeprüft genutzt werden.

2.1.2.5 Ergebnisse Baufortschrittserfassung

Während der Projektlaufzeit haben wir untersucht, wie die Baufortschrittserfassung aus 3D-Punktwolken mit Hilfe von tiefen neuronalen Netzen erreicht werden kann. Zunächst konzentrierten

wir uns dazu auf die semantische Segmentierung von 3D-Punktwolken. Unsere experimentellen Ergebnisse zeigten, dass das entwickelte Modell erfolgreich Wandöffnungen in einem einfachen Testdatensatz (> 95%) sowie andere häufig verwendete Klassen wie Stühle oder andere Möbel segmentieren konnte. Der Algorithmus schnitt auch bei einem öffentlich zugänglichen Datensatz gut ab. Dabei konnten wir eine mittlere IoU (Intersection over Union, Überdeckung von berechneter Segmentierung und tatsächlicher Segmentierung) von ca. 67 %, eine mittlere Genauigkeit (gemittelte Genauigkeit aller Objektklassen) von ca. 77 % und eine Gesamtgenauigkeit (Prozentsatz korrekt klassifizierter Objekte) von ca. 93 % erreichen, was in etwa dem Stand der Technik entspricht. Allerdings enthalten öffentlich verfügbare Datensätze typischerweise keine Wandöffnungen in Form von offenen Türen oder Fenstern. Außerdem konzentrieren sich gängige Verfahren der semantischen Segmentierung aus Punktwolken derzeit auf vollständige Räume, in denen alle Wände, Decke und Böden in den Punktwolkendaten enthalten sind und zumeist geschlossene Quader bilden. Punktwolkendaten von Baustellen geben demgegenüber oft Räume in unfertigem Zustand wieder, wie auch in Abbildung 9 zu sehen ist.



Abbildung 9: Zwei Perspektiven einer Punktwolke eines Gebäudes im Bau mit einem enthaltenen Türdurchbruch. (Quelle: TU Darmstadt)

Zudem ist auf Baustellen eine große Diversität an Rüstzeug, Materiallagern, Schalungen, Gerüsten etc. anzutreffen, die sowohl in Punktwolkendaten z. T. nur schwer identifizierbar sind, Gebäudeteile verdecken können und generell in verfügbaren Standarddatensätzen zur Segmentierung nicht oder nur unzureichend enthalten sind. Die automatische semantische Segmentierung von Punktwolkendaten von aktiven Baustellen muss daher aktuell als eine noch nicht gelöste Herausforderung für die modernen Algorithmen zur semantischen Segmentierung von Punktwolken bewertet werden.

Im Rahmen von DeepSpaceBIM haben wir darum den Problembereich auf die Erkennung von Wandöffnungen eingeschränkt. Wir haben dazu eine Methode entwickelt, um die Löcher in den Punktwolkendaten anhand der Geometrie der Punktwolkendaten zu finden. Zwar ist das beschriebene Verfahren rechenintensiv und war in unseren Tests nicht echtzeitfähig. Da die Erkennung der Wanddurchbrüche jedoch fertige Gebäudes scans in Form von 3D-Punktwolken als Eingangsdaten erfordert, stellt die Ausführung unserer Methoden als nachbearbeitender Schritt keine Einschränkung bzgl. des Arbeitsablaufs dar.

Unsere Analyse konnte zeigen, dass die Erkennung von Löchern aus Punktwolken effektiv ist und auch die Verortung der gefundenen Durchbrüche ermöglicht. Die beschriebenen Ansätze führten in unseren Tests zu verwendbaren Ergebnissen. Für einen robusten und genauen Vergleich mit der

Lage im BIM muss die Dichte der Punktwolken jedoch ausreichend hoch sein. Darüber hinaus benötigen die Algorithmen auch weiter einschränkende Vorgaben, wie z. B. Minimal- und Maximalgrößen zu detektierender Wandöffnungen. Diese Vorgaben können dabei für die Architektur jeder Baustelle unterschiedlich sein (z. B. wegen Vorhandensein oder Fehlen von Glasfronten oder offenen Räumen). Die Verwendung des entwickelten Detektors für Wanddurchbrüche ist also im Sinne einer robusten End-to-End-Methode dennoch einschränkt und bedarf kundiger situativer Anpassung von Suchparametern.

2.1.2.6 Technische Validierung der Objekterkennung

Wie beschrieben, haben wir ein Modell trainiert, das sicherheitsrelevante Objekte in Echtzeit aus Kamerabildern erkennen kann. Dieses Modell ist eine Augmented Reality (AR) App eingebettet, welche im Rahmen des Use Case 4 „Baufortschrittserfassung“ vom Projektpartner Robotic Eyes entwickelt wurde. Die AR-App kann bzgl. der Objekterkennung verwendet werden, um die relevanten Objektklassen live zu detektieren, die Verortung der erkannten Objekte in der cloudbasierten Datenhaltung zu speichern und anschließend in AR-Visualisierungen aus dem Datenbestand heraus an der korrekten Position zu visualisieren. Eine technische Validierung dieser Komponente war im Projektverlauf problemlos an unterschiedlichen Orten möglich, aufgrund der allgemeinen Verfügbarkeit der betrachteten Objektklassen. Wir haben den endgültigen Prototyp während des abschließenden Reality Checks zusammen mit Robotic Eyes vorgestellt.



Abbildung 10: Automatische Erkennung und Verortung eines Objektes in der AR-App des digitalen Bauassistenten. (Quelle: DeepSpaceBIM Konsortium / Robotic Eyes)

2.1.2.7 Technische Validierung der Baufortschrittserfassung

Der entwickelte Algorithmus zur Erkennung von Tür- und Fensteröffnungen in Wänden im Rahmen der Baufortschrittserfassung arbeitet auf bereits erfassten 3D-Punktwolkendaten, also „offline“ bzgl. konkreter Begehungen auf der Baustelle. Wir konnten zeigen, wie wir den vorgeschlagenen Algorithmus verwenden können, um die Wanddurchbrüche in komplexen 3D-Punktwolken zu erkennen und die Ergebnisse wiederum in der zentralen Datenhaltung des Bauassistenten zu speichern. Auf dieser Datenbasis können dann weitere Bewertungsschritte wie der Abgleich mit BIM Planungsdaten erfolgen. Im Zuge einer späteren Ortsbegehung können die erkannten

Wandöffnungen (z. B. zur Verifikation) auch positionskorrekt in einer AR-Darstellung des digitalen Bauassistenten visualisiert werden.

Die geplante Erprobung des Algorithmus auf den unterschiedlichen Baustellen, die im Projekt beteiligt waren, konnte durch die Beschränkungen der Covid-19 Pandemie in dieser Form nicht durchgeführt werden. Für die technischen Tests waren wir daher auf entsprechend aufbereitete Scandatensätze u. a. des Projektpartners DMT angewiesen. Dennoch war in der Finalphase des Projektes zumindest eine Evaluation am Datenbestand und dem realen Gebäude des abschließenden Reality Checks umsetzbar, deren Ergebnisse auch im finalen Reality Check präsentiert wurden (siehe Abbildung 8 und Abbildung 9).

2.1.3 Integration in den „Digitalen Bauassistenten“

Im Rahmen des DeepSpaceBIM-Gesamtprojektes wurde unter Leitung des Projektpartners Robotic Eyes eine Gesamtarchitektur aller Komponenten des „Digitalen Bauassistenten“ erarbeitet (siehe Abbildung 11), in welche sich auch die Beiträge der TU Darmstadt einfügen.

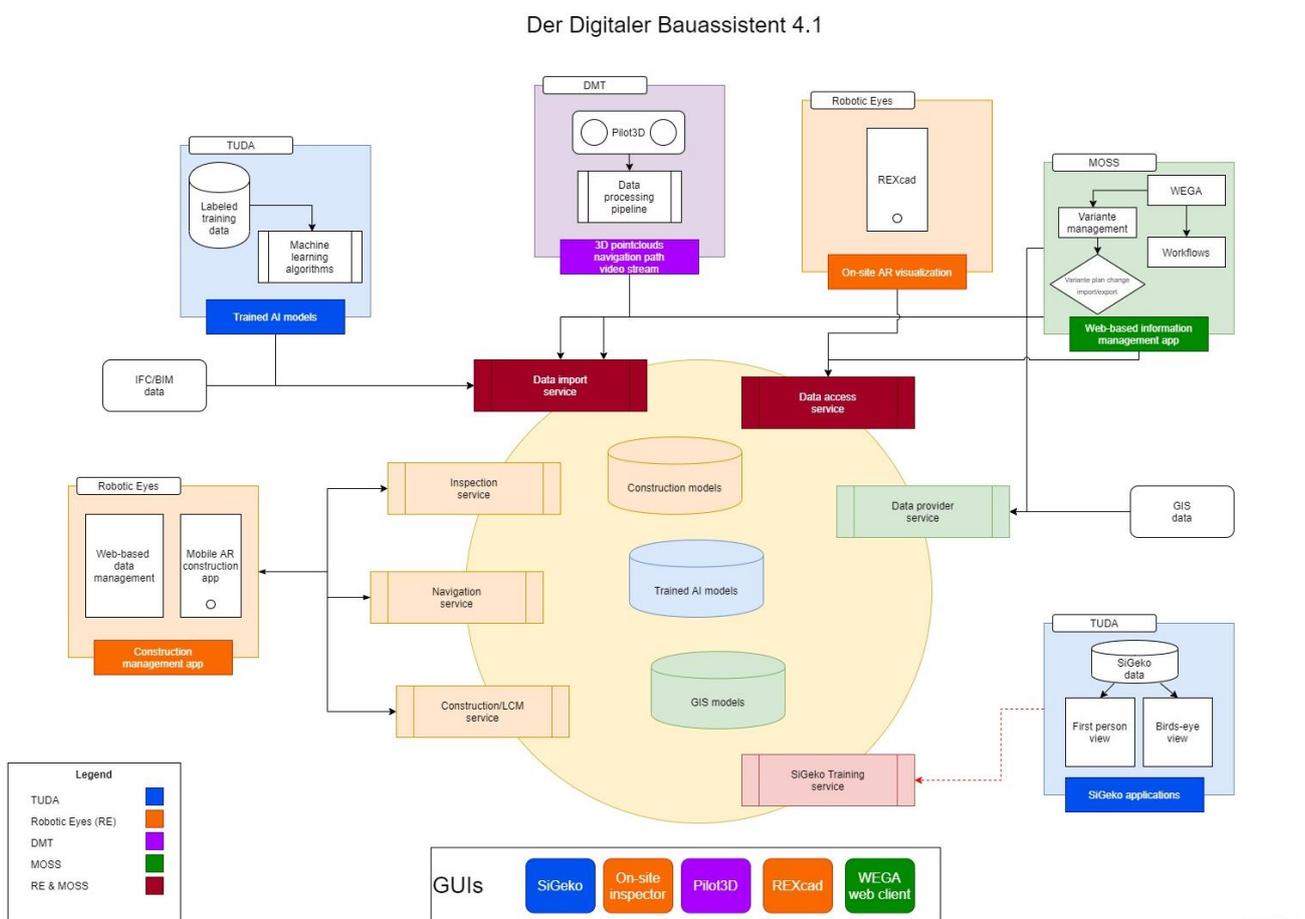


Abbildung 11: Integration - Der digitale Bauassistent (Quelle: DeepSpaceBIM Konsortium / Robotic Eyes)

Da im Gesamtkonzept unterschiedliche Technologien zum Einsatz kamen wurde ein Baukastensystem entwickelt, welches in unterschiedlichen Phasen des Bauprozesses eingesetzt werden kann und in welchem die einzelnen Komponenten technisch unterschiedlich tief integriert sind. Dies gilt auch für die Beiträge der TU Darmstadt. So stellt die SiGeKo-Trainingsimulation ein eigenständiges

Baukastenelement des „Digitales Assistenten“ dar. Prinzipiell besteht hier eine Anbindung zur gemeinsamen Datengrundlage um z. B. baustellenspezifische BIM-Daten abzurufen und in der Simulation zu verwenden (siehe Abschnitt 2.1.1.3).

Die Software-Komponenten des Projektbereichs „Deep Learning“ unterscheiden sich in ihrer Einbindung. Während die Baufortschrittserfassung potenziell Begehungsdaten, d. h. 3D-Punktwolken, aus der gemeinsamen Datenbasis bezieht, diese offline auswertet und die Ergebnisse wieder dem Datenpool zur Verfügung stellt, ist die Objekterkennung tief integriert. Hier werden trainierte Modelle zur Objekterkennung in der in der mobilen AR-App des digitalen Bauassistenten verwendet (siehe Abschnitt 2.1.2.6).

A Anhang

A.1 Literatur

- [BaustellV] Bundesministerium der Justiz und für Verbraucherschutz. Verordnung über Sicherheit und Gesundheitsschutz auf Baustellen (Baustellenverordnung - BaustellV) § 3 Koordinierung. https://www.gesetze-im-internet.de/baustellv/__3.html, abgerufen am 27.07.2021
- [BGBAU] BG BAU Mediacenter, umfangreicher Katalog mit Sicherheitshinweisen für Baustellen als „Bausteine“ und Merkhefte, <https://www.bgbau.de/medien-center/bausteine-und-merkhefte/was-sind-bausteine/>, abgerufen am 26.10.2021
- [BGBAU2017] BG BAU Jahresbericht 2017. https://www.bgbau.de/fileadmin/Medien-Objekte/Medien/Broschuere_Flyer/Jahresbericht_2017.pdf, abgerufen am 27.07.2021
- [Delhi2020] Delhi, V. S. K., & Thomas, A. (2020). Detection of Personal Protective Equipment (PPE) compliance on construction site using Computer Vision based Deep Learning techniques. *Frontiers in Built Environment*, 6, 136.
- [DGUV2020] Deutsche Gesetzliche Unfallversicherung (DGUV). Statistik Arbeitsunfallgeschehen 2019. September 2020
- [FIRENET] Fire-net dataset. <https://rdr.ucl.ac.uk/articles/dataset/FireNet/9137798/1>, abgerufen am 25.04.2021
- [Greuter2013] Greuter, Stefan & Tepe, Susanne & Boukamp, Frank & Wakefield, Ron. (2013). Trouble Tower Game Demo. 10.1145/2513002.2513035.
- [Howard2019] Andrew Howard, Mark Sandler, Bo Chen, Weijun Wang, Liang-Chieh Chen, Mingxing Tan, Grace Chu, Vijay Vasudevan, Yukun Zhu, Ruoming Pang, Hartwig Adam, and Quoc Le (2019). Searching for mobilenetv3. arXiv:1905.02244, May 2019.
- [IMAGENET2017] Image-net object detection dataset. <http://image-net.org/challenges/LSVRC/2017/#det><http://image-net.org/challenges/LSVRC/2017/#det>, abgerufen am 25.04.2021.

-
- [Jeelani2018] Jeelani, I., Han, K., & Albert, A. (2018). Automating Analysis of Construction Workers Viewing Patterns for Personalized Safety Training and Management. arXiv preprint arXiv:1809.00949.
- [Kim2013] Kim, C., Kim, B., & Kim, H. (2013). 4D CAD model updating using image processing-based construction progress monitoring. *Automation in Construction*, 35, 44-52.
- [Lin2019] Lin, J. J., Lee, J. Y., & Golparvar-Fard, M. (2019). Exploring the potential of image-based 3d geometry and appearance reasoning for automated construction progress monitoring. In *Computing in Civil Engineering 2019: Data, Sensing, and Analytics* (pp. 162-170). Reston, VA: American Society of Civil Engineers.
- [Maninis2020] Kevis-Kokitsi Maninis, Stefan Popov, Matthias Nießner, Vittorio Ferrari (2020). Vid2CAD: CAD Model Alignment using Multi-View Constraints from Videos. arXiv:2012.04641v1 [cs.CV]
- [O'Rourke2014] Rourke, Mark (2014). Increasing engagement with vocational education and training: a case study of computer games-based safety training.
- [RAB30] Bundesministerium für Wirtschaft und Arbeit (2003). Regeln zum Arbeitsschutz auf Baustellen, Geeigneter Koordinator, RAB 30. <https://www.baua.de/DE/Angebote/Rechtstexte-und-Technische-Regeln/Regelwerk/RAB/RAB-30.html>, abgerufen am 27.07.2021
- [TENSORFLOW] Tensorflow 1 detection model zoo. https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/tf1_detection_zoo.md, abgerufen am 25.04.2021.
- [Wang2019] Wang, M., Wong, P., Luo, H., Kumar, S., Delhi, V., & Cheng, J. (2019). Predicting safety hazards among construction workers and equipment using computer vision and deep learning techniques. In *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction* (Vol. 36, pp. 399-406). IAARC Publications.
- [WHITECARD2007] Australian Government, Australian Safety and Compensation Council (2007). National Code of Practice for Induction for Construction Work. https://www.safeworkaustralia.gov.au/system/files/documents/1702/inductionforconstructionwork_2007_pdf.pdf, abgerufen am 27.07.2021
- [WHITECARD2020] Anleitung zum Erwerb der Whitecard. <https://www.australien-backpackersguide.com/hol-dir-die-white-card-australia-online/>, abgerufen am 27.07.2021.
- [Yuan2020] Yuan, L., Guo, J., & Wang, Q. (2020). Automatic classification of common building materials from 3D terrestrial laser scan data. *Automation in Construction*, 110, 103017.

- [Kastner-Guhl2020] Theo Kastner-Guhl (2020). Generation of a dynamic construction site environment based on rule-based restrictions. Bachelor Thesis, TU Darmstadt. Supervisors: Philipp Achenbach & Ralf Steinmetz.
- [Precht2019] Marten Precht (2019). Image-based semantic change detection in 3D point clouds using automatically sourced training data. Master Thesis, TU Darmstadt. Supervisors: Cigdem Turan & Kristian Kersting.

A.2 Bildverzeichnis

Abbildung 1: Ausschnitt aus dem White-Card-Game, bei dem der Spieler gerade eine Gefahrenstelle melden soll. (Quelle: [O'Rourke 2014])	7
Abbildung 2: Ausschnitt aus dem Spiel Trouble Tower in welchem der Spieler gerade mit dem richtigen Feuerlöscher einen Brand löschen muss. (Quelle: [Greuter2013])	8
Abbildung 3: Ausschnitt aus der prototypischen Umsetzung von Konzept I, hier zu sehen der Fragendialog bei einer identifizierten Gefahrenstelle. (Quelle: TU Darmstadt).....	11
Abbildung 4: Ausschnitt aus der prototypischen Umsetzung von Konzept II, hier zu sehen der eingestellte bevorzugte Weg zu den Sanitärbereich für das Gewerk der Glaser. (Quelle: TU Darmstadt).....	12
Abbildung 5: Ausschnitt aus der prototypischen Umsetzung von Konzept III, hier zu sehen einige Gefahrenstellen + Fragendialog. (Quelle: TU Darmstadt)	12
Abbildung 6: berücksichtige Objektklassen (Quelle: Bild links und mittig [FIRENET], Bild rechts [IMAGENET2017])	17
Abbildung 7: Finale Testergebnisse (mAP und AR) für die Objekterkennung mit drei Objektklassen. (Quelle: TU Darmstadt).....	17
Abbildung 8: Punktwolke mit erkanntem Türdurchbruch, hier: rot markiert. (Quelle: TU Darmstadt)	18
Abbildung 9: Zwei Perspektiven einer Punktwolke eines Gebäudes im Bau mit einem enthaltenen Türdurchbruch. (Quelle: TU Darmstadt)	20
Abbildung 10: Automatische Erkennung und Verortung eines Objektes in der AR-App des digitalen Bauassistenten. (Quelle: DeepSpaceBIM Konsortium / Robotic Eyes).....	21
Abbildung 11: Integration - Der digitale Bauassistent (Quelle: DeepSpaceBIM Konsortium / Robotic Eyes).....	22