

TwinGen

Technologien zur Generierung digitaler Zwillinge als Grundlage für Betrieb und Instandhaltung baulicher Infrastruktur

Abschlussbericht

Beteiligte Partner	Technische Universität München Ruhr-Universität Bochum RWTH Aachen ZPP Ingenieure AG
Fördermittelgeber	Bundesministerium für Digitales and Verkehr Aktenzeichen: DG 15 – 836.7/12
Projektlaufzeit	01.08.2019 bis 15.11.2022
Datum	München, den 31.12.2022
Autoren	Prof. Dr.-Ing. André Borrmann, Prof. Dr.-Ing. Jörg Blankenbach, Prof. Dr. Jakob Beetz, Prof. Dr.-Ing. Markus König, Dr.-Ing. Ralf Becker, Timothy Blut M.Sc., Firdes Celik M.Sc., Benedikt Faltin M.Sc., Anne Göbels M.Sc., M. Saeed Mafipour M.Sc., Jan Martens M.Sc., Markus Scheffer M.Sc., Simon Vilgertshofer M.Sc.



Inhaltsverzeichnis

Überblick	1
Projektpartner	2
Technische Universität München (TUM)	2
Ruhr-Universität Bochum (RUB)	2
RWTH Aachen	2
ZPP Ingenieure AG	3
Wissenschaftlich-technische Ergebnisse	4
AP 1: Anforderungsanalyse	4
1.1 Systematische Erfassung der Anforderung und Dokumentation mittels IDM	4
1.2 Erfassung der Anforderungen an Bestandsmodelle im Bereich Brücke	5
1.3 Erfassung der Anforderungen an Ingenieurbauwerke des Wasserbaus	6
1.4 Analyse von Datenquellen und Notwendigkeiten der Verknüpfung	6
AP 2: Ermittlung der Datengrundlagen	9
2.1 Schaffung der Datengrundlagen im Bereich Brückenbau	9
2.2 Auswahl geeigneter Datensätze und Datenerfassung an ausgewählten Bauwerken	10
2.3 Methode zur Erzeugung synthetischer Punktwolken als Trainingsgrundlage für KI-Verfahren	16
2.4 Bereitstellung von Daten durch den Industriepartner	19
AP 3: Modellgenerierung durch Cross-Domain-Matching	20
3.1 Segmentierung und Klassifizierung von Punktwolken und Bilddaten sowie Feature Matching	20
3.2 Erzeugung und Verknüpfung heterogener Datensätze	27
3.3 Aufbereitung technischer Zeichnungen mittels neuronaler Netze	31
AP 4: Entwicklung geeigneter Parametrisierungen für das Model Fitting	34
4.1 Analyse der Typologie von Brückenbauwerken	34
4.2 Entwicklung einer Parametrik für weit verbreitete Brückentypen	35
4.3 Typologie und Parametrik für Wasserbauwerke	36
AP 5: Optimierungsverfahren für das Model-to-Cloud Fitting	38
5.1 Heuristische Optimierungsverfahren zur systematischen Variation von Brückenparametern	38
5.2 Cloud-Fitting für schwer zugängliche, partiell sichtbare und verborgene Strukturen	45
AP 6: Informationsstruktur und Analyse zu Schädigungen	46
6.1 Offene Informationsaustauschformate für die bauteilorientierte Verknüpfung von Schadensinformation auf Basis existierender Standards	46
6.2 Bilderkennungsmethoden zur automatisierten Schädigungsdetektion	49
6.3 Einbindung in aktuelle Best-Practice-Verfahren zur Erfassung des Bauzustandes	53
AP 7: Verfahren zur Extraktion von Informationen aus technischen Zeichnungen	55

7.1 Deep Learning-Verfahren zur Extraktion von Informationen aus technischen Zeichnungen	55
7.2 Integration der extrahierten Informationen in digitale Brückenmodelle	61
7.3 Anreicherung von bestehenden Raster- und Vektor-Zeichnungsdaten	62
AP 8: Semantische Anreicherung der Modelle mit Hilfe von Expertenwissen	63
8.1 Musterbasierte Erkennung von Objekten in Bildern und Punktwolken	63
8.2 Entwicklung eines Verfahrens zur Zuweisung von Semantik	64
8.3 Bauteilorientierte Verknüpfung der semantischen Anreicherung	69
8.4 Übertragung in die Praxis	73
AP 9: Infrastruktur semantisch reicher Digitaler Zwillinge	74
9.1 Umsetzung von Linked Data Ansätzen	74
9.2 Entwicklung einer App für die Vor-Ort-Erfassung	78
AP 10: Validierung	81
10.1 Schadenerkennung	81
10.2 Cross Domain Matching	82
10.3 Linked Data Viewer	84
10.4 Bewertung hinsichtlich praxisrelevanter Kriterien	86
Veröffentlichungen im Rahmen des Forschungsprojekts	87
Literaturverzeichnis	89

Überblick

Die gebaute Infrastruktur bildet die Grundlage für die Gewährleistung der Mobilität unserer Gesellschaft. Ihrer fortwährenden Erhaltung kommt daher eine erhebliche volkswirtschaftliche Bedeutung zu. Gleichzeitig erfordern die begrenzt bereitstehenden Finanzmittel ein striktes Management und die Priorisierung von Instandhaltungsmaßnahmen auf Basis verlässlicher Zustandsdaten und Bewertungsverfahren. Zwar haben digitale Methoden für die Planung und den Bau neuer Infrastrukturbauwerke bereits einen ausgereiften Stand erreicht, für Bestandsbauwerke bestehen jedoch noch signifikante technologische Herausforderungen bei der Digitalisierung.

Ziel des Projektes war es daher, diese Lücke zu schließen, indem das Konzept des Digitalen Zwillinges für Infrastrukturbauwerke entwickelt und detailliert ausgearbeitet wird. Der digitale Zwilling soll die Geometrie, die Eigenschaften und den Zustand eines Infrastrukturbauwerks umfassend widerspiegeln und damit als Entscheidungsgrundlage für Wartungs- und Instandhaltungsmaßnahmen dienen. Wesentliches Ziel der Forschungs- und Entwicklungsarbeiten war es, dass hochwertige Digitale Zwillinge möglichst automatisiert erzeugt und um Daten der Zustandsbewertung und des Monitorings angereichert werden können.

Hierfür wurden im Rahmen dieses Projekts neue computergestützte Verfahren und Methoden entwickelt, erweitert und miteinander integriert. Die dabei verfolgten Ansätze reichen von der Punktwolkenverarbeitung über die KI-basierte Verarbeitung von technischen Zeichnungen und die regelbasierte semantische Anreicherung bis zur Anwendung von Linked-Data-Verfahren für die Verknüpfung der vorliegenden heterogenen Datensätze. Die Erprobung der entwickelten Verfahren erfolgte anhand von konkreten Infrastrukturbauwerken des Straßen- und Wasserstraßenbaus.

Projektpartner

Technische Universität München (TUM)

Der Lehrstuhl für Computergestützte Modellierung und Simulation (CMS) hat seinen Schwerpunkt in der Entwicklung von digitalen Methoden und Verfahren für das Bauwesen und beschäftigt sich intensiv mit der Entwicklung geeigneter Datenstrukturen und Geometrirepräsentation. Er verfügt darüber hinaus über umfassende Expertise in der Punktwolkenverarbeitung und hat vielversprechende Arbeiten im Bereich des Maschinellen Lernens durchgeführt. Im Rahmen des Projekts übernahm der Lehrstuhl CMS die Untersuchungen zur Nutzung parametrisierter Modelle für das Model Fitting und die Verarbeitung von technischen Zeichnungen mithilfe von Machine Learning.

Ruhr-Universität Bochum (RUB)

Der Lehrstuhl für Informatik im Bauwesen der Ruhr-Universität Bochum beschäftigt sich seit vielen Jahren mit der Anwendung von Verfahren der künstlichen Intelligenz, der digitalen Bildverarbeitung und der Erkennung von Objekten. Im Rahmen des Projektes wurden Verfahren zur semantischen und geometrischen Erkennung und Rekonstruktion von Bauwerkselementen sowie zur Detektion und Klassifikation von Schädigungen unter Verwendung von maschinellen Lernverfahren entwickelt.

RWTH Aachen

Das wesentliche Ziel der Forschungs- und Entwicklungsarbeiten an der RWTH Aachen ist es, semantische Bauwerksmodelle des Bestands für digitale Zwillinge mit hohem Automatisierungsgrad zu erzeugen und diese Modelle mit Daten der Zustandsbewertung und des Bauwerksmonitorings anzureichern. Hierfür werden neue computergestützte Verfahren und Methoden entwickelt, erweitert und miteinander integriert. Die im Rahmen des Projekts verfolgten Ansätze adressierten in erster Linie die Verarbeitung und Analyse von 3D-Punktwolken und photogrammetrischen Bildaufnahmen für die KI-basierte Modellerzeugung sowie die Anwendung von Linked-Data-Verfahren für die Verknüpfung mit heterogenen digitalen Datensätzen von Bestandsbauwerken.

Das Geodätische Institut und Lehrstuhl für Bauinformatik & Geoinformationssysteme (gia) untersuchte und entwickelte hybride Ansätze zur automatischen digitalen Ableitung digitaler Bauwerksmodelle aus Bilddaten und 3D-Punktwolken durch Cross Domain Matching. Dazu wurden moderne Verfahren des maschinellen Lernens und der digitalen Bildverarbeitung verwendet und weiterentwickelt. Im Fokus stand dabei das Informed Machine Learning als Ansatz für das maschinelle Lernen.

Der Lehrstuhl für computergestütztes Entwerfen (CAAD) beschäftigte sich mit der Verknüpfung der heterogenen Datensätze anhand von Linked-Data-Verfahren. Gegenstand der Forschung war

die Entwicklung einer übergreifenden Ontologie für Infrastrukturbauwerke, die es ermöglicht, die verschiedenen Daten eines Bauwerks miteinander in Bezug zu setzen und semantisch anzureichern. Im Weiteren wurde eine geeignete Form der Speicherung und Zugänglichkeit dieser Daten untersucht, die die technologische Grundstruktur für den digitalen Zwilling darstellt.

ZPP Ingenieure AG

Die ZPP Ingenieure AG erbringen seit über 40 Jahren Ingenieurleistungen aus den Bereichen Planen, Prüfen, Begutachten, Inspizieren und Erhalten. ZPP verfügt somit über umfangreiche Erfahrungen im Anforderungsmanagement von Bestandsdaten und dem Erhalt und der Instandsetzung von Bestandsbauwerken. Durch aktuelle Projekte zur modellbasierten Bestandsaufnahme und Erstellung von Betreibermodellen besteht umfangreiche Expertise bezüglich Punktdatenaufnahme, -bereinigung und -bearbeitung zur Erstellung von Modellen für die Betriebsphase. Seit ca. 10 Jahren werden Projekte aus allen Bereichen auch modellbasiert abgewickelt, wodurch ein großes Portfolio von Erfahrungen aus der Baupraxis existiert. Durch die Mitarbeit in aktuellen Forschungsprojekten zur Implementierung von BIM im Schienenwegebau verfügt die ZPP Ingenieure AG über umfangreiche Methodenkompetenz bei der Arbeit mit digitalen Bauwerksmodellen. Im Projekt unterstützte ZPP die wissenschaftlichen Partner bei der Anforderungsanalyse, Zusammenstellung von Daten, die Evaluierung der Methoden und Ergebnisse. Des Weiteren wurden Konzepte zur Überführung der Ergebnisse in die Praxis und in eigene Produkte erarbeitet.

Wissenschaftlich-technische Ergebnisse

AP 1: Anforderungsanalyse

In diesem Arbeitspaket wurden die konkreten Anforderungen an die Detaillierung der Bestandsmodelle in Abhängigkeit vom jeweiligen Anwendungsfall erarbeitet. Die Spezifikation erfolgte hinsichtlich Geometrie und Semantik. Die Bestandsmodelle können für verschiedene Aufgaben verwendet werden (z. B. Planungsgrundlage für Erhaltungsmaßnahmen, Dokumentation der Bauausführung, Erhaltungsmanagement etc.). Die Anwendungsfälle und Anforderungen werden mit Hilfe der IDM-Methode (Information Delivery Manual) systematisch erfasst und hinsichtlich der praktischen Relevanz bewertet. Des Weiteren werden konkrete Szenarien erarbeitet, die im Rahmen der Evaluierung getestet werden.

1.1 Systematische Erfassung der Anforderung und Dokumentation mittels IDM

Der BIM-Definitionsgrad nach DIN EN 17412 für einzelne Bauelemente eines Infrastrukturbauwerks ist abhängig von Verwendungszweck der bereitzustellenden Informationen. Im Rahmen des Projektes werden Bestandsmodelle insbesondere für das Erhaltungsmanagement erstellt. Hierzu wurden die wesentlichen Bauteile und Anlagen mit ihren relevanten Eigenschaften sowie deren aktueller Zustand erfasst. Welche Informationen wie in welcher Art und Weise erfasst und dann in ein Bestandsmodell überführt werden, kann mit Hilfe eines Information Delivery Manual (IDM) festgehalten werden. Im Fokus des Projektes lagen hierbei vier wesentliche Informationen:

- Identifikation des Typs eines Bauteils oder einer Anlage
- Erfassung der geometrischen Abmessungen
- Ermittlung von semantischen Informationen (z. B. Baustoffe, Kennwerte etc.)
- Detektion und Klassifikation des aktuellen Zustands (z. B. Risse, Abplatzungen etc.)

Die IDM-Methode sieht vor, dass nach Festlegung eines Verwendungszwecks (auch als Use Case bezeichnet) ein Prozessablauf beschrieben wird. Der Prozessablauf (auch als Process Map bezeichnet), beschreibt dabei im Wesentlichen den Informationsfluss zwischen verschiedenen Akteuren. Dabei werden Informationen an bestimmten Stellen übergeben, die als Data Drops bezeichnet werden. Es wurde im Zusammenspiel mit den Projektpartnern definiert, welche Informationen von welcher Stelle bereitgestellt werden können und wie diese anschließend in ein Bestandsmodell zu überführen sind. Das Information Delivery Manual wurde dabei kontinuierlich angepasst und weiter konkretisiert.

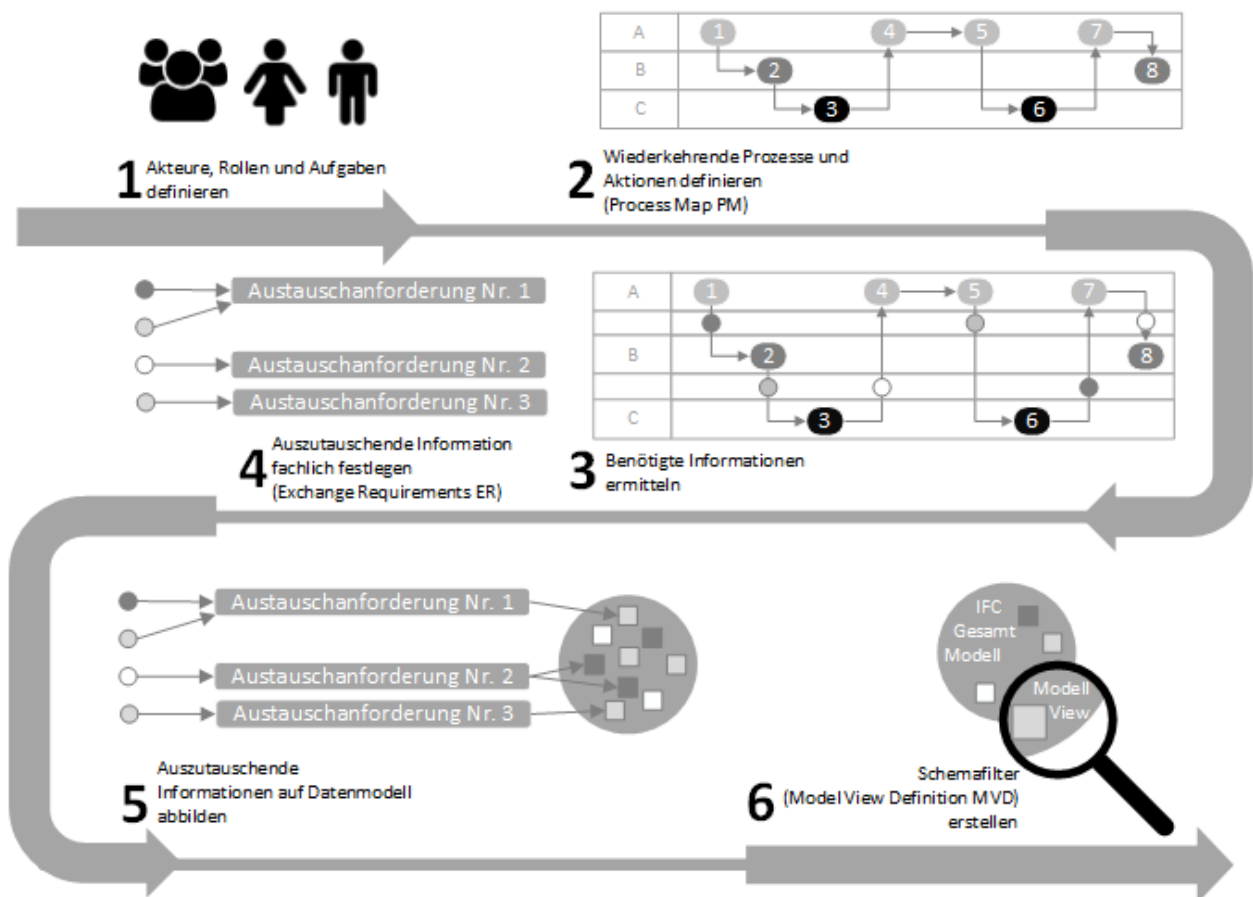


Abbildung 1: Ermittlung von Informationsanforderung unter Berücksichtigung der IDM-Methode (Quelle: (BEETZ et al., 2015))

1.2 Erfassung der Anforderungen an Bestandsmodelle im Bereich Brücke

In diesem Arbeitsschritt wurden die wesentlichen Erkenntnisse aus (Forschungs-)Projekten, die bereits in diesem Bereich durch die TUM durchgeführt wurden, zusammengetragen sowie eine Literaturrecherche zum Stand der Technik durchgeführt.

Zusammengefasst ließ sich dabei feststellen, dass in den vergangenen 15 Jahren im Rahmen verschiedener Projekte umfangreiche Untersuchungen zur Anwendung von BIM im Kontext der Planung, der Ausführung sowie des Betriebs und der Erhaltung von Brücken durchgeführt worden sind und sich dadurch die Anforderungen an entsprechende Bestandsmodelle ableiten lassen. Dabei haben sich mehrere Projekte mit der Konzeption eines generellen Vorgehens zur Nutzung von BIM im Erhaltungsmanagement beschäftigt und liefern wertvolle Erkenntnisse für die Umsetzung einer durchgängigen modellbasierten Methode. Die Modellinhalte bedingen sich allerdings durch Anwendungsfälle und Prozesse, die auf Basis bestehender Arbeitsabläufe, Normen und Richtlinien sowie den Strategien des Bundes definiert werden müssen. Die Veröffentlichung des IFC-Bridge Standards stellt dabei einen wesentlichen Fortschritt dar. IFC-Bridge bildet eine sehr gute Grundlage zur Speicherung von Bestandsmodellen im Bereich Brücke, die auch im Rahmen dieses Projekts genutzt werden kann.

Im Projekt wurde unter Einbeziehung der Bundesanstalt für Straßenwesen (BASt) untersucht, inwieweit Daten aus SIB-Bauwerke genutzt werden können, um eine für das Projekt nutzbare Brückentypologie zu entwickeln. Zusätzlich wurden die Informationen aus SIB-Bauwerke und der ASB-Ing genutzt, um die Anforderungen an Bestandsmodelle im Kontext dieses Projekts praxisgerecht zu definieren. Dabei wurden auch Ergebnisse aus dem BASt-Forschungsprojekt FE 15.0622/2016/RRB "Building Information Modeling (BIM) im Brückenbau", das u. a. durch die TUM bearbeitet wurde, berücksichtigt.

1.3 Erfassung der Anforderungen an Ingenieurbauwerke des Wasserbaus

Die VV-WSV 1102 ist eine Verwaltungsvorschrift des Bundesministeriums für Verkehr und digitale Infrastruktur für den Geschäftsbereich der WSV. Die im Objektkatalog definierten Begriffe werden insbesondere bei der Identifikation der baulichen und sonstigen technischen Anlagen an den Bundeswasserstraßen verwendet. Die im Objektkatalog definierten Objektarten werden insbesondere bei der Identifizierung der Objekte des Bestandswerkes bzw. der Wasserstraßendatenbank verwendet, wobei die Konstanz der Verschlüsselung und einheitliche Verwendung der Begriffe eine wesentliche Rolle spielt. Der Objektkatalog gliedert sich in die Teile I Erläuterungen, II Begriffsbestimmungen, III Objektartengliederung, IV Objektteilgliederung und V Stichwortverzeichnis. Der Objektkatalog ist ein klassifizierendes Ordnungssystem. Für die Objektarten (Teil III) und Objektteile (Teil IV) sind Kennzahlen festgelegt. Objektgruppen, Objektgruppen und Objektuntergruppen bilden den ersten Teil einer Kennzahl, anschließend können Objektteile durch weitere drei Zahlen genau spezifiziert werden. Der Objektkatalog steht digital in Form einer Excel-Tabelle zur Verfügung. Somit besteht eine Anforderung an die Bestandsmodellierung von Ingenieurbauwerken des Wasserbaus, alle relevanten Objektteile hinsichtlich des Objektkatalogs zu klassifizieren. Im Rahmen des Projektes konnten nicht für alle Objektgruppen digitale Verfahren zur Generierung von Bestandsmodellen umgesetzt werden.

Zur Unterstützung bei der Schadensklassifizierung an Verkehrswasserbauwerken wurde durch die BAW ein entsprechendes Merkblatt veröffentlicht. Die Ausführungen beziehen sich auf die Bauwerksprüfung und Bauwerksüberwachung nach VV-WSV 2101. Dadurch wird eine Grundlage geschaffen, um Schäden an Verkehrswasserbauwerken einheitlich erfassen und bewerten zu können. Die Ergebnisse werden anschließend im Programmsystem WSVPruf verarbeitet. Es dient dabei der einheitlichen Erfassung, Dokumentation und Auswertung von Ergebnissen der Bauwerksinspektion. Die Bauwerksinspektion gliedert sich generell in zwei wesentliche Bereiche; a) die Bauwerksprüfung und b) die Bauwerksüberwachung. Das System ist sowohl für die Prüfung als auch für die Überwachung nutzbar und anzuwenden. Das Programm setzt sich aus den Komponenten Anlagenmanagement, Inspektionsmanagement und Schadensmanagement zusammen. Das Programmsystem liefert somit eine wichtige Quelle für die Bestandsmodellierung.

1.4 Analyse von Datenquellen und Notwendigkeiten der Verknüpfung

Das gja hat diverse Datenquellen im Hinblick auf die Verwendung für maschinelle Lernverfahren des Cross Domain Matching (siehe AP 3) analysiert. Die Forschungshypothese geht davon aus, dass

nur durch eine synergetische Verknüpfung von komplementären Informationen aus verschiedenen Datenquellen und der damit erreichten Erhöhung der Informationsdichte ein optimales Ergebnis in der automatisierten Modellableitung mittels maschineller Lernverfahren erreicht werden kann. Als Primärdatenquellen wurden photogrammetrische Bildaufnahmen (terrestrisch oder auch aus der Luft erfasst), daraus durch Bildzuordnungsverfahren abgeleitete 3D-Punktwolken sowie 3D-Laserscans identifiziert. Da die benötigte Auflösung und Genauigkeit von den später in AP 3 untersuchten maschinellen Lernverfahren abhängen, wurden zunächst möglichst hochaufgelöste Daten verwendet. Geringere Auflösungen und Genauigkeiten können aus diesen Daten rechnerisch erzeugt werden.

Als Datenquellen für die Punktwolken wurden terrestrische Laserscanner und kamerabestückte Unmanned Aerial Vehicles (UAVs) verwendet. Die Punktwolken besitzen neben den 3D-Positionsdaten mindestens RGB-Farbwerte und ggf. Intensitätswerte für jeden Punkt, um auch diese zusätzlichen Informationen für die in AP 3 zu entwickelnden Verfahren zu nutzen. Beide Quellen haben ihre jeweiligen Vor- und Nachteile: Terrestrische Laserscans sind aufwändiger durchzuführen, haben jedoch eine höhere räumliche Auflösung und Genauigkeit sowie weniger Rauschen, und können auch in Bereichen ohne ausreichende Beleuchtung sowie mangelnder Himmelsfreiheit (z.B. unter Brücken) verwendet werden. Mit UAVs lassen sich größere Flächen effektiver erfassen. Die resultierenden Punktwolken beinhalten allerdings potenziell mehr Rauschen, haben keine homogene Genauigkeit und die Auflösung hängt stark von der Bildauflösung und Flughöhe ab.

Ein Datensatz bestehend aus Daten beider Aufnahmeverfahren bietet daher eine gute Grundlage für das Testen der verschiedenen Ansätze des maschinellen Lernens, insbesondere im Hinblick auf verschiedene Anwendungsszenarien bezogen auf die geforderte Modellierungsgenauigkeit, die räumliche Ausdehnung und nicht zuletzt damit verbundene Wirtschaftlichkeitsaspekte. Die Luftbilder, die aus den Flügen mit den UAVs entstehen, können zusätzlich zu den Punktwolken in AP 3 für das Cross Domain Matching verwendet werden.

Die Untersuchungen zu den verwendeten bildbasierten Klassifizierungsverfahren (AP 3) haben inzwischen gezeigt, dass hohe Bildauflösungen und Punktwolkendichten für diese Verfahren von Vorteil sind. Hohe Bildauflösungen haben zu feineren Klassifizierungsmasken geführt, hohe Punktwolkendichten ermöglichen eine lückenlose Zuordnung der Bilddaten zu den Punktwolken. Um Verdeckungen aus einzelnen Perspektiven auszugleichen und fehlerhafte Label einzelner Aufnahmen zu korrigieren, sind zudem Bildaufnahmen aus verschiedenen Kamerapositionen wünschenswert.

CAAD hat verschiedene Datengrundlagen untersucht, welche zur Erstellung einer Ontologie und übergeordneten Struktur der Daten herangezogen werden können. Im Bereich des Brücken- und Tunnelbaus stellt die „Anweisung Straßeninformationsbank, Teilsystem Bauwerksdaten (ASB-ING)“ (BUNDESMINISTERIUM FÜR VERKEHR, BAU UND STADTENTWICKLUNG, ABTEILUNG STRASSENBAU., 2013) (siehe AP 2) eine umfassende und grundlegende Klassifizierung bereit, welche sowohl geometrische und semantische Daten beinhaltet, als auch Metadaten bezüglich der Verwaltung und Inspektion umfasst. Für Wasserbauwerke gibt es analog zu ASB-ING den „Objektkatalog - Verwaltungsvorschrift der Wasser- und Schifffahrtsverwaltung des Bundes“ (ObKat VV-WSV 11 02), der ein ähnliches Schema zur Verfügung stellt.

Auch die entwickelte Erweiterung des offenen Standards Industry Foundation Classes (IFC), „IFC-Bridge“ wurde als weiteres Klassifizierungssystem für Brückenbauwerke identifiziert. Im Bereich der Wasserbauwerke wird IFC derzeit um den Standard IFC Ports & Waterways (IFC P&W) weiterentwickelt. IFC-Bridge und IFC P&W sind in der jüngst veröffentlichten Version 4.3 des IFC-Standards enthalten, der damit ein offenes Datenaustauschformat für geometrische und semantische Daten von Brücken- bzw. Wasserbauwerken bereitstellt.

Im Bereich der Schadenskartierung kann die Damage Topology Ontology (DOT) (HAM DAN et al., 2019) herangezogen werden (siehe AP 3), die verschiedene Schadensklassifikationen bereitstellt und es ermöglicht, die Schäden mit den Bauteilen in Bezug zu setzen.

Bei den bisher genannten vorhandenen Datengrundlagen fehlt jedoch die Unterstützung zur Abbildung und Verknüpfung von Bild- und Punktwolkendaten sowie technischen Zeichnungen, innerhalb eines Bauwerksmodells. Hier bestand Entwicklungsbedarf zur Erstellung einer geeigneten Struktur, die es ermöglicht, diese Daten ebenfalls systematisch zu erfassen und innerhalb des Modells räumlich zu verorten.

Um einen vollständigen digitalen Zwilling abzubilden benötigt es primär einen Weg, alle Klassifizierungen und die zugehörigen Elemente der verschiedenen Domänen miteinander zu verknüpfen. So kann ein Datenmodell entstehen, das bspw. IFC-Bauteile mit dem dazugehörigen Objekt aus dem ASB-ING-Objektmodell verbindet. Diese können mit Punktwolken, Bildern und Zeichnungen verknüpft sein, in welchen sie abgebildet sind.

AP 2: Ermittlung der Datengrundlagen

Für die Erzeugung von Referenzdaten, die für alle folgenden Arbeitspakete (AP 3-9) zur Verfügung standen, wurden geeignete Bauwerke im Zuständigkeitsbereich des BMDV bzw. der untergeordneten Bundesbehörden ausgewählt. In Absprache mit den verantwortlichen Stellen wurden die benötigten Eingangsdaten (Punktwolken, Bilder, technische Zeichnungen, technische/funktionale Daten etc.) identifiziert, bewertet und zusammengetragen bzw. im Bedarfsfall – insbesondere Punktwolken und Bilder – erhoben sowie den beteiligten Partnern zur Verfügung gestellt. Dabei wurden insbesondere auch Daten berücksichtigt, die bereits in anderen Kooperationsprojekten (z. B. Kooperation der RWTH mit der BAW im Projekt „Neue Schleuse Trier“ und Beratung der RUB im Rahmen des Pilotprojektes „Schleuse Wedtlenstedt“) bereits erhoben wurden.

2.1 Schaffung der Datengrundlagen im Bereich Brückenbau

Es galt, geeignete Brückenbauwerke für die Erprobung der entwickelten Ansätze zu identifizieren, und entsprechende Daten zu erfassen.

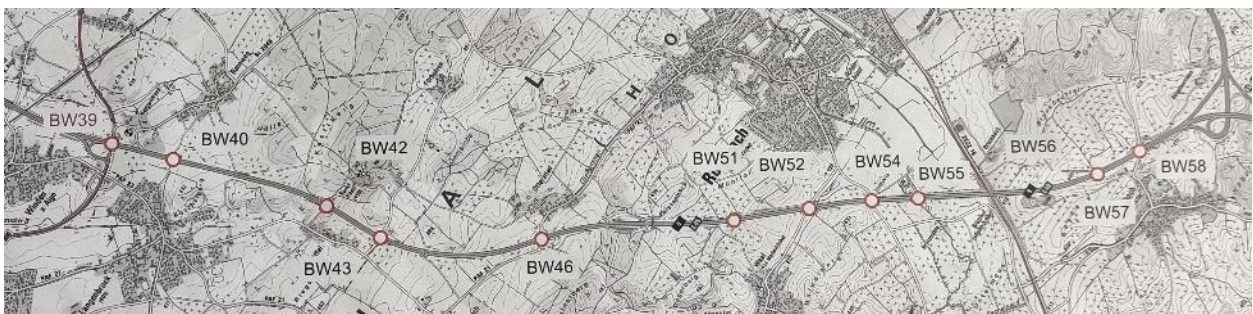


Abbildung 2: Standorte der Brückenbaustellen auf der A 9 Nürnberg-München (Quelle: AdB Südbayern).

Dazu wurden mit freundlicher Genehmigung der Autobahn GmbH des Bundes, Niederlassung Südbayern (AdB Südbayern) Drohnenbefliegung der zwölf Brückenbaustellen im Erhaltungsprojekt Anschlussstelle Langenbruck – Autobahndreieck Holledau auf der A 9 Nürnberg-München durchgeführt (siehe Abbildungen 2 und 3).

Mittels des durch die Befliegung gewonnenen Bildmaterials konnten durch den Einsatz photogrammetrischer Methoden Punktwolken (siehe Abbildung 4) der Bauwerke in verschiedenen Bauzuständen generiert werden. Im kommenden Jahr 2021 können zusätzlich Baustellen der Gegenrichtung im Jahr 2021 befliegen und erfasst werden. Die so generierten Daten bilden voraussichtlich eine ideale Grundlage für die Entwicklung und Validierung der Methoden in diesem Forschungsprojekt.

Die erzeugten Daten wurden allen Projektpartnern zur Verfügung gestellt und seitens der TUM bereits als Grundlage für die optimierte Anpassung parametrischer Modelle genutzt. Zusätzlich wurden die zu den Projekten gehörenden Pläne für die Arbeiten in AP 7 eingesetzt.



Abbildung 3: Bauwerk 43 auf der A 9 Nürnberg-München (Quelle: TUM).



Abbildung 4: Photogrammetrisch erzeugte Punktwolke eines Brückenbauwerks (Quelle: TUM).

2.2 Auswahl geeigneter Datensätze und Datenerfassung an ausgewählten Bauwerken

Als Datengrundlage im Bereich Wasserbau konnte seitens des gfa die hochqualitative geodätische Bestandsaufnahme der Schleusenanlage „Neue Schleuse Trier“ identifiziert werden, die im Rahmen des Forschungs- und Entwicklungsprojektes BIM4LOC (BECKER & KNAPP, 2020) erzeugt wurde (Abbildung 5). Dabei wurden verschiedene Verfahren wie das terrestrische 3D-Laserscanning (inkl. der Erfassung von RGB- und Intensitätswerten) und photogrammetrische Bildaufnahmen, terrestrisch wie auch UAV-gestützt eingesetzt. Der Anschluss an das übergeordnete geodätische Festpunktfeld in Lage und Höhe wurde durch Verknüpfungsmessungen an entsprechende Festpunkte hergestellt. Abbildung 6 zeigt die Verteilung der Scanpositionen.




Abbildung 5: Eingefärbte Punktwolke der Schleuse in Trier (Quelle: gia).




Abbildung 6: Ausschnitt der Punktwolke mit dargestellten Scanpositionen (Quelle: gia).

Die einzelnen Scanneraufnahmen wurden mit einem Verfahren der Multistationsausgleichung gegenseitig registriert, d.h. in ein gemeinsames Koordinatensystem überführt, bei dem im Prinzip ein Iterative Closest Points (ICP)-Algorithmus mit vorgelagertem Plane Patch-Filter verwendet wird.

Abbildung 7 zeigt die Verteilung der Normalen der Ebenen, die verwendet wurden, um die Multistationsausgleichung vorzunehmen. Die Normalen sind räumlich gut auf der Hemisphäre verteilt, was eine hohe Genauigkeit beim Zusammenführen (Registrierung) der Einzelscans gewährleistet. Die Verteilung der Abweichungen (Residuen) wird in Abbildung 8 dargestellt. Es liegt annähernd eine Normalverteilung vor; die Standardabweichung beträgt 5 mm. Die komplette Punktwolke besteht aus 1,3 Milliarden Punkten aus 173 Scanpositionen, die mit dem terrestrischen Laserscanner RIEGL VZ-400 aufgenommen wurden. Pro Scanposition wurden mit der Spiegelreflexkamera Nikon D800 7 Bilder aufgenommen, woraus insgesamt 1211 Bilder resultierten.

Eine detaillierte Übersicht der Daten ist in Tabelle 1 aufgelistet. Jeder Punkt des Datensatzes besitzt eine 3D-Koordinate, einen RGB-Farbwert und eine Intensität, wodurch die Anforderungen, die in Abschnitt 1.4 ermittelt wurden, erfüllt werden. Es wurden außerdem Luftbilder mit einem UAV erfasst, die zu einem Orthofoto kombiniert wurden.




Abbildung 7: Verteilung der Ebenennormalen der terrestrischen Laserscans (Quelle: gia).




Abbildung 8: Registrierungsgenauigkeit der terrestrischen Laserscan (Quelle: gia).

Tabelle 1: Übersicht über die Datenmengen bei der Erfassung der Neuen Schleuse Trier.

Daten	Menge
Scannpositionen gesamt	173
Anzahl Scanpunkte	1263 Mio.
Scanauflösung	0,06°
Punkte / Scanposition (Mittel)	6 – 8 Mio.
Fotos pro Scanposition	7
Fotos gesamt	1211
Datenmenge Fotos (JPG)	10 GB
Datenmenge Rohscans	13 GB
Datenmenge TLS Punktdatenbank	26 GB

Als Grundlage für die Untersuchungen im Bereich Brückenbau wurde am 01.10.2021 eine Autobahnbrücke an der A99 bei München als Referenzobjekt für die Weiterentwicklung der Segmentierungs- und Modellierungsverfahren erfasst. Verwendet wurde der terrestrische Laserscanner RIEGL VZ-400 mit aufgesetzter Nikon D800 Spiegelreflexkamera, so dass Laserscanner-Punktwolken in Kombination mit photogrammetrischen Bildern erfasst werden konnten (siehe Abbildung 9). Die Brücke wurde weitestgehend verdeckungsfrei von 20 verschiedenen Scanpositionen inkl. sieben Bildern je Einzelscan erfasst. Die Bilddaten wurden zudem genutzt, um die Punktwolke einzufärben. Insgesamt wurden so 140 Bilder und ca. 173 Mio. Punkte mit RGB-Farb- und Intensitätswerten gewonnen. Die Einzelscans wurden im Nachgang mithilfe eines Iterative Closest Points (ICP)-Verfahrens miteinander registriert, d.h. in ein gemeinsames Koordinatensystem überführt. Vor der Registrierung wurde ein Plane-Patch Filter angewendet, welcher neben einer vereinfachten Registrierung eine Abschätzung der Scanqualität über die Verteilung der Normalen zulässt. Abweichungen (Residuen) hinsichtlich der Distanz liegen innerhalb eines 97,5%-Quantils je nach Scan zwischen 5,4 mm und 14,7 mm (für eine detaillierte Analyse der Einzelscans, siehe Abbildung 10).



Abbildung 9: Beispielfoto und Punktwolkenausschnitt des erfassten Referenzobjekts, welches am 01.10.2021 an der A99 erfasst wurde.

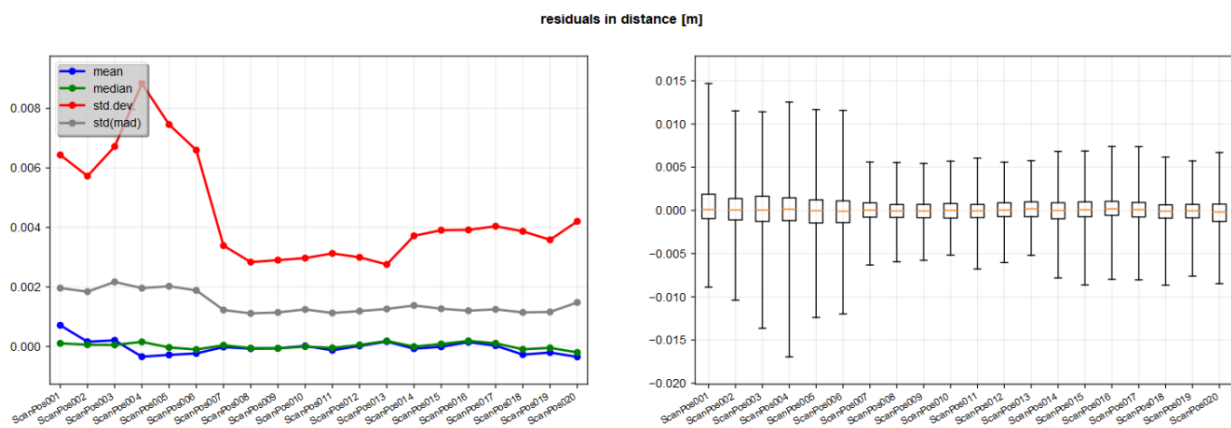


Abbildung 10: Fehlerresiduen bezüglich der Distanz für die Einzelscans des Referenzobjekts an der A99.

Die erfassten Daten entsprechen den ermittelten Anforderungen (vgl. Abschnitt 1.4). Sie wurden den Projektteilnehmern bereitgestellt, damit die Untersuchungen und Entwicklungen der verschiedenen Projektbeteiligten auf einer einheitlichen Datengrundlage erfolgen können.

In der Umgebung von Aachen wurden vom gia ergänzend weitere Bestandsobjekte der Straßeninfrastruktur mittels terrestrischen Laserscannings inklusive photogrammetrischer Bildaufnahmen erfasst und für das maschinelle Lernen aufbereitet, indem manuell Objektklassen in den Punktwolken markiert (gelabelt) werden. Die gesammelten Daten (16 Datensätze insgesamt) umfassen hochaufgelöste Punktwolken mit RGB-Farbattributen und Intensitäten sowie zugehörige Bildern, wobei die Punktwolken manuell in einzelne Bauteile zerlegt und für den Einsatz der maschinellen Lernverfahren dokumentiert wurden. Ebenfalls aufbereitet wurden UAV-Bildaufnahmen, die von der TUM bereitgestellt wurden.

Als weitere Datenquelle wurden frei verfügbare Bilder aus Suchmaschinen evaluiert, allerdings erwiesen sich diese nicht als hilfreich, da nur wenige Bilder den Anforderungen des Projekts gerecht wurden. Hieraus folgt erschwerend ein damit verbundener manueller Evaluierungsaufwand bei der Suche geeigneter Bilder.

Das CAAD der RWTH untersucht potenzielle Datenquellen projektbezogener Datensätze, wie z.B. aus „SIB Bauwerke /ASB_ING“, technischen Zeichnungen, Punktwolken, Schadenskartierungen (Rissbilder) etc.

SIB-Bauwerke – ASB ING

Die Straßeninformationsbank Bauwerke (SIB Bauwerke)(WPM INGENIEURE GMBH, 2022) ist eine umfassende Datenbank für die Ingenieurbauwerke der Infrastruktur des Bundes (siehe Abbildung 11). Sie ermöglicht eine einheitliche Erfassung, Verwaltung und Auswertung dieser Bauwerke. Die Daten können zentral und dezentral verwaltet werden. Mit dem Programmsystem SIB-Bauwerke wird auch die Archivierung digitaler Dokumente betrieben. Mögliche Anbindungen, Erweiterungen oder Transformationen dieser in vielen öffentlichen Verwaltungen im Einsatz befindlichen Datenbanken werden untersucht.

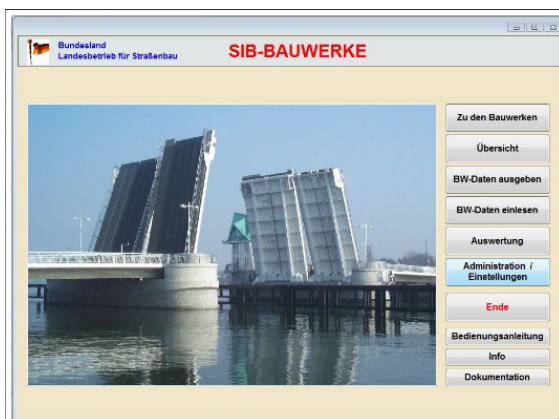


Abbildung 11: Startfenster SIB-Bauwerke¹.

Durch die Kooperation mit dem Projektpartner ZPP Ingenieure, kann auf Datensätze aus SIB-Bauwerke zugegriffen werden. Die Bereitstellung dieser Daten ermöglicht es, die zu entwickelnde Struktur des digitalen Zwillings hinsichtlich der Kompatibilität auf die bestehenden Datenstrukturen auszurichten. Außerdem wird durch eine Analyse der Datensätze ersichtlich, welche Informationen bereits über das Bauwerk vorhanden sind, und welche zusätzlichen Daten noch erfasst oder generiert werden müssen, um eine vollständige digitale Repräsentation des Bauwerks zu ermöglichen.

Da die Mehrzahl aller Ingenieurbauwerke des Bundes bereits in diesem Programm erfasst sind, ist die Nutzung und effiziente Verarbeitung dieser Daten essenziell, um digitale Zwillinge von bestehenden Bauwerken zu realisieren. Es ist möglich, den gesamten Datensatz einer Brücke als sogenannte „CAB-Datei“ zu exportieren. Dieses Containerformat enthält die einzelnen Datenbanktabellen aus der Anwendung welche die Bauwerks- und Inspektionsdaten speichern, sowie einen Ordner mit allen vorhandenen Plan- und Bilddaten. Diese Daten können so im Weiteren Prozess in den digitalen Zwilling eingearbeitet werden.

Die ASB-ING (Anweisung Straßeninformationsbank, Teilsystem Bauwerksdaten)

Das Datenmodell ASB-ING dient als Grundlage für das Programmsystem SIB-Bauwerke und beinhaltet die Klassifikationen von Infrastrukturbauwerken, wie Brücken und Tunneln. Es beinhaltet die Definitionen der Bauteile und deren Eigenschaften, der Inspektionsdaten, wie auch der Metadaten über ein Objekt. Auch die Beziehung dieser Daten zueinander wird festgelegt. Im Weiteren sind einige ausgewählte Beispiele gezeigt (siehe Abbildungen 13 und 15).

¹Quelle: https://www.wpm-ingenieur-re.de/include.php?path=sib_bauwerke&pid=21&subid=3

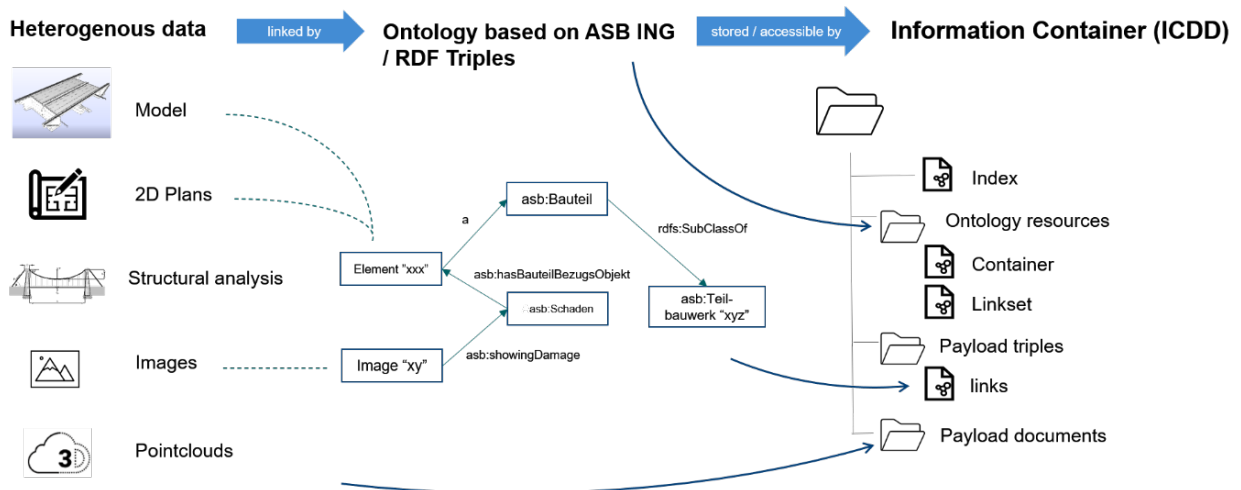


Abbildung 12: Verknüpfung heterogener Daten durch Linked-Data-Verfahren und Speicherung in ICCD-Containern.

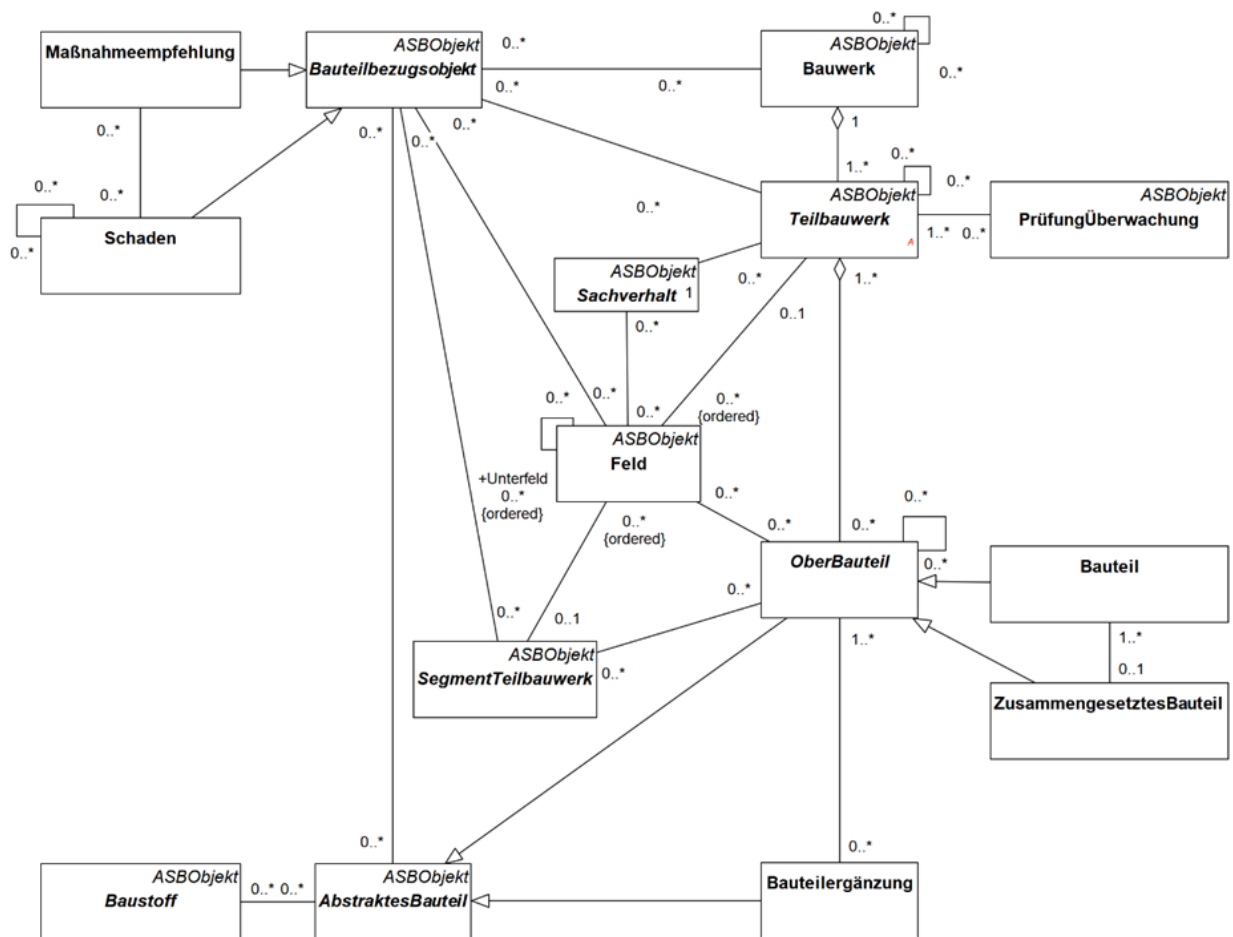


Abbildung 13: UML Übersichtsdiagramm der ASB-ING (Quelle: Bundesministerium für Verkehr, Bau- und Stadtentwicklung).

Im Rahmen der ersten Arbeitsschritte wurde untersucht, wie das Datenmodell der ASB-ING zusätzlich zu der derzeitigen nativen Repräsentation als UML/XMI als Linked-Data-Modell / Ontologie (RDF/S, OWL, SKOS etc.) abgebildet werden kann (siehe Abb. 11). Durch eine Konvertierung und

Transformationen können so die SIB-Bauwerke Datensets mit standardisierten Technologien bspw. in ICCD-Containern strukturiert abgelegt und verknüpft werden (siehe Abbildung 12).

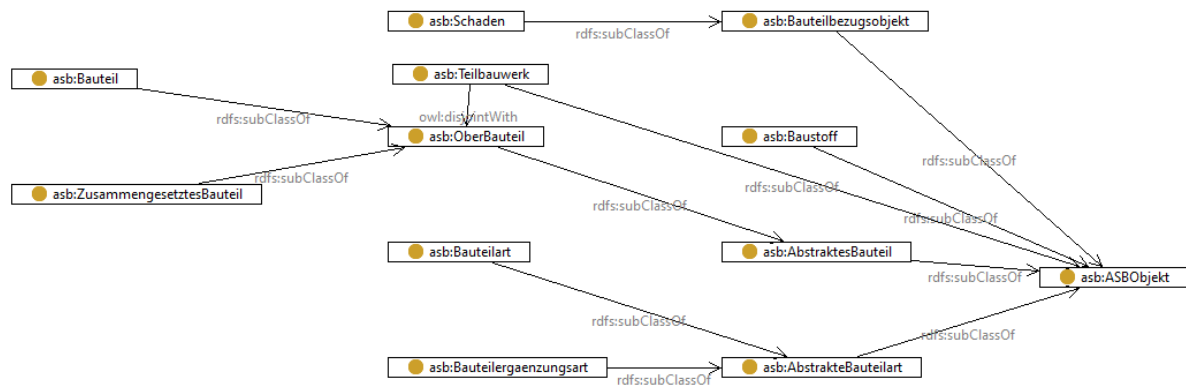


Abbildung 14: Ausschnitt der ASB-ING-Struktur als Linked Data Model.

2.3 Methode zur Erzeugung synthetischer Punktwolken als Trainingsgrundlage für KI-Verfahren

Im Rahmen dieses Arbeitspaketes hat die Ruhr-Universität Bochum eine Methodik erarbeitet, die es ermöglicht, Punktwolken als Trainingsgrundlagen für Methoden des maschinellen Lernens künstlich zu erzeugen. Hierzu wurden verschiedene Frameworks getestet und verglichen, die es ermöglichen, einen wirklichkeitstreuen Laserscan an einem virtuellen Bauwerksmodell vorzunehmen.

Computertechnische Umsetzungen dieser physikalischen Simulation sind unter anderem von der Hochschule für Technik und Wirtschaft Dresden in Form der Blender Erweiterung BlendSor oder als eigenständige Applikation HELIOS des Geographischen Institutes der Universität Heidelberg erfolgt. Große Variabilität und Erweiterbarkeit wurde im Programm HELIOS (Heidelberg LiDAR Operations Simulator) festgestellt. HELIOS wurde in der Programmiersprache Java implementiert. Das System ist modular aufgebaut, sodass auf Basis dessen verschiedene Arten von Anwendungen entwickelt werden können, die die Bibliothek nutzen. Die RUB hat Laserscan-Simulationen anhand einiger verschiedener BIM-Modelle durchgeführt und die erzeugte Punktwolke validiert. Als Fortsetzung dieser Ergebnisse soll das Programm einerseits auf die Bedürfnisse der Forschungsziele einer automatisierten Gebäuderekonstruktion angepasst werden. Dies beinhaltet zum Beispiel eine performantere Implementierung der Algorithmen. Zusätzlich soll eine weitestgehend automatisierte Pipeline programmiert werden, sodass die Schritte von Modellerzeugung bis hin zum Export einer Punktwolken-datei ohne weitere Eingriffe des Nutzers erfolgen.

Für die synthetische Erzeugung verschiedener Punktwolken wurden anschließend Modelle erstellt, bei denen alle signifikanten Parameter variabel definiert wurden. Dadurch können schnell viele

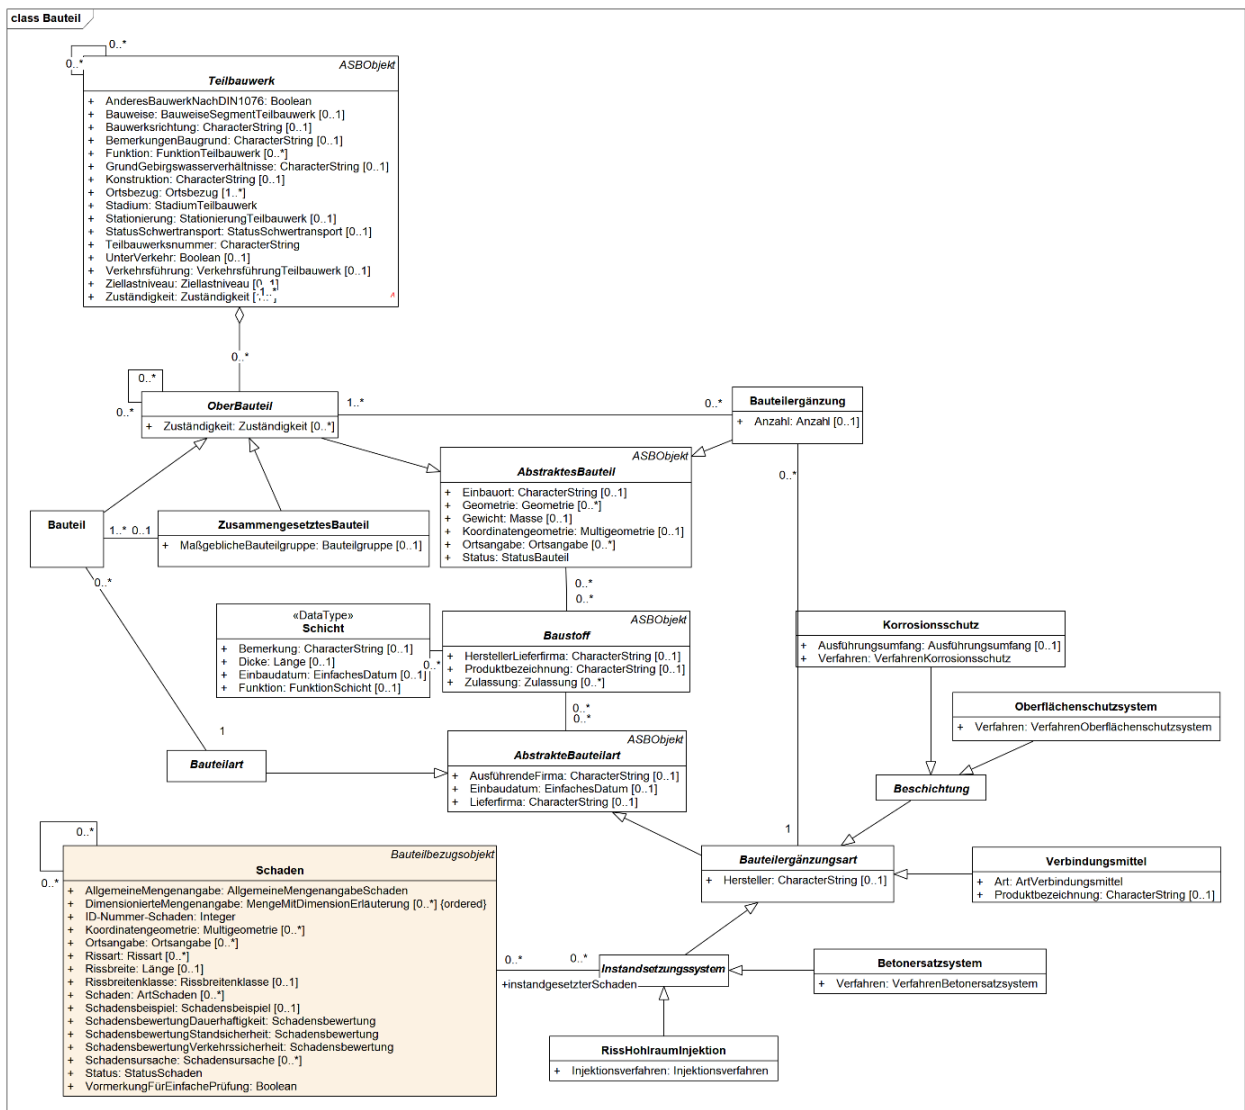


Abbildung 15: UML Bauteildiagramm der ASB-ING.




Abbildung 16: Erzeugung von synthetischen Punktwolken auf Basis eines BIM-Modells.

verschiedene Bauwerksmodelle generiert werden. Diese Modelle können anschließend für die Simulation des Laserscannings zugrunde gelegt werden. Dadurch kann die Quantität der Trainingsdaten, die für die Entwicklung von Methoden des maschinellen Lernens zugrunde liegen müssen, gedeckt werden. Auf diese Weise wird lediglich ein kleiner realer Datensatz benötigt, der durch beliebig viele synthetische Daten, erzeugt in einer virtuellen 3D Umgebung, sinnvoll ergänzt werden kann.

Im Bereich des Wasserbaus wurden die BIM-Modelle zur Schleuse Wedtenstedt analysiert. Die Schleuse Wedtenstedt ist die Eingangsschleuse zum SKS und soll für den Schiffsverkehr mit übergroßen Großmotorgüterschiffen sowie 185 m langen Schubverbänden ausgebaut werden. Das Bauvorhaben „Ersatzneubau der Westkammer der Schleuse Wedtenstedt“ umfasst den Bau einer Schleusenkammer, mit einem Achsabstand von 29 m, neben der bereits vorhandenen Westkammer. Die Vorhäfen sind hierzu entsprechend aufzuweiten. Die Schleusenkammer wird als Stahlbetonkonstruktion in einer gedichteten Baugrube hergestellt. Bei den Stahlwasserbauteilen werden alle wesentlichen Elemente der Schleusenstandardisierung umgesetzt. Die Hauptabmessungen der neuen Kammer betragen 190 m Nutzlänge, 12,50 m Nutzbreite und 4 m Wassertiefe. Die Hubhöhe beträgt 9,30 m. Das Projekt Schleuse Wedtenstedt wird derzeit mittels konventioneller Planung durch das Neubauamt Hannover betrieben und vorrangig im eigenen Hause bearbeitet. Parallel dazu soll das Projekt mit BIM nachvollzogen werden. Für die Schleuse Wedtenstedt existiert bereits ein BIM-Modell, welches hinsichtlich der enthaltenden Bauwerke und Bauteile analysiert wurde.




Abbildung 17: BIM-Modell der Schleuse Wedtenstedt.

2.4 Bereitstellung von Daten durch den Industriepartner

Durch ZPP wurden die anderen Partner bei der Aufbereitung der vorhandenen Daten unterstützt.

Aufgrund der langjährigen Tätigkeit im Bereich der Bauwerksprüfung und der sich daraus ergebenden Kontakte, war es der ZPP Ingenieure AG möglich, dem Forschungsprojekt einen umfangreichen Datensatzbestand bereitzustellen. Die eingeschränkten Exportmöglichkeiten von SIB-Bauwerke bedingen jedoch eine intensive Analyse der Datenstrukturen, um eine bedarfsgerechte Bereitstellung der Daten zur weiteren Nutzung im Projekt zu ermöglichen.

Das von SIB-Bauwerke verwendete Dateiformat ist das proprietäre Format CAB. Dieses kann nur durch SIB-Bauwerke und nur mit einer entsprechenden Lizenz geöffnet werden und eignet sich in dieser Form somit nur bedingt zur Nutzung in diesem Projekt. Den Projektpartnern wurden die in diesen Datensätzen enthaltenen Informationen mittels Konvertierung in nutzbare Formate zur Verfügung gestellt.

Es wurden digitalisierte Bauwerkspläne vergangener Brückenprojekte zur Verfügung gestellt, um die Robustheit des Konzepts zum automatisierten Auswerten von Bauwerksplänen zu überprüfen. Hierbei wurde auf eine vielfältige Auswahl an Plänen wert gelegt, um möglichst alle in der Praxis vorkommenden Qualitätsunterschiede von Plänen berücksichtigen zu können. Beispielhaft ist in 18 ein aus den übergebenen Daten ausgewählter vergilbter Scan einer Brücke dargestellt.

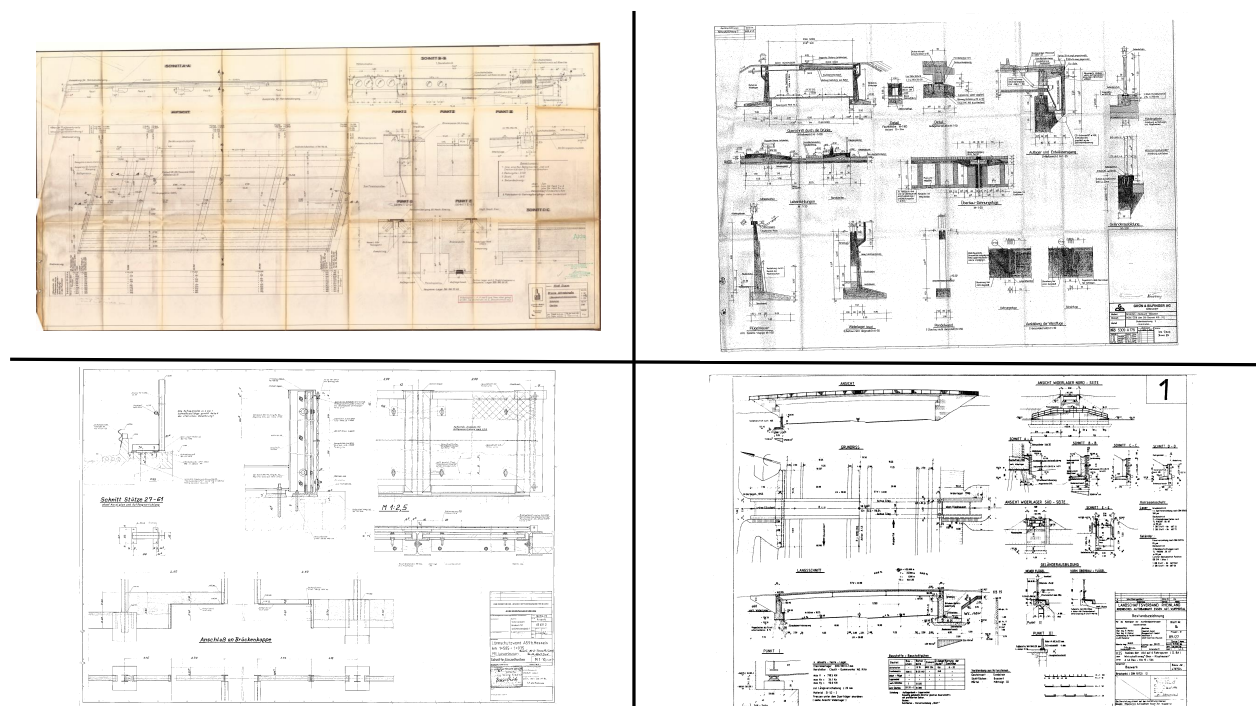


Abbildung 18: Beispiele unterschiedlicher Planqualitäten von Bestandsplänen (Quelle: ZPP Ingenieure AG).

AP 3: Modellgenerierung durch Cross-Domain-Matching

Im Zentrum dieses Arbeitspakets stand die kombinierte Auswertung von Daten verschiedener Erfassungssensoren — insbesondere Punktwolken und Fotos. Das Feature Matching zwischen Datensätzen aus verschiedenen Quellen (cross-domain matching) erlaubt eine komplementäre Informationsableitung für eine höher automatisierte 3D-Modellbildung inklusive der Erfassung der Semantik. Hierzu werden Verfahren zur geometrischen Strukturanalyse weiterentwickelt und mit Methoden der künstlichen Intelligenz (KI) verknüpft. In Anlehnung an aktuelle Arbeiten aus dem Bereich des Maschinellen Lernens wurden hierfür bekannte Verfahren wie Entscheidungsbäume und Neuronaler Netze insbesondere für Materialerkennung, Objektregistrierung und Modellverfeinerung eingesetzt.

3.1 Segmentierung und Klassifizierung von Punktwolken und Bilddaten sowie Feature Matching

Das gja hat sich im Rahmen der Arbeitsschritte 3.1 und 3.2 mit der Implementierung von Verfahren des maschinellen Lernens zur Segmentierung und Klassifizierung von 3D-Punktwolken und Bilddaten befasst.

Maschinelles Lernen

Systeme der Künstlichen Intelligenz lernen, aus Beispielen Muster zu erkennen und diese auf unbekannte Daten zu verallgemeinern. Dazu werden, basierend auf den Trainingsdaten, statistische Modelle aufgebaut, um Muster und Gesetzmäßigkeiten zu erkennen. So können diese Systeme Aussagen über unbekannte Daten tätigen.

Für das Segmentieren und Klassifizieren von 3D-Punktwolken werden häufig Künstliche Neuronale Netze (KNN) verwendet (Guo et al., 2020). Aktuelle KNN-Techniken fallen wegen ihrer Mehrschichtigkeit unter den Begriff "Deep Learning" (DL; dt. mehrschichtiges Lernen). Bei DL sind künstliche Neuronen in mehreren Schichten angeordnet und untereinander durch eine Aktivierungsfunktion und Gewichte verbunden (siehe Abbildung 19). Anders als bei klassischen Lernverfahren, wie z. B. der linearen Regression oder Entscheidungsbäumen, werden beim Deep Learning aus den Eingangsmerkmalen neue Merkmale erlernt und kombiniert. Die leistungsfähigsten DL-Verfahren fallen in die Gruppe überwachter Lernverfahren und eignen sich insbesondere für Probleme mit hoher Komplexität, wie etwa das Segmentieren und Klassifizieren von Bildern und Punktwolken.

Entwickelte Deep Learning-Ansätze

Die im Rahmen des Projektes getesteten DL-Ansätze basieren auf Faltungsnetzen (Convolutional Neural Network, CNN), die auf mehrdimensionalen Rastern arbeiten. Anders als bei konventionellen KNNs, bei denen Merkmale basierend auf dem kompletten Raster gelernt werden, werden bei CNNs viele Merkmale für kleinere, lokale Bereiche des Rasters erkannt. Für Punktwolken werden Voxelraster verwendet. Der Vorteil ist, dass kleinere Unterschiede zwischen Punktwolken,




Abbildung 19: Mehrschichtiges Neuronales Netzwerk (Quelle: gia).

wie z. B. Verschiebungen und Rotationen, besser generalisiert werden können und somit die Erkennungsraten verbessert werden. Ein weiterer Vorteil ist, dass weniger Speicher für die erlernten Modellparameter benötigt wird. Die einzelnen Voxel beinhalten die normalisierten Punktdichten (Anzahl Punkte im Voxel), die anschließend als Merkmale für das Lernen für den jeweiligen Bereich der Punktwolke dienen. Die regelmäßige Struktur dieser Raster erlaubt es, ähnliche Konzepte zu verwenden wie bei CNNs für 2D-Bilddaten. Dieser Ansatz wird in Abbildung 20 dargestellt.




Abbildung 20: Ein erster Ansatz für einen Ablauf zum Segmentieren einer Punktwolke mithilfe eines Neuronalen Netzwerks und Voxeln (Quelle: gia).

Cross Domain Matching

Der hier verfolgte, neuartige Ansatz basiert zunächst auf CNNs, die in Bildern einzelne Bereiche von Brücken segmentieren und klassifizieren sollen. Die Motivation dieses Ansatzes liegt darin, dass größere Mengen an Brückenbildern zur Verfügung stehen als 3D-Punktwolken. Daher ist es potenziell besser möglich, ein leistungsfähiges Modell zum Segmentieren und Klassifizieren von Bildern zu trainieren. Die Segmentierungen der Bilder sollen mithilfe des Cross-Domain-Matchings als Vorsegmentierung in die Punktwolke übernommen werden. Anschließend wird das Labelling der vorsegmentierten Punktwolke mithilfe von Vorwissen verfeinert, um Ausreißer, Klassifizierungsfehler und fehlende Segmente zu korrigieren. Vorteil des nachgelagerten Verarbeitungsschritts ist, dass auch Fehler, die ihren Ursprung in begrenzten Trainingsdaten oder Registrierungsfehlern haben, ausgeglichen werden. Des Weiteren werden nicht alle Muster zwingend durch trainierte ML-Modelle

aus den Daten erkannt. Diese können jedoch bereits aus Analysen und Vorwissen bekannt sein. Der Ablauf dieses Ansatzes ist in Abbildung 21 dargestellt.

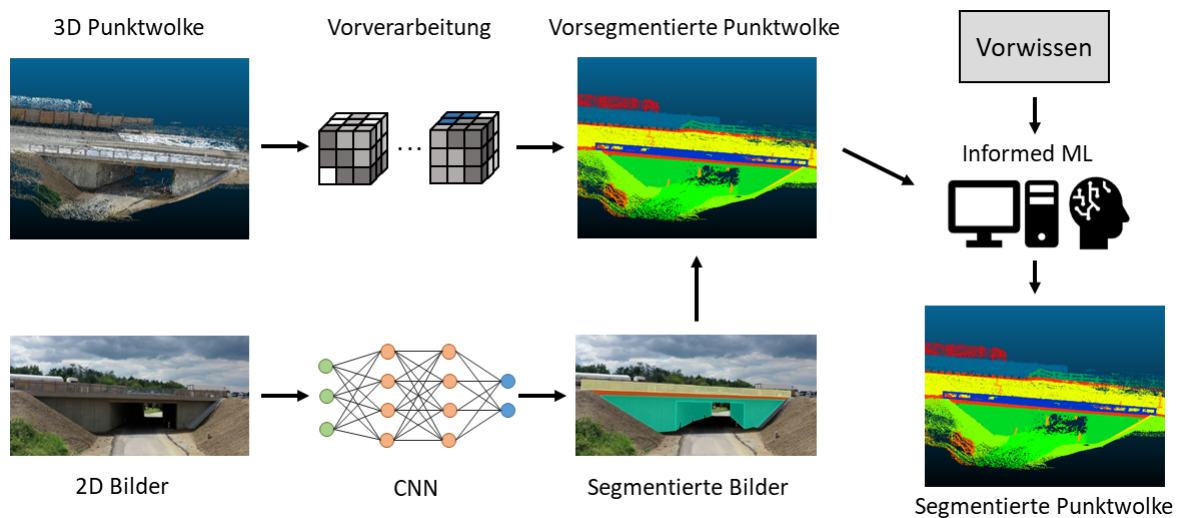


Abbildung 21: Ansatz für ein Segmentierung von Punktwolken mithilfe von Bildern und Vorwissen (Quelle: gia).

Bildklassifizierung

Auf Grundlage einer ausführlichen Literaturrecherche wurde für die Vorsegmentierung und -klassifizierung auf Grundlage von Bilddaten die Mask-RCNN-Architektur ausgewählt. Mask-RCNN wurde ursprünglich von Facebook AI Research entwickelt und stellt derzeit eine der leistungsfähigsten DL-Modelle für das maschinelle Bildverstehen dar. Dieses stützt sich zur Feature Extraction auf ResNet, während der Netzwerkkopf, welcher für jedes erkannte Objekt neben Klassenlabel und Bounding Boxes zusätzlich pixel-genaue Masken prädiziert. Für das Projekt wurde die Mask-RCNN-Architektur mittels Python implementiert. Die durchgeführten Untersuchungen mit Anwendung von Mask-RCNN auf UAV-Bildern haben für die Klassifizierung bereits gute Ergebnisse geliefert, wobei zunächst eine eingeschränkte Menge an Klassen (Oberbau, Unterbau, Geländer) eingeführt wurde. Aufgrund der begrenzten Menge an Trainingsdaten wurde Transfer Learning als Trainingsstrategie verfolgt, um ein bestehendes, auf dem COCO-Datensatz vortrainiertes Netzwerk auf das gegebene Problem anzupassen.

Das hierfür verwendete ResNet-Backbone hat eine Tiefe von 50 Schichten, wobei der Kopf des Netzwerks für das Erkennen von Brückenunterbau, Überbau und Geländer verändert wurde. Das Netzwerk wurde im nächsten Schritt auf einem eigens erstellten Datensatz von etwa 530 Bildern von Brückenbauwerken trainiert, wobei die Daten aus Konsistenzgründen im COCO-Format vorliegen. Wegen der begrenzten Anzahl an Trainingsdaten wurde die Datenmenge mithilfe von *Data Augmentation* künstlich vergrößert. Etwa 70 weitere Bilder wurden zur Validierung der Ergebnisse verwendet. Die entsprechende Konvergenz von Training and Validation Loss ist in Abbildung 22 dargestellt und verdeutlicht, dass das Netzwerk erfolgreich an das Problem angepasst wurde.

Die generierten Segmentierungsmasken sind bereits ansprechend (siehe Abbildung 23), weisen vereinzelt allerdings noch Ungenauigkeiten an Objekträndern und transparenten Objekten auf. Eine




Abbildung 22: Training und Validation Loss für das verwendete Netzwerk.



Abbildung 23: Klassifizierungsmasken für drei Bauteiltypen innerhalb eines Bildes.

Erweiterung des bisherigen Ansatzes durch geometrisches Vorwissen ist aber unabhängig davon nötig, um die Qualität der Ergebnisse beim Übertragen auf Punktwolken zu verbessern.

Projektion und Ko-Registrierung der Bildmasken

Die oben bereits erwähnte Kern-Forschungshypothese, die das gia bei der Modellableitung verfolgt, ist, dass die automatisierte Ableitung von Bauwerksmodellen aus Aufmaßdaten signifikant von der Verknüpfung von (heterogenen) Daten verschiedener Domänen (Cross Domain Matching) profitieren kann. Das Ziel ist es daher, unterschiedliche Datenquellen miteinander zu verknüpfen, um die damit erhaltenen zusätzlichen Informationen bzw. das zusätzliche Wissen für das maschi-




Abbildung 24: Obere Reihe: Gerenderte Punktwolke (links) und Projektion der Objektlabel ohne Beachtung von Verdeckungen (rechts). Untere Reihe: Tiefenkarte der gerenderten Punktwolke und Projektion der Objektlabel mit Beachtung von Verdeckungen.

nelle Lernen zu nutzen. Die Daten unterschiedlicher Sensoren und Qualitäten sowie verschiedener Repräsentationen (hier insbesondere Kamerabilder und Laserscanpunkt wolken) müssen ggf. harmonisiert und in ein gemeinsames Koordinatensystem (Ko-Registrierung) überführt werden. Diese Zuweisung verlangt genaue Kenntnisse über die Koordinatensysteme der beteiligten Datenquellen.

Die Verortung und Ko-Registrierung aller Daten ist wesentliche und unabdingbare Voraussetzung zur Durchführung des Cross Domain Matching. Da geodätische Bestandsaufnahmen typischerweise in einem einheitlichen Koordinatenreferenzsystem stattfinden, können diese Informationen bereits für die Ko-Registrierung ausgenutzt werden. Dies gilt insbesondere für Datenerfassungssysteme wie UAVs und terrestrische Laserscanner mit fest angebaute Kamera. Gerade dann können die extrinsischen und intrinsischen Kameraparameter rekonstruiert werden, um einerseits die gewünschte Ko-Registrierung zu erreichen. Als Verfeinerung der Ko-Registrierung kann in den Bildern nach geometrischen Merkmalen (z.B. Kanten und Ecken) gesucht werden, die mit geometrischen Merkmalen in den dazugehörigen Punktwolken in Übereinstimmung gebracht werden, womit anschließend die Position und Orientierung (Pose) der Kamera im Koordinatensystem des Laserscanners berechnet bzw. verbessert werden kann. Weitere bzw. verfeinerte Ansätze wurden in einer Literaturrecherche identifiziert und im Rahmen der Implementierung der Verfahren näher untersucht.

Für die Projektion der Bildmasken wurde zunächst der Deep Learning-Ansatz auf Bildern zur Segmentierung der Bilder verfolgt. Die segmentierten und klassifizierten Bauteile werden anschließend von den zweidimensionalen Bildern per Ko-Registrierung auf die dreidimensionale Punktwolke übertragen. Den Bildern selbst fehlt allerdings die zur Bestimmung von Verdeckungen nötige Tiefeninformation, d.h. es nicht klar, welche Punkte vom Kamerastandpunkt aus sichtbar sind. Ein naiver Ansatz weist folglich Bauteilen, die aus bestimmten Perspektiven verdeckt sind, falsche Label zu. Zur Lösung dieses Sichtbarkeitsproblems werden für jeweilige Einzelbilder in Anlehnung




Abbildung 25: Verarbeitung der Eingangspunktwolke (oben). Vorsegmentierung der Bauteiloberflächen durch projizieren der Segmentierungsmasken (mittlere Reihe links) und Ergebnis des automatisierten Filters zur Korrektur von Klassifizierungsfehlern (mittlere Reihe rechts). Eine zusätzliche Segmentierung mittels Region Growing (unten) ermöglicht ein Labelling fehlender Segmente.

an die Computergrafik Tiefenmasken durch Rendern der Punktwolke aus dem korrespondierenden Standpunkt generiert, welche der Distanz der Punkte zu einer virtuellen Kamera entsprechen (siehe Abbildung 24).

Dieser Ansatz erfordert Wissen über die Kameraparameter des Erfassungssystems, welche wie erwähnt rekonstruiert werden. Mithilfe der Tiefenmaske lassen sich verdeckte Punkte beim Übertragen der Label ausschließen, für eine gute Qualität ist eine hohe Dichte der Punktwolke vorteilhaft. Der umgesetzte Workflow ist aufgrund des Einsatzes von Bildklassifizierung von der Punktwolkenauflösung unabhängig, was ihn von vielen Punktwolken-basierten Klassifizierungsverfahren unterscheidet. Da die Masken verschiedener Bilder sich beim Projizieren in die Punktwolke überschneiden können und unter Ungenauigkeiten an den Rändern leiden, wurden für eine Verbesserung der Ergebnisse Verfahren erprobt, um die Ergebnisse für Punkte mit in Konflikt stehenden Labels über ein Majority Voting zu verbessern. Das Majority Voting agiert hierfür auf den 3D-Daten und korrigiert innerhalb von Punktnachbarschaften fehlerhafte Label.

Feinsegmentierung der Punktwolke

Im dritten Schritt des entwickelten Cross Domain Matching-Ansatzes wird die durch die projizierte Bildklassifizierung semantisch vorsegmentierte Punktwolke mit dem Ziel der Feinsegmentierung weiterverarbeitet. Der Zweck besteht darin, durch ergänzende Algorithmen automatisiert einerseits Fehler oder Unschärfen der Vorsegmentierung zu verbessern und andererseits die semantische Segmentierung durch die Einbeziehung von Wissen zu vervollständigen. Zur Korrektur möglicher Ausreißer und Artefakte, die beim Labelling auftreten, wird ein wissensbasierter Filter für die automatische Nachbearbeitung verwendet, welcher geometrisches Modellwissen einsetzt (s. Abbildung 25). Bauteilspezifische Eigenschaften wie Oberflächenform und Ausrichtung werden hierbei verwendet, um falsch markierte Segmente zu entfernen und so Artefakte und unscharf segmentierte Bauteilränder zu korrigieren. Neben diesem globalen Filter werden zusätzlich markierte Regionen als Zusammenhangskomponenten untersucht. Da markierte Regionen jeweils einzelnen Bauteilklassen zugeordnet werden, werden von diesen zusätzlich ebenfalls geometrische Eigenschaften sowie die Größe der Region selbst überprüft. Falsch-positive Regionen werden so erfolgreich entfernt, was die Qualität der Segmentierung steigert. Regionen mit fehlenden Labels hingegen treten aufgrund nicht-sichtbarer Bauteile gelegentlich abschnittsweise auf Oberflächen auf. Diese falsch-negativen Abschnitte lassen sich durch ein Propagieren der Bauteillabel entlang der Oberflächen beheben. Angepasste Verfahren wie Region Growing, welche üblicherweise zur Vorsegmentierung verwendet werden (s. Abbildung 25), haben sich hierbei besonders bewährt.

Übertragbarkeit auf Wasserbauwerke

Eine Übertragung dieser Techniken von Brückenbauwerken auf Schleusen wurde ebenfalls untersucht. Mangels Trainingsdaten wurden dieselben Neuronale Netze verwendet, welche auch für die Segmentierung der Bildaufnahmen von Brücken zum Einsatz kamen. Die Ergebnisse weisen hierbei auf die Anwendbarkeit des Ansatzes auf Wasserbauwerke hin, da die Netzwerke auch für diese in der Lage sind, die Schleusenwände zu erkennen und hierbei sogar teilweise eine Unterteilung

in Fugen umzusetzen (siehe Abbildung 26). Für eine weitergehende Untersuchung sind jedoch ergänzende Trainings(bild)daten von Schleusen erforderlich. Es ist aber davon auszugehen, dass der Ansatz dann vergleichbare Ergebnisse wie bei Brücken liefern kann und durch angepasste Algorithmen in der Feinsegmentierung ein hoher Automatisierungsgrad auch in der semantischen Segmentierung von Schleusenpunktwolken erreicht werden kann.




Abbildung 26: Semantische Segmentierung von Schleusenbildern mithilfe eines Neuronalen Netzes. Aufgrund fehlender Trainingsdaten für Schleusen wurde ein auf Brückendaten trainiertes Netzwerk verwendet.

3.2 Erzeugung und Verknüpfung heterogener Datensätze

In Voruntersuchungen und der Erarbeitung des aktuellen Standes von Forschung und Wissenschaft untersuchte das CAAD die Problemstellung der Erzeugung eines digitalen Zwillings aus heterogenen Datensätzen. Hierbei lag der Fokus auf der Interoperabilität heterogener Datensätze und dem Aufbau einer übergeordneten räumlichen Struktur. Auch hier ist essenziell, dass für jedes Dokument, jeden Datensatz und jedes Element die relative räumlichen Referenzierung (Pose) gegenüber einem gemeinsamen Referenzkoordinatensystem bekannt ist.

Voraussetzung zur Verwendung in den Verfahren des Cross Domain Matching ist die Verortung und Ko-Registrierung der Daten der heterogenen Datenquellen. Jedes Dokument, jeder Datensatz und jedes Element bedarf der Kenntnis zur Verortung bestehend aus Lage und ggf. Orientierung (Pose) gegenüber einem gemeinsamen Referenzkoordinatensystem. Dabei müssen auch unterschiedliche Datenformate (z. B. IFC) handhabbar sein. Zur Umsetzung wird eine Datenstruktur benötigt, in der die notwendigen Informationen zu Pose und Referenzsystem gespeichert und nutzbar gemacht werden. Diese Datenstruktur (siehe Abbildung 27) kann bspw. auf dem GeoTIFF Worldfile basieren und nutzt das Prinzip der Georeferenzierung, sodass ein Modell des gebauten Objektes, seiner Komponenten und Informationsaspekte entsteht.

Durch Linked Data Technologien können diese Strukturen allgemein zugänglich gemacht werden. Das heißt, dass alle Daten in einem ICDD Container (ISO 21597) (ICDD, 2020) gespeichert und mit standardisierten Technologien und Werkzeugen (etwa Triple-Stores, Graph-Datenbanken, SPARQL, GraphQL etc.) langfristig abrufbar und verwaltbar gemacht werden.

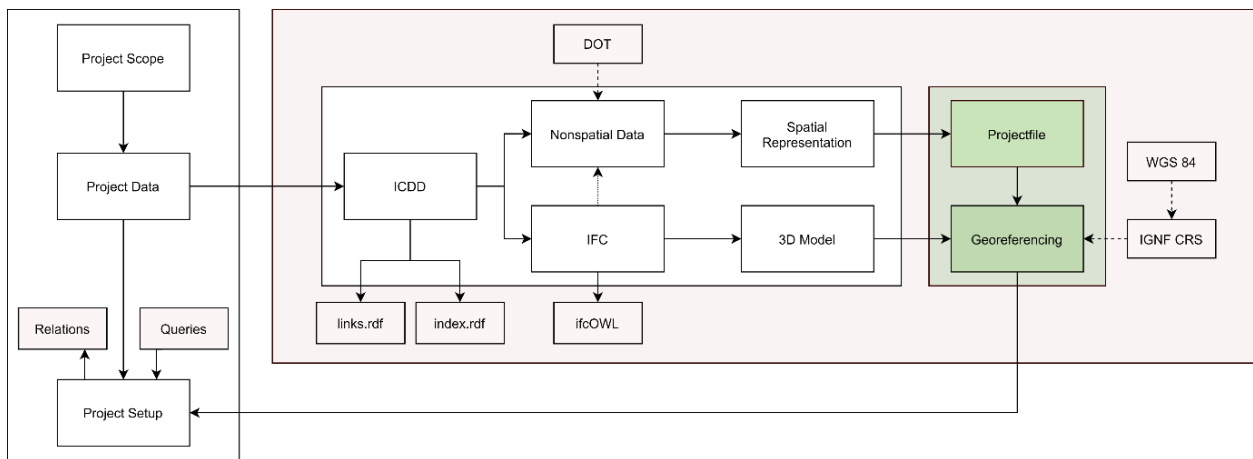


Abbildung 27: Beispielhafte Architektur einer Containerisierung von heterogenen Datensätzen im Bauwesen (anlehnt an DIN SPEC 91391 bzw. ICDD).

Information Container for Linked Document Delivery (ICDD) — Einführung

Ein „Information Container for Linked Document Delivery“ (ICDD) (dt: Informationscontainer zur Datenübergabe) (ICDD, 2020) bietet die Möglichkeit, alle Daten, die zu einem Objekt der gebauten Umwelt gehören, in einer Informationslieferung zusammenzufassen und die einzelnen Dateien aus verschiedenen Datenquellen miteinander semantisch zu verknüpfen.

Dies ermöglicht ein effizientes Bauwerksdatenmanagement und bietet ein einheitliches Informationsaustauschformat. So befinden sich alle notwendigen 3D-Modelle, Fach- und Teilmodelle, Zeichnungen, Textdokumente etc., die für einen bestimmten Zweck gebraucht werden, in diesem Container. Die darin enthaltenen einzelnen, heterogenen Informationseinheiten sind miteinander verknüpft, sodass alle Informationen und Daten aus verschiedenen Quellen direkt abzurufen sind. Dies gewährleistet eine zuverlässige und umfassende Datenübergabe zwischen Projektbeteiligten. Die sich aktuell in der Entwicklung befindliche ISO Norm 21597 definiert den Aufbau und die technische Umsetzung eines solchen Informationscontainers.

Jeder Container stellt eine Zip-Datei dar, welche eine Struktur aus drei Hauptordnern beinhaltet (siehe Abbildung 28). Im Ordner „Payload documents“ befinden sich die Modelle und alle weiteren Dokumente, welche übergeben werden sollen.

In einem weiteren Ordner („Payload Triples“) werden die Links zwischen diesen Dateien gespeichert. Diese werden im Format des „Resource Description Framework“ (www.w3.org/RDF) implementiert. Dieses Datenformat ermöglicht es, mittels Graphen zwei Ressourcen (hier: Dokumente) semantisch miteinander zu verknüpfen, also die Beziehung zueinander zu definieren (z.B. „enthält“ oder „ist Teil von“).

Im dritten Ordner werden die Ontologien zu dem im Container befindlichen Dateien bereitgestellt („Ontology Resources“). Sie definieren das übergeordnete Schema, in welchem die Container als auch die Links beschrieben werden müssen, und bestehen aus Vorgaben zu den zugehörigen Dateiformaten und Eigenschaften.

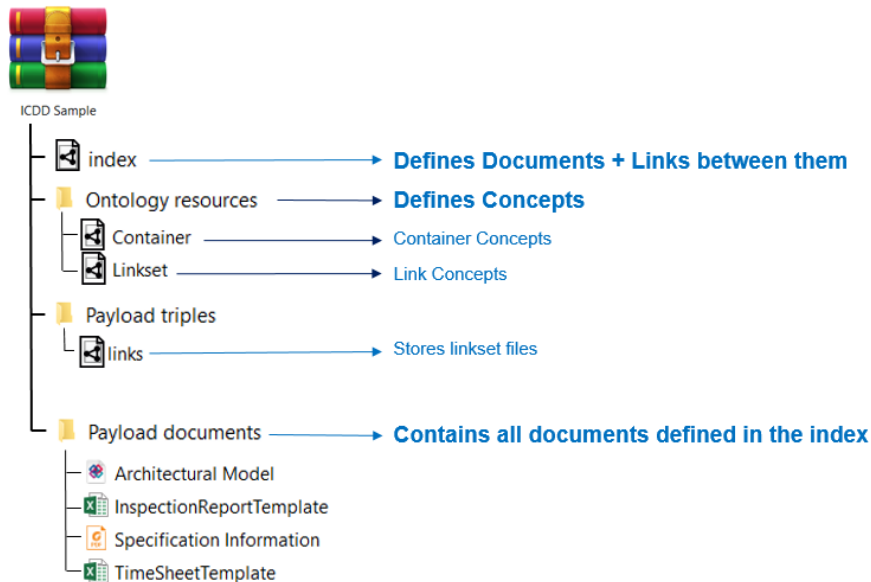


Abbildung 28: Beispielhafte Architektur einer Containerisierung von heterogenen Datensätzen im Bauwesen (angelehnt an DIN SPEC 91391 bzw. ICCD).

Im Index werden die vorhandenen Dateien definiert und es wird festgelegt, wie diese miteinander verknüpft sind. Wie in Abbildung 29 zu sehen, wird hier auf die Links im Ordner Payload Triple verwiesen, welche wiederum auf die Dateien im Payload Documents Ordner zurückgreifen. Hieran angelehnt soll es in künftigen Common Data Environments (CDEs) einheitlich definierte Frameworks und Schnittstellen geben, um auf solche (Multi-Modell-)Container projektbezogen, herstellerunabhängig und verteilt zuzugreifen (DIN SPEC 91391).



Abbildung 29: Beispielhafte Architektur einer Containerisierung von heterogenen Datensätzen im Bauwesen (anlehnt an DIN SPEC 91391 bzw. ICCD).

Damage Topology Ontology

Die „Damage Topology Ontology“ (DOT) (HAMDAN et al., 2019) ist ein Schema, welches es ermöglicht, Schäden an existierenden Bauwerken zu definieren und zu dokumentieren. Sie unterstützt die digitale Dokumentation von Inspektionen und Schadensbeurteilungen bestehender Bauten.

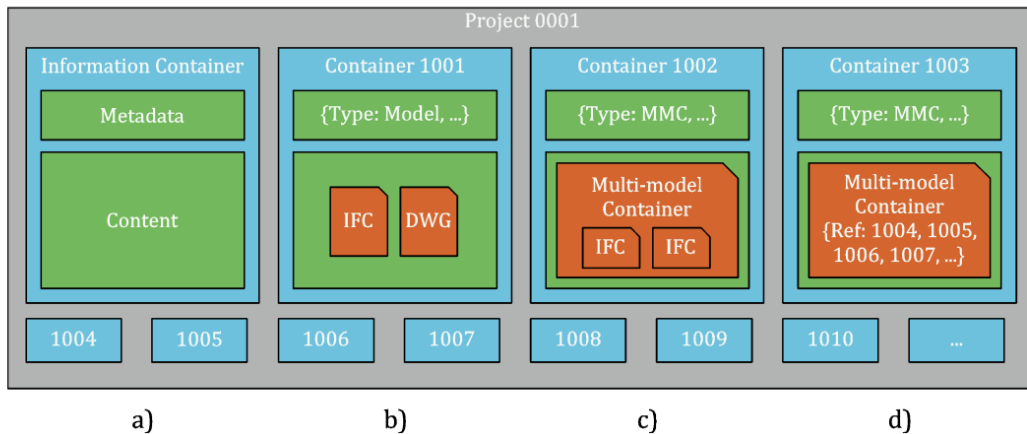


Figure 2 — Information container in a project: a) Abstract structure of an information container, b) Container with with two internal structures (IFC, DWG), c) Multi-container containing sub-structures (IFC, IFC), d) Multi-container with references to further containers (1004, 1005, etc.)

Abbildung 30: Informationscontainer eines Projektes (Quelle: DIN SPEC 91391).

Die Terminologien und Definition für Schäden sind in der Web Ontology Language (OWL) beschrieben und unterstützen somit einen Linked Data Ansatz. Die Schäden können durch den modularen Aufbau mit den betroffenen bestehenden Bauteilen verknüpft werden, welche beispielsweise in der Building Ontology Topology (BOT)(RASMUSSEN et al., 2017) definiert sind (siehe Abbildung 32). Die geometrische Repräsentation als 3D-Modell ist nicht zwingend erforderlich, wodurch dieser Ansatz für bestehende Bauwerke sehr effektiv ist.

Mit dieser digitalen Repräsentation der Schäden und der zugehörigen Bauteile können im Weiteren Dokumente (Fotos, Zeichnungen, Beschreibungen) verknüpft werden. Dies geschieht durch die Nutzung eines Informationscontainers (ICDD). Dieser beinhaltet alle Modelle und Dokumente und verknüpft diese mit den jeweiligen Schäden (DOT Instanzen) durch RDF Linksets.




Abbildung 31: Beispiele für die 5 Methoden einen Schaden zu dokumentieren anhand der Damage Topology Ontology. (HAMDAN et al., 2019, nach)

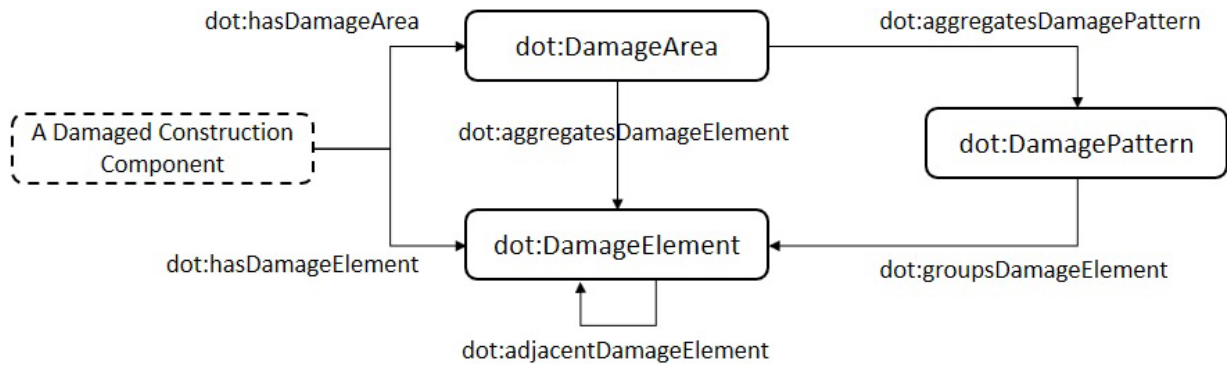


Abbildung 32: Überblick über die Klassen und Objekt Eigenschaften der Damage Ontology Typology. (HAMDAN et al., 2019, nach)

3.3 Aufbereitung technischer Zeichnungen mittels neuronaler Netze

Für die Erfassung der semantischen und topologischen Informationen wurden zusammen mit den Partnern Muster untersucht, die in AP 8 für die semantische Anreicherung der Modelle verwendet werden. Hierzu werden die Daten verschiedener Erfassungssensoren systematisch ausgewertet und aufbereitet.

Technische Zeichnungen enthalten Informationen über die vollständige Geometrie des Bauwerks. Im Gegensatz zu Punktwolken stellen Pläne auch die Kubatur von nicht sichtbaren Bauteilen, wie bspw. der Gründung, dar. Pläne sind somit unverzichtbar zur Extraktion der gesamten Bauwerksgeometrie.

Während für neuere Bauwerke meistens CAD-basierte Pläne vorliegen, existieren für ältere Bauwerke oftmals nur Papierpläne, die nachträglich eingescannt werden. Diese Papierpläne können bereits durch physischen Verfall beschädigt worden sein. Dazu gehören Anomalien wie Verfärbungen in verschiedenen Schattierungen, Flecken oder Knicklinien verschiedener Art. Diese Beschädigungen verzerren die verfügbaren Informationen, was zum einen die eindeutige Erkennung von Bauteilen und Textelementen erschwert, zum anderen zu falschen Ergebnissen führen kann.

Gerade die automatische Informationsextraktion aus Plänen durch den Einsatz von ML-basierten Erkennungsmethoden wird durch die Beschädigungen erschwert. Für diesen Zweck vorgesehene Erkennungsmodelle werden oftmals auf einem Trainingsdatensatz, der überwiegend aus CAD-basierten Plänen besteht, trainiert. Dies verursacht Ungenauigkeiten bei der Detektion auf alten Papierplänen, da diese nicht gut im Training repräsentieren worden sind. Um eine genaue Informationsextraktion mit Hilfe von Erkennungsmodelle zu ermöglichen, wurde im Forschungsprojekt ein Verfahren entwickelt, dass es ermöglicht die Beschädigungen in alten Papierpläne automatisch zu entfernen. Für diesen Bildvorverarbeitungsschritt wurde ein neuronales Netz basierend auf dem Cycle-consistent Generative Adversarial Network (CycleGAN) (ZHU et al., 2017) angewendet.

CycleGAN basiert auf dem Generative Adversarial Network (GAN) (n. d.). GANs sind Methoden, die das Aussehen von Trainingsdaten erlernen, um anschließend neue Daten erzeugen können, die den Trainingsdaten ähnlich sehen. Aufgrund dieser Fähigkeit haben GANs in den letzten Jahren die Aufmerksamkeit der Forschungsgemeinschaft auf sich gezogen, da sie zahlreiche

Bildverarbeitungsprobleme lösen können. GANs werden zum Beispiel oft für die Bild-zu-Bild-Übersetzung eingesetzt. Diese Problem beschreibt die Transformation des Stils *A* eines beliebigen Bildes in einen beliebigen Stil *B*, um ein neues Bild zu erzeugen. Bekannte Beispiele sind Sommer-Winter- oder Zebra-Pferd-Transformationen wie in Bild Abbildung 33 zu sehen ist.




Abbildung 33: Die Transformation von Bild-zu-Bild ermöglicht es, Bilder in verschiedenen Stilen zu überführen. Beispielsweise kann eine Landschaft, die im Sommer fotografiert wurde, in ihrer Erscheinung im Winter dargestellt werden. (Quelle: (ZHU et al., 2017))

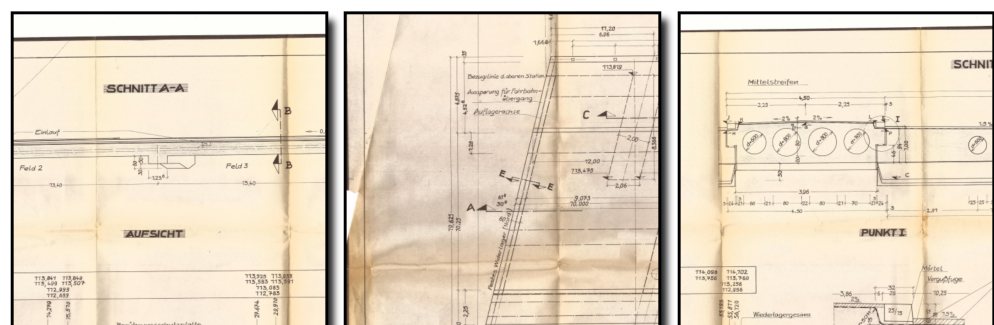
CycleGAN ist in der Lage, diese Bild-zu-Bild-Übersetzung zu lösen. Der Aufbau von CycleGAN ist ähnlich wie bei allen GAN-basierten Methoden: Es gibt einen Generator- und ein Diskriminatornetz, die in einer gegensätzlichen Beziehung zueinander stehen. Die Aufgabe des Generators besteht darin, das Aussehen des Trainingsdaten zu erlernen, um daraufhin neue Daten zu synthetisieren. Der Diskriminator hingegen, lernt zwischen synthetisch generierten und echten Daten zu unterscheiden. Generator und Diskriminator sind gegensätzlich und versuchen, einander zu täuschen. Um ihren Gegner zu übertreffen, verbessern beide Netzwerke stetig ihre Fähigkeit.

Zusätzlich hat CycleGAN den Vorteil gegenüber anderen GAN-Architekturen, dass die Transformation auf unüberwachte Weise erlernt werden kann. Das heißt, zum Training benötigt CycleGAN keine gepaarten Datensätze mit Original und entsprechend transformiertem Bild. Im Falle der Wiederherstellung der Qualität alter Pläne muss also keine moderne Version eines alten Pläne für das Training vorliegen. CycleGAN wird auf einem Satz alter Pläne und einem nicht verknüpften Satz modernen Pläne trainiert.

In Abbildung 34 sind alte Pläne und die durch CycleGAN transformierten Plänen einander gegenübergestellt. Das trainierte Modell ist in der Lage, die Knicklinien weitestgehend zu entfernen. Darüber hinaus bleiben Linien, Texte und Zahlen erhalten. Das Modell kann also intelligent feststellen, was Teil der ursprünglichen Zeichnung war und was durch physischen Verfall hinzugekommen ist. Ein weiterer Aspekt ist die Schriftstärke von Beschriftungen. Das CycleGAN-Modell zeichnete diese wie in den Originalbildern nach. Dies zeigt, dass Textelemente durch das Modell als solche klassifiziert werden und keine Änderungen hieran vorgenommen werden. Linien werden ebenfalls als solche erkannt und teilweise kontrastreicher übernommen.

Insgesamt wird die Qualität der alten Pläne ausreichend wiederhergestellt. Daher eignet sich das hier gezeigte Verfahren als Vorverarbeitung für die Verfahren von Kapitel 7, um Informationen aus Zeichnungen effektiv extrahieren zu können.

Original



Verbessert




Abbildung 34: Vergleich von alten Plänen, die durch Entfernung von Beschädigungen verbessert wurden. (Quelle: RUB)

AP 4: Entwicklung geeigneter Parametrisierungen für das Model Fitting

Im Rahmen des *Model Fitting*-Ansatzes wurden zunächst geeignete Parametrisierungen für Brücken- und Schleusenbauwerke entwickelt und anschließend mithilfe eines Optimierungsansatzes die freien Parameter systematisch variiert, bis sich eine möglichst gute Annäherung des Modells an die erfasste Punktwolke ergibt. Dieser Ansatz kann entweder alternativ oder in Ergänzung zu dem in AP 3 entwickelten Ansatz zum Einsatz kommen. Im ersten Schritt ist eine Bauwerkstypologie aufzubauen, um Klassen von den in Deutschland üblichen Bauwerkstypen zu definieren und daraus eine detaillierte Parametrisierung abzuleiten. Dies soll sich sowohl auf die äußere Erscheinung als auch die verborgenen Geometrien beziehen. Der Ansatz erlaubt zudem die unmittelbare Einbindung von Semantik, da die Bauteiltypen bekannt sind.

4.1 Analyse der Typologie von Brückenbauwerken

Auf Basis der in AP 1 ermittelten Voraussetzungen an Bestandsmodelle wurde eine Brückentypologie erstellt, auf deren Grundlage anschließend weitere parametrische Grundmodelle erzeugt werden. Zur Erstellung der Typologie wurde anhand der Daten aus SIB-Bauwerke eine Auswertung der Häufigkeiten der in Deutschland vorkommenden Brückenarten vorgenommen. Mit diesen Daten kann die Typologie so verfeinert werden, dass beispielsweise für häufig vorkommende Bauwerke weitere Untertypen erstellt werden, da es sinnvoll erscheint, diese Brückentypen im Rahmen der Parametrisierung hauptsächlich zu betrachten.

Brückentypen




Abbildung 35: Das parametrische Profil eines Brückendecks mit seinen Parametern.

Abbildung 35 zeigt einen Überblick der Verteilung der Brückentypen. Da über 70 % der Bauwerke einem von vier Typen zugeordnet werden können, werden im Folgenden vorrangig Methoden zur Erzeugung digitaler Modelle dieser Typen untersucht.

4.2 Entwicklung einer Parametrik für weit verbreitete Brückentypen

Ein parametrisches Modell umfasst eine Reihe von Parametern, über die es gesteuert werden kann. Außerdem enthält es eine Reihe von Zwangsbedingungen, die die Form des Objekts bei der Aktualisierung steuern und erhalten. In 3D-Zeichenprogrammen beginnt der Prozess der parametrischen Modellierung im Allgemeinen mit dem Erstellen von 2D-Skizzen auf Ebenen, den sogenannten Referenz-/Arbeitsebenen. Diese 2D-Skizzen werden verfeinert und für Funktionen wie Extrudieren, Sweep, Loft und Rotation genutzt, um ein volumetrisches 3D-Modell zu erstellen.

In Anlehnung an diesen Prozess definieren wir ein parametrisches Prototypmodell (PPM) als Dummy-Modell mit manuell definierbaren Parametern und Beschränkungen, das seine Form anpassen kann. Das PPM eines Elements wird auf der Grundlage einer Reihe von Parametern und Zwangsbedingungen erstellt, die seine geometrische Form beschreiben. Zu den Parametern gehören die Koordinaten des Ursprungs, die Länge der Kanten und die Winkel. Ein PPM hat insbesondere drei Eigenschaften. Es enthält eine endliche Anzahl von Parametern und Zwangsbedingungen, hat einen bestimmten Objekttyp und ist in der Lage, die Form in Abhängigkeit vom Wert der Parameter zu verändern. Im Gegensatz zu den herkömmlichen Methoden zur Anpassung von Modellen ermöglichen die PPMs nicht nur die Anpassung an primitive Formen, sondern auch an nicht-primitive Formen, die bei Brücken häufig vorkommen.

Die PPMs werden für einzelne Brückenbauteile zunächst getrennt voneinander entwickelt. Der Programmierungsprozess eines PPMs wird vom Ursprung aus gestartet und auf der Grundlage der Parameterwerte auf andere Eckpunkte ausgedehnt. Gleichzeitig werden Beschränkungen wie Parallelität, Konnektivität, Rechtwinkligkeit und Symmetrie implizit auf das Prototypmodell angewendet. Das PPM weist variable und festgelegte Abmessungen sowie Beschränkungen auf. Konkrete Ausprägungen des PPM weisen dann den freien Parametern spezifische Werte zu. Abbildung 36 zeigt das PPM eines typischen Querschnitts der Fahrbahn einer Brücke, das durch eine Reihe von Parametern beschrieben wird. Wie hier erkennbar ist, führt jede Änderung der Parameterwerte zu einem anderen Objekt vom Typ Querschnitt-Fahrbahnplatte mit neuen Dimensionen. Betrachtet man eine Punktwolke, die mit diesem Querschnitt assoziiert ist, kann eine Liste von Kandidaten/Lösungen erstellt und für den Wert der Dimensionen vorgeschlagen werden, die die Punktwolke repräsentiert. Um den Wert der Parameter durch ein PPM zu bestimmen, muss jeder Kandidat auf der Grundlage seiner Ähnlichkeit mit der Punktwolke quantifiziert werden.




Abbildung 36: Das PPM eines Fahrbahnquerschnitts mit seinen drei Varianten, die durch Änderung der Parameterwerte erzeugt wurden.

Brücken bestehen i.d.R. aus Überbau und Unterbau. Der Überbau umfasst die Fahrbahn bzw. die Fahrbahnplatte, das Geländer, die Träger und die Brüstung, während der Unterbau aus Elementen

wie Pfeilern, Pfeilerkappen und Widerlagern besteht. Alle diese Elemente können unterschiedlich beschaffen sein. Die Fahrbahn kann zum Beispiel ein Deck mit T-förmigen Trägern oder ein balkenförmiges Deck sein, siehe Abbildung 37. Unter Berücksichtigung der vorhandenen Brückenelemente und der verschiedenen Typen, die sie aufweisen können, wurde eine Bibliothek der PPMs erstellt. Diese Dummy-Modelle werden angepasst und in die Punktwolke der entsprechenden Elemente der PPMs eingepasst.



Abbildung 37: Die PPMs von zwei verschiedenen Querschnitten.

4.3 Typologie und Parametrik für Wasserbauwerke

Als Basis der Entwicklung einer Typologie für den Wasserbau und die Parametrik für weit verbreitete Wasserbauwerke wurde vom gia im Rahmen von AS 4.3 der ObKat VV-WSV 11 02 der Bundeswasserstraßenverwaltung (vgl. Abbildung 38) als eine geeignete Grundlage identifiziert. Weitere Parameter finden sich in der Wasserstraßendatenbank (WADABA) (vgl. Abbildung 39).

Objektteil Stufe 1		Objektteil Stufe 2		Objektteil Stufe 3	
.200	Schleusen	.210	Schleusenkammern	.211	Kammersohlen (einschl. Grundläufe)
				.212	Kammerwände (einschl. Umläufe)
		.220	Schleusenhäupter	.221	Bauwerke (einschl. Torkammern, Umläufe, Aufbauten für Maschinenräume u. dgl.)
				.222	Torkammern, Tosbecken
				.231	Schleusentore (einschl. Stege (.270))
		.230	Schleusenverschlüsse	.232	Antriebe der Schleusentore, Antriebe der Tordurchlassverschlüsse (einschl. Schubstangen, Ketten, Gegengewichte, Verriegelungen u.dgl.), örtl. Steuerungen (.610)
				.233	Pumpeinrichtungen der Tore (einschl. Antriebe)
				.234	Luftsprudeleinrichtungen, Enteisungseinrichtungen
				.235	Revisionsverschlüsse
				.236	Portalkräne, Hebepons

Abbildung 38: Auszug aus der Verwaltungsvorschrift der WSV des Bundes ObKat VV-WSV 11 02 (Quelle: BMVI).

Die WADABA enthält grundlegende Informationen zu Objekten, die der Beschreibung und Identifizierung der Anlagen der WSV und Dritter dienen. Sie soll künftig durch die zentrale Datenbank für die Wasserstraßen-Infrastruktur-Daten (WInD) mit flächendeckenden Infrastrukturdaten (z.B. eindeutige Identifikation, Bezeichnung, Lage, Fragen des Eigentums und der Unterhaltung, der Prüfpflicht und des Baujahrs) abgelöst werden (SCHENK & LAURSEN, 2018). Auf nationaler Ebene wird von buildingSMART Deutschland der Katalog „BIM – Klassen der Verkehrswege“ herausgegeben, der in seiner 2. Auflage auch IFC-Klassen in den Bereichen „Wasserwege/Hafen“ umfasst. Auch die Entwicklungen auf internationaler Ebene zur Erweiterung im Bereich der Häfen und Wasserstraßen (IFC P&W) haben Berücksichtigung gefunden. Wichtiger Aspekt zur Festlegung der Typologie und Parametrik für die spezifische Anwendung z.B. in Betrieb und/oder Unterhaltung ist der benötigte

Detailgrad, da etwa die Art der Modellierung von Baufugen sich deutlich auf den Zeitaufwand auswirkt (siehe Abbildung 40). Eine Modellierung ohne Unterteilung in Fugen ist etwa am schnellsten umzusetzen, erfüllt aber möglicherweise nicht die Anforderungen für die Instandhaltung. Diese Modellierungsparameter sind deswegen mit den Bauwerksverwaltern abzustimmen.

Schleusenammer		311 Schiffsschleusenanlagen Schiffsschleusenanlage Trier	
Kammernummer:	1		
Bezeichnung der Kammer:			
Höhensystem für alle Höhen:	100 RP DHHN12, Normalorthometrische Höhe		
Baujahr:	1959	Art der Schleusenammer bzw. Schleusenanlage:	Einzelschleuse
Baukosten:	0 TEUR	Bauart der Kammer:	Schwergewicht mit geschlossener Sohle
Breite der Kammer:	12,08 m	Baumaterial:	Beton
Nutzlänge gesamt:	170 m	max. Schleusungswasservolumen, gesamt:	16,1 x1000m³
UK Schleusensteg/Tormaske/Tor:	m (absolut)	Visuelle Einfahrhilfe vorhanden:	nein
Durchfahrtshöhe:	m	Hochwasserentlastung:	nein
Grenzwasserstand oben (GVo):	m (absolut)		
Länge obere Teilkammer:	m	Länge untere Teilkammer:	m
Anzahl Sparbecken:		Gesamtsparrwasservolumen:	0 x1000m³
Anzahl		Zulässiger Trossenzug	
Nischenpoller:	110	Nischenpoller:	300 kN
Schwimmpoller:	0	Schwimmpoller:	kN
Kantenpoller:	16	Kantenpoller:	375 kN
Steigleitern:	16	Länge Schleusengeländer:	m
Bemerkung:	Schwergewichtsmauer, Sohle mit Auftriebsentlastung Bau einer 2. Schleuse möglich		

Abbildung 39: Beispielhafter Datenreport aus der Wasserstraßendatenbank (WADABA) der WSV (Quelle: WSV).

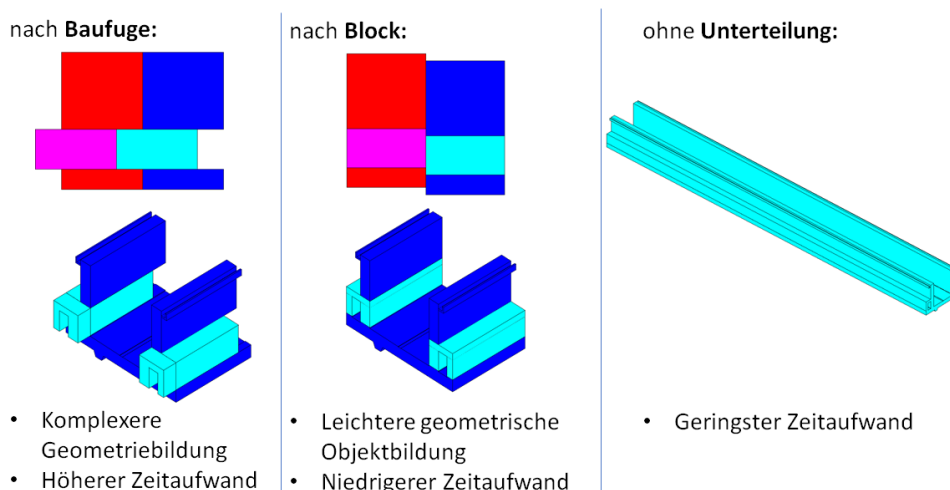


Abbildung 40: Abhängigkeit von geometrischem Detailgrad und Modellierungsaufwände bei Wänden in den Schleusenbauwerken (Quelle: gia).

AP 5: Optimierungsverfahren für das Model-to-Cloud Fitting

5.1 Heuristische Optimierungsverfahren zur systematischen Variation von Brückenparametern

Die Kernkomponenten des Top-Down-Ansatzes von AP 4 ist die Verfügbarkeit eines geeigneten Optimierungsansatzes zur Anpassung des parametrischen Modells an die gegebene Punktwolke. Da die parametrischen Modelle im Regelfall über eine sehr hohe Anzahl von freien Parametern verfügen, ergibt sich ein mehrdimensionales Optimierungsproblem, dass nur durch heuristische Ansätze gelöst werden kann.

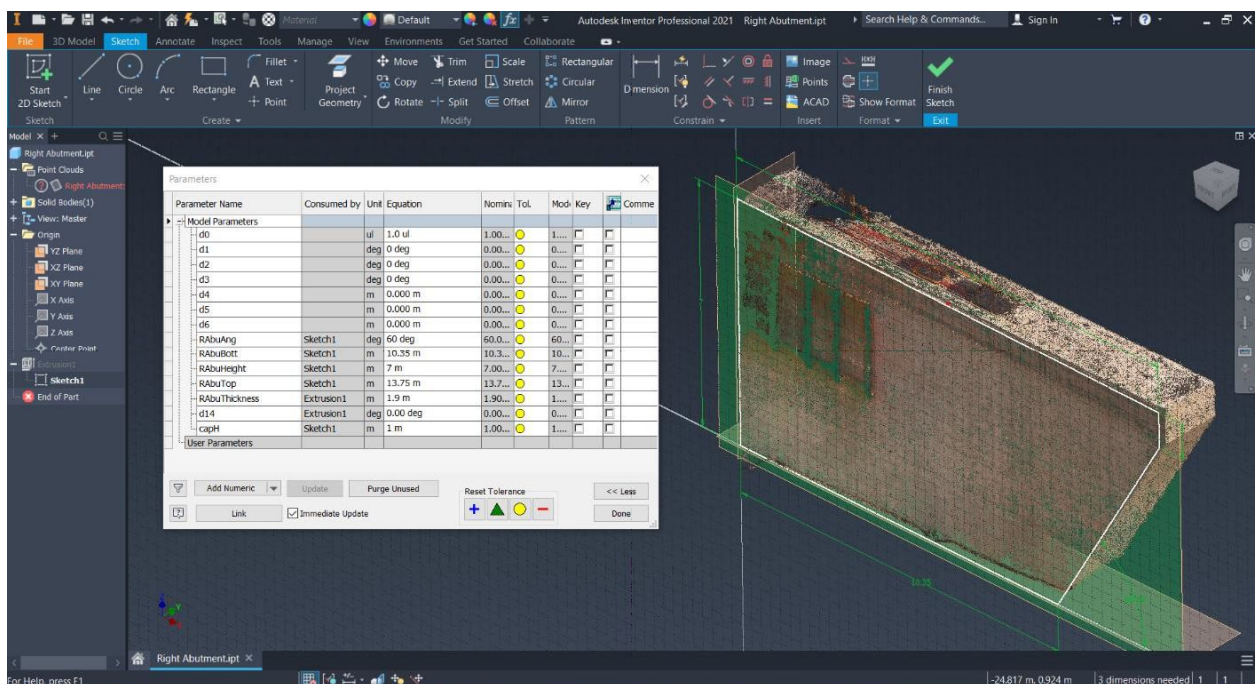


Abbildung 41: Annäherung der Punktwolke durch ein parametrisches Modell in Autodesk Inventor.

Hierfür wurde bereits untersucht, wie Segmente der durch die Drohnenbefliegung erzeugten Punktwolken durch ein parametrisches Modell (siehe Abbildung 41) angenähert werden können, indem die Werte der Parameter dieses Modells iterativ optimiert werden (model fitting).

Dazu werden metaheuristische Algorithmen eingesetzt, die auf Basis der Punktwolken Daten beispielsweise den Querschnitt eines bestimmten Bauwerksteils erkennen, indem die Form des Querschnitts möglichst genau durch ein Polygon angenähert wird (siehe Abbildung 42). Es wurden hierzu verschiedene Ansätze und Optimierungsalgorithmen betrachtet, eingesetzt und untersucht, um letztlich einen möglichst optimalen Prozess zu entwickeln.

Metaheuristische Algorithmen

Metaheuristische Algorithmen sind ein Zweig der künstlichen Intelligenz (KI) und gehören zu den Optimierungsalgorithmen. Die meisten metaheuristischen Algorithmen wurden durch biologische Systeme von Menschen oder Tieren inspiriert. Diese Algorithmen sind im Gegensatz zu gradi-

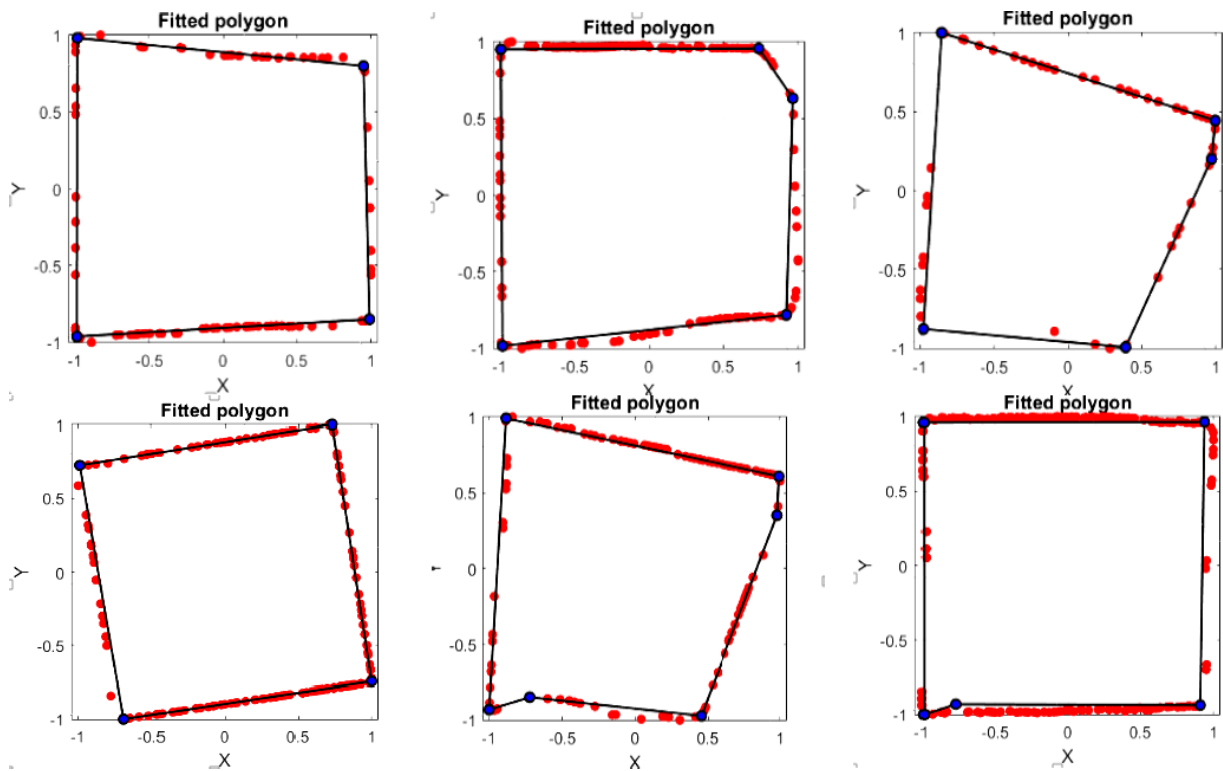


Abbildung 42: Annäherung des Querschnitts einzelner Bauteile auf Basis der Punktwolkendaten.

entenbasierten Algorithmen ableitungsfrei und nicht von der geschlossenen Formulierung der Kostenfunktion abhängig. Diese Eigenschaft ermöglicht es ihnen, Kostenfunktionen zu optimieren, deren Ableitungen nicht einfach berechenbar sind. Die Partikelschwarmoptimierung (PSO) ist beispielsweise ein metaheuristischer Algorithmus, der sich am Sozialverhalten von Vögeln und Fischeschwärmen orientiert (KENNEDY & EBERHART, 1997). Bei Anwendung des PSO wird zunächst ein Schwarm von zufälligen Lösungen initialisiert. Anschließend wird die Qualität jeder Lösung anhand einer Kostenfunktion bewertet.




Abbildung 43: Ein Schwarm von Partikeln (Brückendecks) in PSO-Kodierung: (links) kodierte Lösung des Decks; (rechts) Visualisierung der entsprechenden Lösung (Deck)

Das parametrische Profil der Brückenelemente (siehe Abschnitt 4.2) ist von den Werten der Parameter abhängig. Ändert sich also der Wert der Parameter, wird das Modell aktualisiert. Diese Modelle können im PSO-Algorithmus kodiert werden, wie in Abbildung 43 dargestellt.

Während die Parameter primitiver Formen durch eine geschlossene Formel ausgedrückt werden können, wird ein PPM numerisch auf der Grundlage einer Reihe von Parametern und Beschränkungen definiert. Daher kann das mathematische Modell eines PPM nicht einfach ausgedrückt und durch gradientenbasierte Algorithmen abgeleitet werden. Um dieses Problem zu lösen, können

metaheuristische Algorithmen eingesetzt werden, um PPMs anzupassen und sie in die Punktwolke der Elemente einzupassen. Um ein PPM zu instanziiieren, können zufällige Werte in vordefinierten Bereichen generiert werden, die durch Wissen aus dem Brückenbau bestimmt sind. Um ein PPM anzupassen, muss der euklidische Abstand seiner Kanten zur Punktwolke minimiert werden. Im Allgemeinen kann ein PPM eine beliebige Position in Bezug auf die Punkte auf einer 2D-Ebene haben und es ist nicht offensichtlich, welche Kante den kürzesten Abstand zu einem Punkt hat. Daher müssen die Punkte zunächst der nächstgelegenen Kante zugewiesen werden. Dieser Schritt kann dazu führen, dass einige Kanten möglicherweise keinem Punkt zugeordnet werden.

Da es keinen Punkt gibt, um diesen Kanten einen Fehlerwert zuzuweisen, können sie eine beliebige Position in der Ebene haben. Mit anderen Worten, diese Kanten haben redundante Freiheitsgrade, die eliminiert werden müssen. Um dieses Problem zu lösen, wurde das Konzept der aktiven und passiven Kanten erarbeitet, das sich an der Definition einer Linie im 2D-Raum orientiert. Eine Kante wird als aktiv bezeichnet, wenn sie entweder mindestens zwei Punkte oder einen Punkt und eine vertikale/horizontale Beschränkung fängt. Unter allen anderen Bedingungen wird die Kante als passiv bezeichnet, da sie keinen Beitrag zum Optimierungsprozess leisten kann. Um alle Kanten eines PPMs während des gesamten Optimierungsprozesses zu kontrollieren, muss die Aktivität der Kanten bewertet werden. Außerdem müssen die passiven Kanten aktiviert werden. Um dieses Problem zu lösen, definieren wir eine Kostenfunktion, die aus zwei Termen besteht. Der erste Term (d) ist einfach die L2-Norm des Vektors, der den kürzesten Abstand der Kanten und Eckpunkte zu den Punkten enthält. Der zweite Term (e) ist eine Strafe, die zu den passiven Kanten hinzugefügt wird, um sie aktiv zu machen.

$$f(p_1, p_2, \dots, p_n) = \sum_{i=1}^n d_i + \sum_{j=1}^m e_j$$

Um den Wert von e_j zu berechnen, werden die Nachbarkanten der passiven Kanten ausgewertet und ein Fehlerwert in Höhe des Abstands des Scheitelpunkts der passiven Kante zum nächstgelegenen Punkt der benachbarten aktiven Kante addiert. Wenn die benachbarte Kante ebenfalls nicht aktiviert ist, bedeutet dies, dass das Modell entweder weit von den vorhandenen Punkten entfernt ist oder mit einer großen Menge an Verdeckungen zu kämpfen hat. Infolgedessen wird ein großer Fehlerwert zur Kostenfunktion hinzugefügt, um die Wahrscheinlichkeit der Auswahl dieser Lösung im nächsten Schwarm zu minimieren. Zur Berechnung des genauen Fehlerwerts können auch die Nachbarn der passiven Nachbarkanten überprüft werden, was jedoch sehr rechenintensiv ist. Abbildung 2 zeigt den Fehlerwert, der der Kostenfunktion in verschiedenen Szenarien eines rechteckigen PPM hinzugefügt werden sollte.

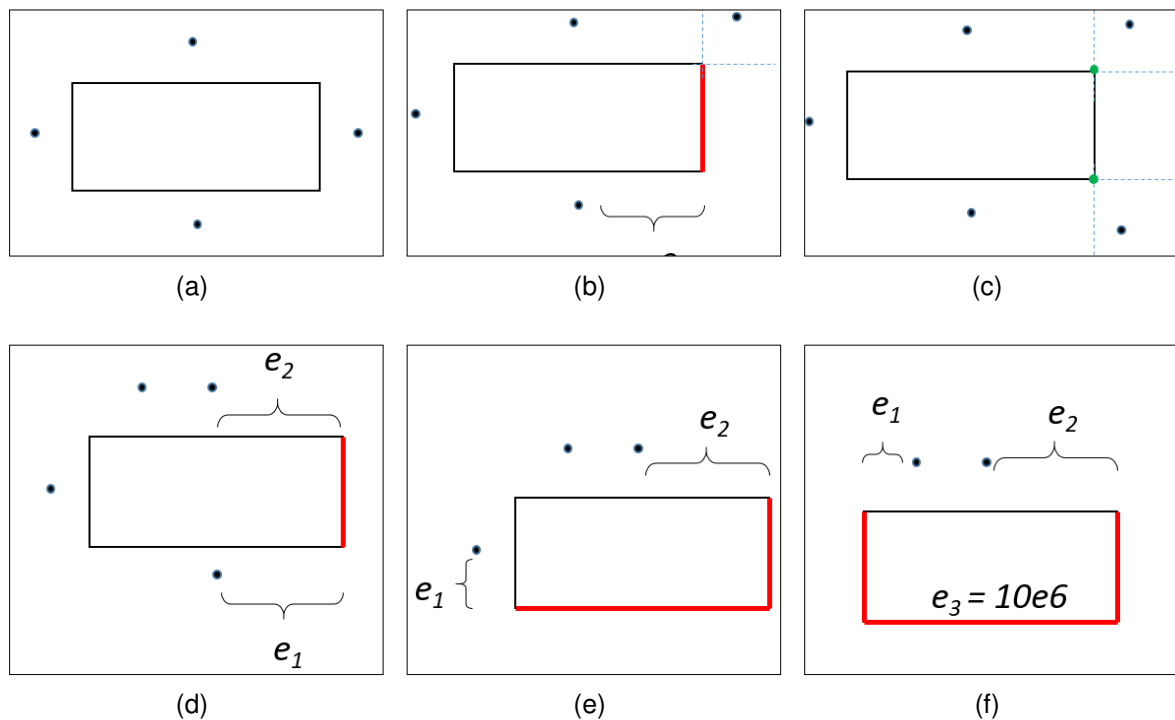


Abbildung 44: Fehlerwert für die Aktivierung der passiven Kanten eines Rechtecks: (a) alle Kanten sind aktiv, da eindeutig ist, wie sie verschoben werden müssen, damit sie sich in die Punkte einpassen; (b) nur ein Endpunkt der rechten Kante ist aktiv = die Kante ist passiv (es ist nicht direkt klar, ob die Kante nach rechts oder nach links verschoben werden muss); (c) beide Endpunkte der rechten Kante sind aktiv = die Kante ist aktiv; (d) der rechten Kante konnte kein Punkt zugeordnet werden = die Kante ist passiv; (e) die rechte und die untere Kante haben keinen Punkt = beide Kanten sind passiv; (f) die untere Kante hat keinen Punkt und ihre benachbarten Kanten sind ebenfalls passiv.

Fallstudie 1

Um die Leistung der entwickelten heuristischen Algorithmen zu bewerten, wurde das Brückendeck des Cambridge-Datensatzes² (LU et al., 2019) segmentiert. Für die parametrische Modellierung des Decks wurden die Punkte in Intervalle von 3 m segmentiert, wie in Abbildung 45 dargestellt. Für jedes Segment wurde das entsprechende Modell des Decks angepasst. Zu diesem Zweck wurde PSO mit 35 Partikeln und 100 Iterationen angewendet. Die Koeffizienten c_1 und c_2 wurden ebenfalls auf 2 gesetzt und es wurde ein Dämpfungsfaktor von 0,99 berücksichtigt. Anschließend wurden alle aus dem PSO resultierenden sequentiellen Endpunkte miteinander verbunden. Da diese Linien möglicherweise nicht geglättet sind, wurde ein Polynom an die Scheitelpunkte angepasst, und die Scheitelpunkte des Modells wurden geändert. Abbildung 46 zeigt das angepasste Modell in der Punktwolke. Wie zu erkennen ist, ist das Modell symmetrisch und stellt ein stark parametrisiertes Modell mit einer genauen Anzahl von Parametern dar, die einem manuell modellierten Deck sehr nahe kommen. Das Konvergenzdiagramm (Verlust) von PSO zeigte einen Fehler von etwa 5 cm für jedes Segment. Dies zeigt, dass die vorgeschlagene Methodik den Wert der Parameter mit einem Fehler von ca. 1,67 cm/m extrahieren kann.

²Frei verfügbarer Datensatz einer Messkampagne im Rahmen des Projekts SEEBridge, bei der im Umkreis von Cambridge (UK) eine Reihe von Brücken per Laserscan aufgenommen wurden.




Abbildung 45: Segmentierung des Decks in Intervalle: (a) Eingabepunktwolke; (b) Schnittebenen durch die Punktwolke orthogonal zur angenommenen Bauwerksachse; (c) segmentierte Punkte.




Abbildung 46: In die Punktwolkendaten eingepasstes Deck (Fallbeispiel 1).

Fallstudie 2

Für den zweiten Fall wurde eine Brücke in München gescannt (siehe Abbildung 47, Details in Abschnitt 2.2), um die Punktwolkendaten anschließend zu untersuchen.

Für die parametrische Modellierung der Fahrbahn wurden die Punkte in Intervalle von 3 m segmentiert. Für jedes Segment wurde das Profil einer Fahrbahn mit T-förmigen Trägern angepasst. Zu diesem Zweck wurde PSO mit 35 Partikeln und 150 Iterationen angewendet. Die Koeffizienten c_1 und c_2 wurden ebenfalls auf 2 gesetzt, und es wurde ein Dämpfungsfaktor von 0,99 berücksichtigt. Anschließend wurden alle aus dem PSO resultierenden sequentiellen Scheitelpunkte miteinander verbunden. Da diese Linien möglicherweise nicht geglättet sind, wurde ein Polynom an die Scheitelpunkte angepasst, und die Scheitelpunkte des Modells wurden geändert. Abbildung 48 zeigt das angepasste Modell in der Punktwolke. Wie zu erkennen ist, ist das Modell symmetrisch und stellt ein stark parametrisiertes Modell mit einer genauen Anzahl von Parametern dar, die einem manuell modellierten Deck sehr nahe kommen. Das Konvergenzdiagramm (Verlust) des PSO zeigte einen Fehler von etwa 3 cm für jedes Segment. Dies zeigt, dass die vorgeschlagene Methodik den Wert der Parameter mit einem Fehler von ca. 1,00 cm/m extrahieren kann.



Abbildung 47: Scan einer Brücke in München.




Abbildung 48: In die Punktwolke eingepasstes Brückendeck (Fallbeispiel 2).

Fallstudie 3

Für die parametrische Modellierung des Widerlagers wurden die Punkte der Flügelwände und der Stützmauer geclustert. Anschließend wurden diese Punkte unter Verwendung der Punktnormalen und der lokalen Koordinaten der Ebene von 3D in 2D transformiert. Dann wurden die Grenzpunkte jeder Fläche durch Fuzzy-C-Means (FCM) Clustering ermittelt. Zu diesem Zweck wurde der Wert der Verschiebung von jedem Abfragepunkt zu seinen Nachbarn berechnet und als Merkmal im FCM verwendet. Die Grenzpunkte werden dann mit Hilfe von zwei Clustern (Mittel- und Grenzpunkte) ermittelt. Um die Parameterwerte der Flügelwände und der Stützmauer zu extrahieren, wurden zwei Dummy-Profile mit zufälligen Werten instanziiert, die auf dem Wissen des Brückenbaus basieren. Schließlich wurden diese Profile mit PSO angepasst. Die Parameter des PSO wurden analog zu den oben genannten Fällen gewählt. Zur Rücktransformation der angepassten Profile in den 3D-Raum wurde die inverse Moore-Penrose-Matrix der ursprünglichen Transformationsmatrix ver-

wendet. Abbildung 49 zeigt den Prozess der Modellanpassung des Widerlagers, und Abbildung 50 veranschaulicht die endgültige Anpassung des Widerlagers an die Punktwolkendaten.

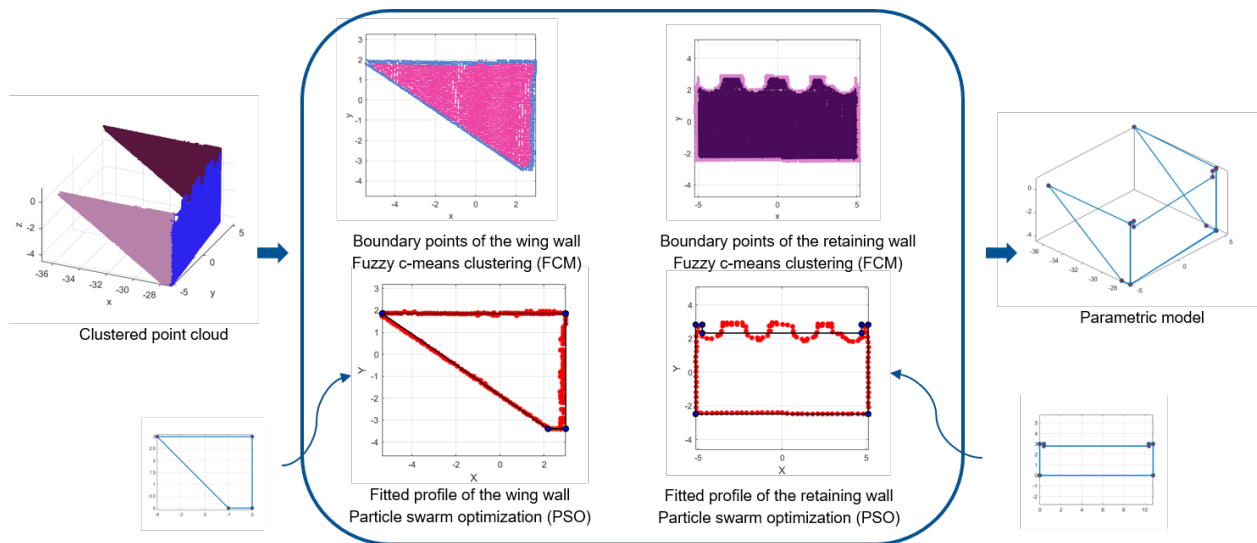


Abbildung 49: Prozess der Modellanpassung des Brückenwiderlagers.




Abbildung 50: In die Punktwolke eingepasstes Brückenwiderlager.

5.2 Cloud-Fitting für schwer zugängliche, partiell sichtbare und verborgene Strukturen

Untersuchungen zu möglichen Ansätzen des Cloud-Fittings für schwer zugängliche, partiell sichtbare und verborgene Strukturen weisen darauf hin, dass eine Rekonstruktion nicht ohne Vorwissen möglich ist. Dieses kann zwar durch maschinelle Lernverfahren automatisiert erlernt werden, um Geometrien zu vervollständigen (CHU et al., 2021; HAN et al., 2017). Allerdings sind Verfahren wie multimodale Optimierung spezifischer, da sie unter Verwendung von Normen (z.B. DIN 19703 im Wasserbau) und Bauteilparametern wie Parallelität, Symmetrie und Flächenausrichtung in der Lage sind, Modelle zu konstruieren (XUE et al., 2019). Allerdings ist Vorwissen aus Bau- und Bestandsplänen ebenfalls wertvoll, um auch nicht-sichtbare Geometrien speziell für das vorliegende Bauwerk korrekt zu rekonstruieren (GIANNATTASIO et al., 2019; YIN et al., 2020; ZHAO et al., 2021). Ähnliche Ansätze werden in Abschnitt 7.2 verfolgt, wobei das Vorwissen zuvor mithilfe automatisierter Verfahren aus Bauplänen extrahiert wurde. Auch hier spielt das eingangs erwähnte Vorwissen (etwa zur Bauteilsymmetrie) eine Rolle bei der Bauteilparameterwahl und Rekonstruktion.

AP 6: Informationsstruktur und Analyse zu Schädigungen

Das Arbeitspaket befasste sich mit der nachhaltigen Erfassung, Verwaltung und Verfügbarmachung von Schäden und der Schaffung erweiterter Möglichkeiten ihrer systematischen Abfrage, Analyse und Bewertung. Für vorhandene Strukturen wie ASB-ING, die dem Programm SIB-Bauwerke zugrunde liegen, wurden neben den bisherigen schlüsseltabellenbasierten, alphanumerischen Daten sowie den semi-strukturierten Bildverzeichnissen weitergehende Ansätze für die Verlinkung von bauteilorientierten, geometrischen Modellen, erfassten Bild- und Messdaten und wissensbasierten Anmerkungen inklusiver geeigneter Metadaten entwickelt. Die cross-modale, multi-mediale Verlinkung bislang lose strukturierter Datensätze und Informationen erfolgte mit methodischen Ansätzen und technischen Standards von Linked Data und der vernetzten Wissensmodellierung.

6.1 Offene Informationsaustauschformate für die bauteilorientierte Verknüpfung von Schadensinformation auf Basis existierender Standards

Um Schadensinformationen sowie weitere semantische Annotationen mit Bauteilen zu verknüpfen, eignet sich der Einsatz eines „Information Containers for Linked Data Delivery“ (ICDD) (vgl. Abschnitt 3.1). In ihm können sowohl die semantischen Informationen über Schäden gespeichert werden, also auch die zugehörigen Schadensfotos oder Kartierungen. Des Weiteren beinhaltet der Container auch das Bauwerksmodell und weitere bauwerksbezogene Daten wie 2D-Dokumente und die Inspektionsdaten aus SIB-Bauwerke. Diese Dokumente können als Ganzes, aber auch auf Bauteil/Objektebene, untereinander durch den Einsatz von Linked Data verknüpft werden. Dieser verknüpfte Informationscontainer dient dann als Grundlage für das strukturierte Abfragen, Verwalten und Analysieren von Informationen (s. Abbildung 51).

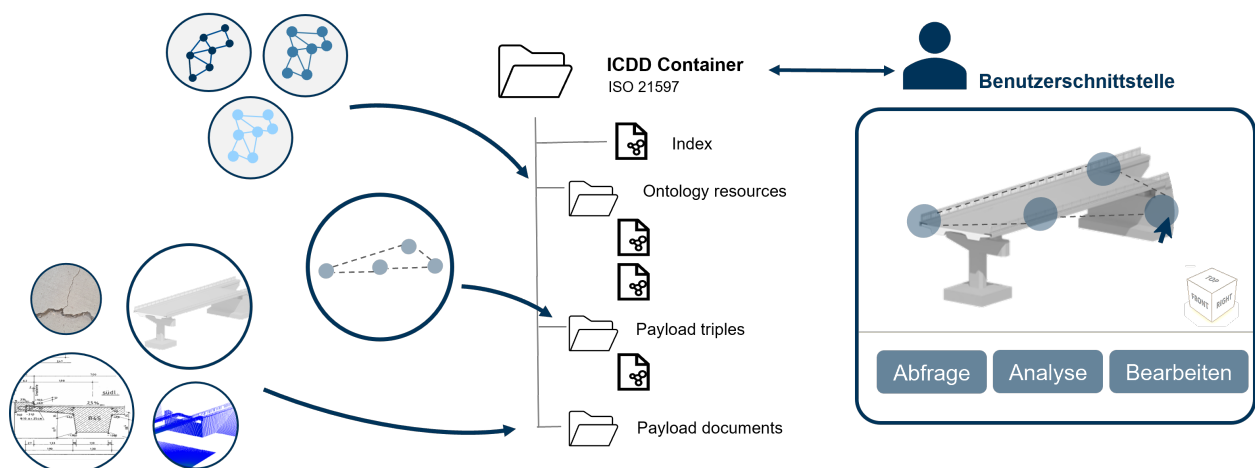


Abbildung 51: Verknüpfte, strukturierte Ablage aller Bauwerksdaten in ICDD Containern.

Um eine Verlinkung auf Objektebene zu ermöglichen, müssen die Objekte (bspw. einzelne Schäden, geometrische Bauteile, etc.) im Linked Data Format (das Resource Description Format (RDF)) beschrieben werden. Für das Bauwerksmodell und die darin enthaltenen Bauteile bietet sich zunächst die Speicherung im offenen Austauschformat IFC an, welches dann mithilfe der IFCowl (BEETZ et al., 2009) Ontologie in eine Linked-Data kompatible Repräsentation konvertiert werden kann.

Für die Beschreibung und Verwaltung von Schäden gibt es auch bereits einige Ontologien, wie die Damage Topology Ontology (DOT) (HAMDAN et al., 2019) (vgl. Abschnitt 3.1) und die Area Of Interest Ontology (AOI) (HAMDAN & SCHERER, 2021) von Hamdan et al., sowie verschiedene Ontologien zur Klassifikation von Schäden an bestimmten Materialien.

Die DOT Ontologie ist fokussiert auf Klassen für die Definition und Beschreibung von Schäden und Schadensbereichen und deren Verbindung zu betroffenen Bauteilen (vgl. AS 3.2). Die AOI Ontologie verfeinert diese Verbindung und definiert die konkreten einzelne Bereiche der Bauteile, an welchen der Schaden auftritt. Die Bauteile selbst müssen jedoch in einer externen Ontologie beschrieben werden.

Durch die Umwandlung von ASB-ING in eine Ontologie (vgl. Abschnitt 9.1) (GÖBELS & BEETZ, 2021) stehen uns die darin enthaltenen Definitionen von Schäden und Bauteilen ebenfalls zur Verfügung. Wie in Kapitel 9.1 beschrieben, erlaubt die ASB-ING Ontologie die Konvertierung der SIB-Bauwerke Daten in RDF-Graphen. Dies ermöglicht es, die bereits dokumentierten Schäden mithilfe von Linked Data Technologie mit den entsprechenden Bauteilen zu verknüpfen.

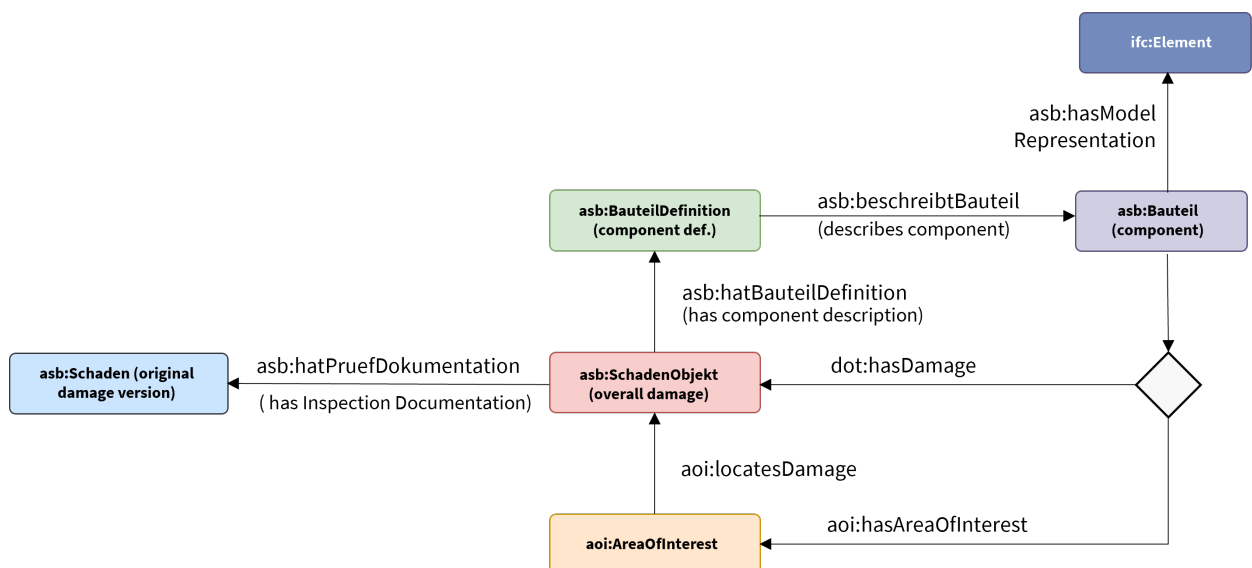


Abbildung 52: Neu eingeführte bauteilorientierte Dokumentation von Schadensinformationen.

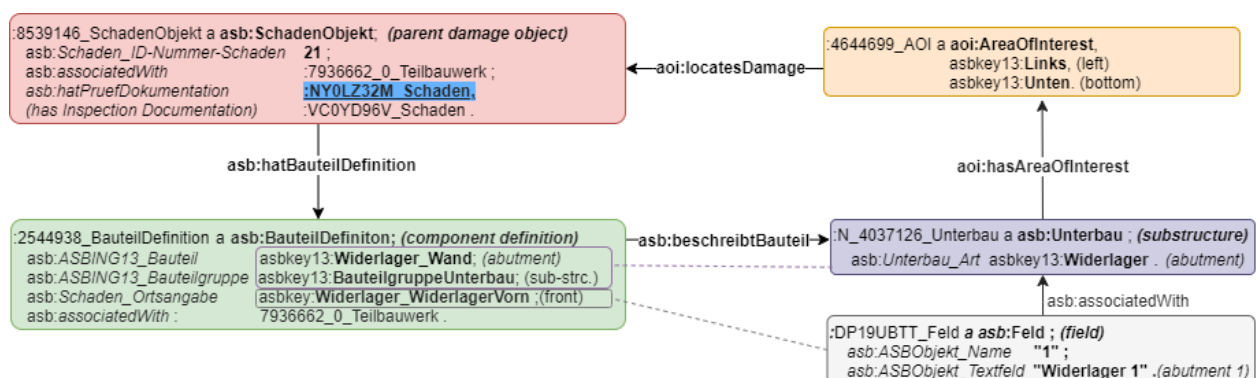


Abbildung 53: Darstellung der bauteilorientierten Schadensdokumentation mit Beispieldaten.

Da in SIB-Bauwerke die Schäden nur durch textliche Beschreibungen den betroffenen Bauteilen zugeordnet werden, wird zunächst die Struktur innerhalb des SIB-Bauwerke Graphen angepasst,

sodass es einen expliziten Link zwischen dem ebenfalls in SIB-Bauwerke dokumentierten Bauteil und dessen Schäden gibt GÖBELS, 2022. Abbildung 52, zeigt die neue, objekt-orientierte Struktur, welche mithilfe der DOT und AOI Ontologie erstellt werden konnte.

Um diese Struktur umzusetzen, werden zunächst alle Versionen eines Schadens aus den verschiedenen Inspektionsjahren in einem übergeordneten neu erstellten Schaden Objektzusammengeführt. So muss für die räumliche Verlinkung des Schadens in Modell nur ein Schaden verarbeitet werden, anstatt alle Versionen dieses Schadens. Zudem ermöglicht die Zusammenfassung der Schäden ein einfachere Abfrage und Analyse der chronologischen Zustände und Veränderungen des Schadens.

Die Zuordnung der Schäden zu den betroffenen Bauteilen wird aus der jeweiligen „Bauteil“-/„Konstruktionsteil“-Bauteilgruppenangabe und der „Ortsangabe“ des Schadens aus SIB-Bauwerke abgeleitet. Diese Angaben, die das individuelle Bauteil beschreiben werden als "Bauteildefinition" zusammengefasst. Durch den Einsatz vergleichender, strukturierter Abfragen (SPARQL Queries) kann aufgrund der "Bauteildefinition", das separat dokumentierte ASB-ING Bauteil aus SIB-Bauwerke gefunden werden. Die Angaben die geschädigten Bereich des Bauteils beschreiben als "Area of Interest" festgehalten. Abbildung 53 zeigt die neue Struktur anhand eines Beispiels, das verdeutlicht, welche Daten in welchem Objekt gespeichert sind, und wie die Zuordnung von Bauteildefinition und Bauteil funktioniert.

Diese neu eingeführte Struktur ist kompatibel mit der objektorientierten Struktur von IFC-Modellen, welche das bauteilorientierte Verknüpfen dieser beiden Datensets vereinfacht, bzw. erst ermöglicht. Zudem erlaubt sie auch innerhalb von den SIB-Bauwerke Daten eine genauere Analyse von einzelnen Bauteilen und ihren geschädigten Bereichen, anstatt lediglich eine undifferenzierte Zustandsnote für eine gesamte Bauteilgruppe.

In Kapitel 8.4 wird beschrieben, wie die Informationen aus den "Bauteildefinition und AreaOfInterest-Angaben" verarbeitet werden, um die Verknüpfungen zum IFC-Modell zu erstellen. Resultat sind explizite Links zwischen den ASB-ING und IFC-Bauteilen und eine dreidimensionale Repräsentation der dokumentierten Schadensbereiche.

So können die existierenden Daten strukturiert und einfach zugänglich über das Modell abgerufen werden. Die Verortung im Modell erlaubt überdies auch räumliche Analysen der Schäden um bspw. besonders beschädigte Bereiche der Brücke aufzufinden oder räumliche Zusammenhänge von verschiedenen Schäden zu verfolgen. Bild 54 zeigt die Darstellung von Schäden im Modell, überlagert mit den semantischen Informationen aus SIB-Bauwerke in einem prototypisch im Rahmen des Projekts entwickelten 3D-Viewer (<https://design-computation-rwth.github.io/LinkedDataViewerPublic/>).

Neu dokumentierte Schäden, die beispielsweise durch die automatische Schadenserkennung durch Bild- und Punktwolkenanalysen klassifiziert werden, können durch die Linked Data Methode ebenfalls zum Datensatz hinzugefügt und verknüpft werden, sofern sie mithilfe einer Ontologie (bspw. DOT) im RDF-Format dokumentiert wurden (s. Abbildung 55). Durch ein Mapping der Ontologie, die für die „neu“ definierten/dokumentierten Schäden genutzt wurde, und der ASB-ING

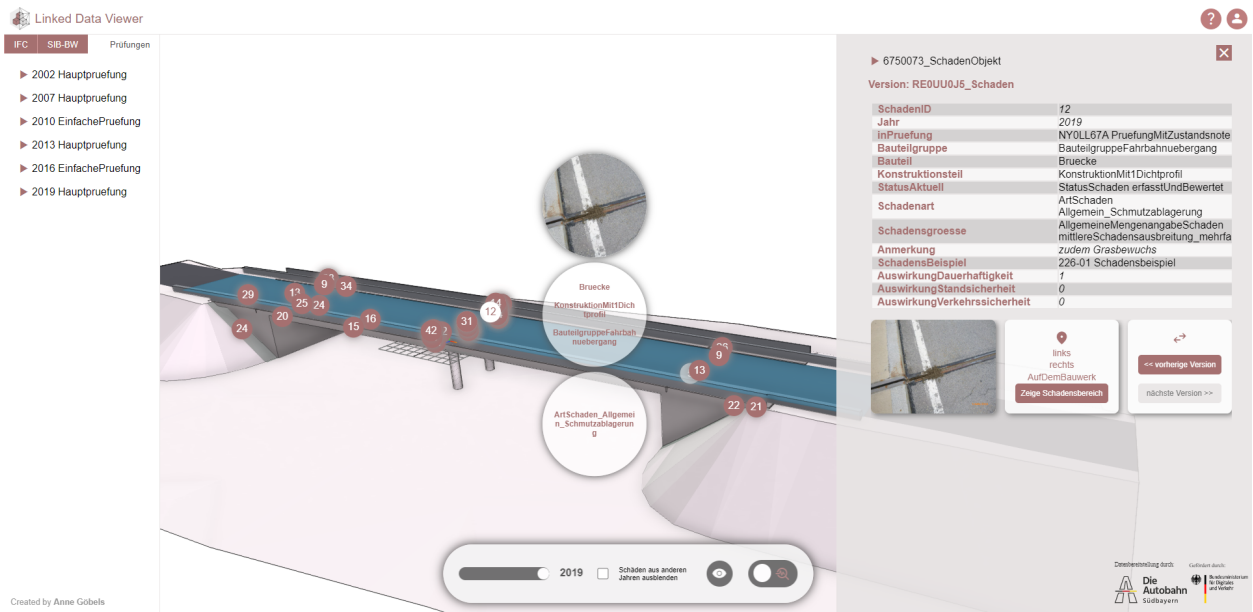


Abbildung 54: Darstellung der Schäden im prototypischen Viewer.

Ontologie, ist es zudem möglich, auch die neuen Schäden im vorgegeben Format nach ASB-ING zu beschreiben.

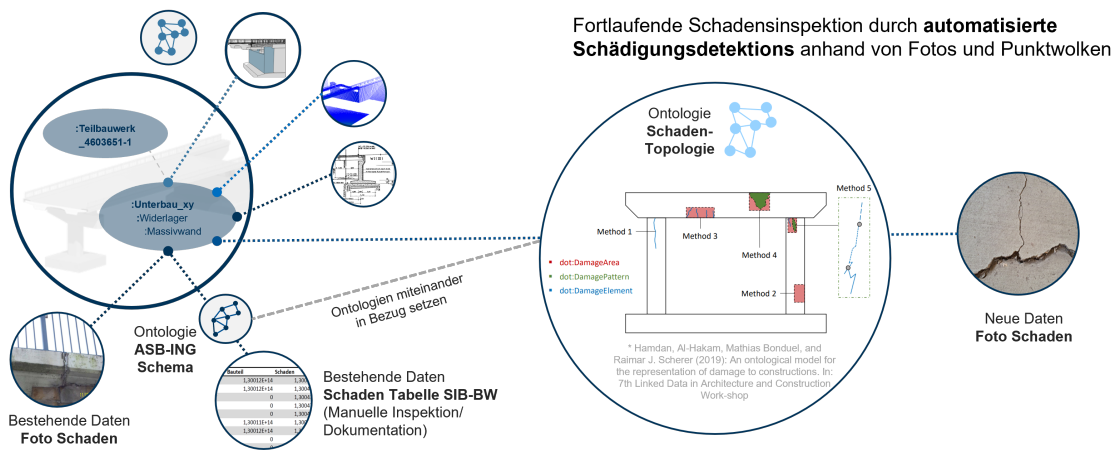


Abbildung 55: Bauteilorientierte Verknüpfung der Schadensinformationen.

6.2 Bildererkennungsmethoden zur automatisierten Schädigungsdetektion und Berücksichtigung von Schäden bei der semantischen Anreicherung

Im Bereich der KI-basierten Schadenerkennung im Bauwesen liegt der Forschungsschwerpunkt auf der Detektion von Beton- oder Asphalttrissen. Gründe hierfür sind zum einen das häufige Auftreten von Rissen in vielen Bauwerken und zum anderen die feine und komplexe Struktur von Rissen, die eine besondere Herausforderung für neuronale Netze darstellen. Zur vollständigen Automatisierung der Schadenerkennung ist dabei nicht nur die Erkennung von Rissen, sondern auch weiteren Schadensarten notwendig. Daher wurde das Spektrum um die drei Schadensarten Kiesnester, Abplatzungen bzw. Delaminationen und Korrosion erweitert.

Für dieses Vorhaben wurde ein Bild-Datensatz erstellt, der die oben erwähnten Schadensarten enthält. Die Bilder wurden mithilfe von internationalen Studierenden in verschiedenen Ländern und von unterschiedlichen Betonbauwerken aufgenommen. Die Bildaufnahme erfolgte mit Smartphone-Kameras. Der Datensatz umfasst 6189 Fotos mit einer Größe von 1024x1024 Pixeln. Die anschließende Annotation der Bilder wurde in Form von Segmentierung im Stil der COCO-Annotationsdokumentation (LIN et al., 2014) vorgenommen.

Der Datensatz wurde nach folgenden Kriterien zusammengestellt:

1. Der Datensatz soll eine möglichst große Variation der definierten Schadensarten vorweisen, da so das auf diesem Datensatz trainierte KI-Modell zuverlässig wird.
2. Die ausgewählten Schadensarten sollen von Studierenden ohne große Schwierigkeiten zu erkennen und zu unterscheiden sein, da der erste Durchlauf der Annotationsarbeit von Studierenden durchgeführt werden musste. Diese war erforderlich, da der Einsatz von Experten für die zeitintensive Annotationsarbeit aus Zeit- und Kostengründen nicht zu erfüllen war. In einem zweiten Durchlauf wurde die Annotation auf geometrische Konsistenz und Richtigkeit der Schadensbezeichnung geprüft und gegebenenfalls korrigiert.

Als KI-Architektur wurde das Feature Pyramid Network (FPN) (LIN et al., 2017) verwendet, da es bei mehreren Versuchen zur Schadenssegmentierung gegenüber anderen Architekturen wie U-Net (RONNEBERGER et al., 2015), U-Net++ (ZHOU et al., 2018), DeepLabv3+ (CHEN et al., 2018) und LinkNet (CHAURASIA & CULURCIELLO, 2017) die besten Resultate erzielt hat. Um das Training zu optimieren und dem FPN zu einer besseren Informationsextraktion zu verhelfen, wurde Transfer Learning angewendet. Dabei wurden die Faltungskerne in den Aufwärtsverknüpfungen (engl. bottom-up path) des FPN durch die auf ImageNet vortrainierten Faltungskerne des EfficientNetB0 (TAN & LE, 2019) ersetzt. Für die zuverlässige Evaluierung der Segmentierungsergebnisse wurde eine fünffache Kreuzvalidierung durchgeführt.

Die Trainingsdatensätze wurden mit Datenaugmentierungstechniken wie Rotation, tonnenförmige Verzerrung, Unschärfe, Aufhellung sowie Verdunkelung angereichert. Zusätzlich wurden den Trainingsdatensätzen 33 Bilder von Bauwerken und Bauwerksumgebungen ohne Schäden hinzugefügt, damit das Netzwerk lernt Schadens-ähnliche Strukturen von Schäden zu unterscheiden. Insgesamt bestanden die Trainingsdatensätze aus 19.869 Bildern und die Validierungsdatensätze aus 1.239 Bildern. Als Verlustfunktion wurde die Jaccard-Funktion angewandt und als Metrik zur Messung der Genauigkeit der Segmentierungsmasken wurde der Jaccard-Index gewählt.

Das FPN wurde auf zwei verschiedene Weisen trainiert. Als Erstes wurde das Netz mit Daten für alle vier Schadensarten trainiert, d.h. die Ground Truth Daten bestanden aus vier Kanälen, die jeweils die geometrischen und semantischen Informationen zu den Schadensarten enthalten (Methode 1 in Tabelle 2). In einem weiteren Schritt wurde das FPN einzeln für jede Schadensarten separat trainiert, d.h. die Ground Truth Daten bestanden aus jeweils einem Kanal (Methode 2). Die Ergebnisse der FPN-Modelle sind in Tabelle 2 zusammengefasst. Die Ergebnisse zeigen, dass die FPN-Modelle, die auf den einzelnen Schadensarten trainiert wurden, akkurater sind als das FPN-Modell, das auf vier Schadensarten gleichzeitig trainiert wurde. So ist die Segmentierung von Abplatzungen um 7,7 %, für Risse um 8,15 %, für Korrosion um 9,84 % und für Kiesnest

Tabelle 2: Ergebnisse der FPN-Segmentierung als Jaccard-Index für einzelne Schadenkategorien

	Abplatzung	Riss	Korrosion	Kiesnest
Methode 1	53,92 ± 3,28	46,34 ± 3,53	56,32 ± 2,21	50,89 ± 3,9
Methode 2	61,62 ± 0,76	54,04 ± 1,06	66,46 ± 2,3	55,07 ± 1,35

um 4,53 % besser. Auffällig ist auch, dass die FPN-Modelle, die auf einzelnen Schadensarten trainiert wurden, geringere Standardabweichungen vorweisen als die FPN-Modelle, die auf allen vier Schadensarten trainiert wurden. Folglich sind die auf einzelne Arten trainierten FPN-Modelle robuster bzw. konsistenter in der Informationsextraktion. Die Erkennung von Korrosion mit dem FPN ist deutlich akkurater als bei anderen Schadensarten. Dies kann mit dem farblichen Merkmal von Korrosion zusammenhängen. Die Erkennung von Rissen ist im Vergleich zu anderen Schadensarten aufgrund ihrer feinen Struktur weiterhin eine große Herausforderung.

Visualisiert man die Segmentierungsleistung der FPN-Modelle auf Testbildern, wie in Abbildung 56 und Abbildung 57 so wird deutlich, dass die FPN-Architektur Schäden gut segmentieren kann. In Abbildung 56 wird außerdem gezeigt, dass Risse im Millimeter-Bereich akkurat erkannt werden. Nutzt man zusätzlich mit Tiefensensoren ausgestattete Kameras, so kann mithilfe der berechneten Segmentierungsmaske die Breite und Länge der Risse und Flächen der Abplatzungen und Kiesnester berechnet werden. Dadurch wäre die Nutzung von Hilfsmitteln wie Risschablone und Gliedermaßstab überflüssig.




Abbildung 56: Segmentierung von feinen Rissen (blaue Masken) mit Breiten im Millimeterbereich.

Für die Erstellung eines digitalen Zwillings ist die genaue Lokalisierung der Schäden in den Bauteilen ein weiterer wichtiger Schritt. Dabei kann die Schadensintegration in zwei Schritten erfolgen. Im ersten Schritt können mithilfe von Punktwolkenaufnahmen relativ große Schäden (Abplatzungen, korrodierte Bewehrung und Kiesnester) segmentiert werden, sodass die geometrische Form und die Ortsinformation für jedes erkannte Schadensobjekt genau gegeben ist. In einem zweiten Schritt können kleine Schadensobjekte, wie Risse, vor Ort während der Bauwerksinspektion grob verortet werden. Für den ersten Schritt können KI-Netze für die Segmentierung in Punktwolken oder auf



Abbildung 57: Segmentierung von Rissen (blaue Masken), Korrosion (grüne Maske) und Abplatzung (rote Maske) auf einem Testbild mit einem FPN-Modell.

Bildern von Punktwolkenabschnitten genutzt werden. Die erste Option ist aufgrund des hohen Zeitaufwands, insbesondere aufgrund der Erstellung eines entsprechenden Datensatzes, und der begrenzten Projektzeit nicht durchführbar. Die zweite Option bietet sich an, weil bildbasierte Segmentierungsmodelle zur Verfügung stehen. In Abbildung 58 und Abbildung 59 werden die Segmentierungsergebnisse auf Testbildern von Punktwolken gezeigt. Diese Testbilder enthalten Abplatzungen mit freiliegender korrodierter Bewehrung von Betonbauteilen. Trotz der Differenz von Bildern aus Kameraaufnahmen und Punktwolkenbildern kann eine Segmentierung erfolgen - wenn auch nicht fehlerfrei. So werden beispielsweise deutlich erkennbare freiliegende korrodierte Bewehrungen nicht vollständig erkannt. Eine Anpassung des vorhandenen Datensatzes an die Punktwolkendarstellung kann die Ergebnisse verbessern. Ein offener Schritt ist die Übertragung der bildbasierten Segmentierungsinformationen auf die entsprechenden Punkte in der Punktwolke.



Abbildung 58: Punktwolke von einer Stütze mit einer Abplatzung und einer freiliegenden korrodierten Bewehrung. Das FPN-Modell erkennt im Bild die Abplatzung, jedoch nicht die Korrosion der Bewehrung



Abbildung 59: Punktwolke von einer Betondecke mit mehreren Abplatzungen und freiliegenden korrodierten Bewehrungsstäbe. Das FPN-Modell erkennt viele Abplatzungs- und Korrosionsobjekte.

6.3 Einbindung in aktuelle Best-Practice-Verfahren zur Erfassung des Bauzustandes

Die Erfassung des Bauzustandes und somit auch von Schäden ist ein Anwendungsgebiet der Dienstleistungen von ZPP. Es wurden die vorhandenen Erfahrungen eingebracht und die Konzepte hinsichtlich Verwertungspotential diskutiert.

Den Projektbeteiligten wurde zur Analyse der aktuellen Anforderungen an BIM-Bauwerksmodelle ein aktuelles Beispiel für ein Brückenmodell vorgestellt. Hierbei wurden Themen wie Modellstruktur, Anforderungen an einzelne Fachmodelle, aktuelle Anwendungsfälle und Nutzung, ebenso wie die Ableitung von Modellierungsanforderungen besprochen. Die Ergebnisse des Workshops sind in die

Bewertung der einzelnen Auswertungsmethoden und automatisierten Modellierungsansätze eingeflossen. Insbesondere der Aspekt der unterschiedlichen Detaillierungsstufen zwischen Modellen der Ausführungsphase und zum Betrieb von Infrastrukturbauwerken benötigten As-Built-Modellen wurde diskutiert.

Im Rahmen eines weiteren Workshops wurden die aktuelle Vorgehensweise der Bauwerksinspektion und Bewertung präsentiert. Insbesondere die aktuelle Aufnahme und Beschreibung der Verortung von Schäden war hierbei im Fokus. In diesem Zuge wurde ebenfalls der Prozess der Inspektion von Brücken nach DIN1076 erläutert. Die anschließende Diskussionsrunde hat unter anderem ergeben, dass es bereits Prüfungen gibt, bei denen Angaben in SIB-Bauwerke bereits sehr umfangreich vorgenommen wurden und diese als Grundlage zur Weiterentwicklung der Konzepte dienen können. Die Daten wurden den Projektbeteiligten übergeben und bei deren Auswertung unterstützt.

AP 7: Verfahren zur Extraktion von Informationen aus technischen Zeichnungen

Die in den AP 2 und 3 entwickelten Erfassungsverfahren sind systemimmanent auf die Erfassung der sichtbaren Oberfläche von Infrastrukturbauwerken beschränkt. Insbesondere beim Brückenbau spielen aber nicht sichtbare Gegebenheiten eine wichtige Rolle. Beispielsweise werden sehr häufig Hohlkastenquerschnitte eingesetzt, die in einem umfassenden Digitalen Zwilling samt dem Hohlraum abgebildet werden müssen, auch wenn dieser nicht sichtbar ist. Ein weiteres wichtiges Element bildet die in den allermeisten Fällen unzugängliche Spanngliedführung, die ebenfalls Teil des Digitalen Zwillings sein muss. Informationen zu verborgenen Gegebenheiten sind häufig in den technischen Zeichnungen aus der Planung enthalten. Im Rahmen dieses Arbeitspakets wurden daher Verfahren entwickelt, um diese Informationen aus technischen Zeichnungen zu extrahieren. Dazu wurden Verfahren der Bilderkennung mit modernen Verfahren des maschinellen Lernens (Deep Learning) kombiniert.

7.1 Deep Learning-Verfahren zur Extraktion von Informationen aus technischen Zeichnungen

Da Punktwolkendaten nur die äußere Hülle von Elementen zeigen, können technische Zeichnungen als ergänzende Informationsquelle für die Modellierung der gesamten Brücke oder unsichtbarer Teile verwendet werden. Technische Zeichnungen von Brücken bestehen im Allgemeinen aus verschiedenen Elementen und verschiedenen Ansichten. Zum Beispiel die Vorderansicht der Flügelwand, die Seitenansicht der Flügelwand, die Draufsicht des Widerlagers usw. Außerdem gibt es Maßlinien, Zahlen und Tabellen, die die geometrischen und semantischen Informationen von Brücken darstellen. Um diese Informationen zu extrahieren, müssen die 2D-Zeichnungen digitalisiert werden. Die Digitalisierung einer Brückenzeichnung kann mit der Erfassung von Ansichten und Schnitten beginnen. Zu diesem Zweck wurden die technischen Zeichnungen von 16 einfeldrigen Brücken aus Stahlbeton (RC) ausgewertet. Jede Brücke hat im Durchschnitt etwa 15 verschiedene Bilder, und diese Bilder bestehen außerdem aus mehreren verschiedenen Ansichten der Brücke. Nach der Identifizierung der Klassen wurden die technischen Zeichnungen dieser verschiedenen Ansichten den jeweiligen Klassen zugeordnet, so dass es am Ende der Identifizierung und Zuordnung der Klassen insgesamt 14 Klassen gibt. Einige Beispiele für solche Klassen sind die Draufsicht auf die gesamte Brücke, der Querschnitt des Decks, die U-förmige Draufsicht auf das Widerlager, die trapezförmige Seitenansicht des Widerlagers und so weiter.

Hier ist zu erkennen, dass die Zeichnungen den Klassen ausschließlich auf der Grundlage der geometrischen Informationen und der Form einer Ansicht zugeordnet werden. Die technischen Zeichnungen der Brücken wurden manuell annotiert, indem Bounding Boxes um eine Ansicht gezeichnet und mit der jeweiligen Klasse beschriftet wurden (siehe Abbildung 2).

Da für einige Klassen keine ausreichenden Proben zur Verfügung standen, wurde der Eingabedatensatz erweitert. Zu diesem Zweck wird das parametrische Modell der Brückenkomponenten




Abbildung 60: Anzahl der Beispiele für jede Klasse.

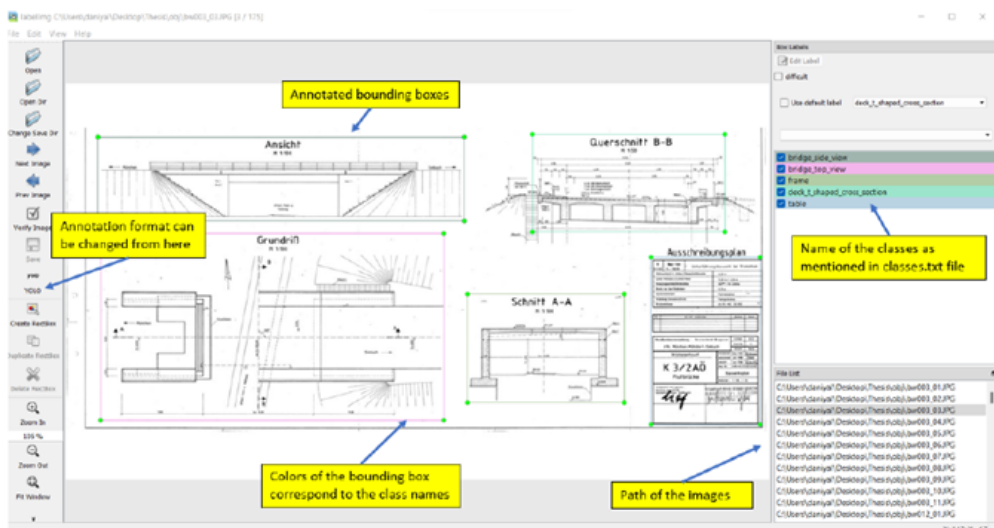


Abbildung 61: Beschriftungsprozess von Bildern

in AutoCAD erstellt, wie in Abbildung 3 dargestellt. Durch Änderung der Parameterwerte werden neue synthetische Zeichnungen erstellt und dem Datensatz der aktuellen Bilder hinzugefügt.

Um Elemente und ihre Ansichten zu erkennen, wird Yolo v4 als Deep-Learning-Modell trainiert. Um den Wert der Hyperparameter für dieses Modell einzustellen, wird ein Versuch-und-Irrtum-Verfahren durchgeführt. Zum Trainieren des Modells wird eine Stapelgröße von 8, eine Lernrate von 0,001 und eine Unterteilung 8 gewählt. Abbildung 4 zeigt das Lerndiagramm des Modells, in dem das Modell eine mittlere durchschnittliche Präzision (mAP) von 89,15 % erreicht hat.

Nach dem Training des Modells wurde seine Leistung mit 20 % der tatsächlichen Bilder bewertet. Abbildung 5 zeigt die Testergebnisse des Modells nach dem Training. Wie zu sehen ist, konnte das Modell bei den meisten Beispielen die Bounding Box korrekt erkennen.

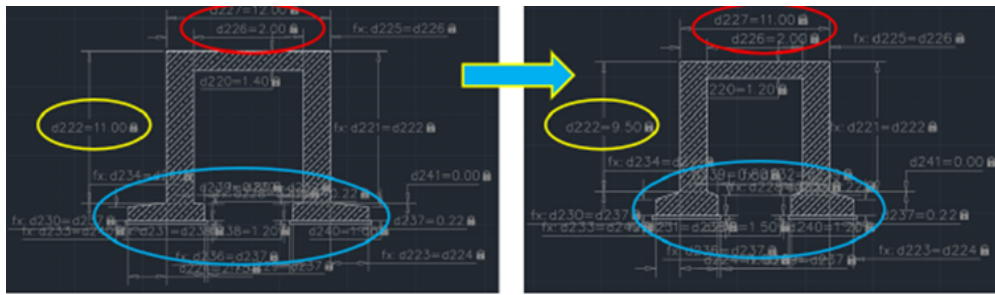


Abbildung 62: Datenerweiterung durch parametrische Modellierung der Brückenelemente.

Anschließend müssen die Zahlen (Abmessungen) in ein digitales Format umgewandelt werden. Zu diesem Zweck werden Algorithmen zur optischen Zeichenerkennung (OCR) verwendet, wie in der Abbildung zu sehen ist





Abbildung 63: Lerndiagramme des Modells.



Nach der Erkennung des Begrenzungsrahmens (Bounding Box) für jedes Element mit dem entsprechenden Typ wird eine Aufgabe zur Erkennung von Text in der Szene definiert, um Zahlen in der Zeichnung zu erkennen. Zu diesem Zweck wird Craft, ein vortrainiertes Modell, eingesetzt. Dieser Modus ist in der Lage, vorhandene Texte in Bildern zu erkennen und ein Polygon um sie herum zu zeichnen. Abbildung 6 veranschaulicht

Abbildung 64: Ergebnisse der Tests an tatsächlichen Bildern.

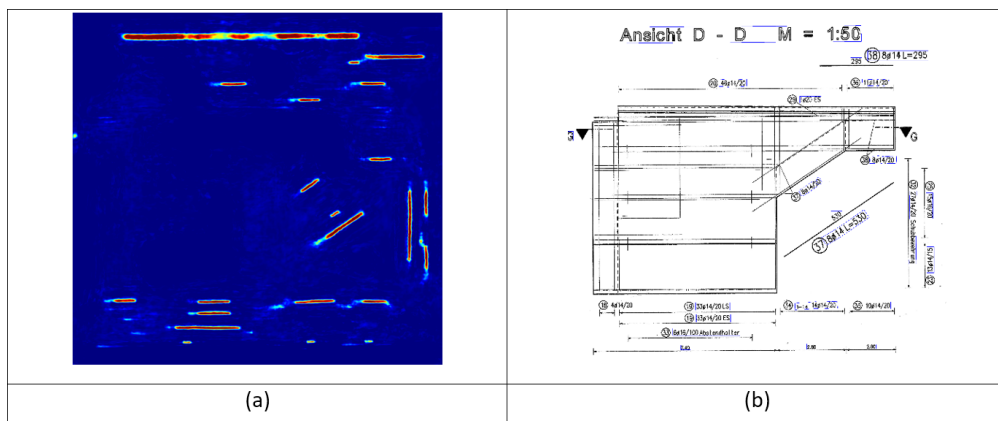


Abbildung 65: Ergebnisse: (a) Text-Score-Heatmap; (b) erkannte Polygone.

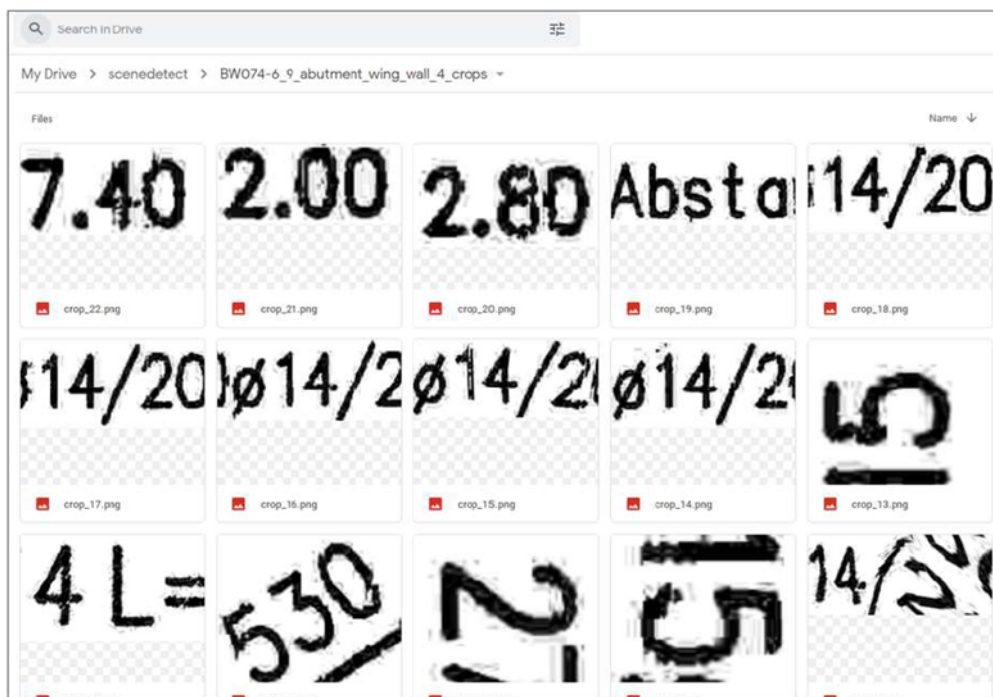


Abbildung 66: Ergebnisse der Anwendung von OCR auf die erkannten Nummern.

7.2 Integration der extrahierten Informationen in digitale Brückenmodelle

Geometrische Informationen werden hauptsächlich aus Punktwolkendaten extrahiert, da sie den aktuellen Zustand der bestehenden Struktur darstellen. Für die Flächen, die in den Punktwolkendaten nicht sichtbar sind, wie z. B. die Rückseite der Flügelwände eines Widerlagers, werden jedoch auch technische Zeichnungen verwendet. Zu diesem Zweck wird das parametrische Dummy-Modell der Brücke erstellt, wie in Abbildung 67 zu sehen ist. Aufgrund des parametrischen Aufbaus des Modells ist es vollständig von den Werten der Parameter abhängig. Daher kann es aktualisiert werden, wenn sich der Wert der Parameter ändert. Dieses Dummy-Modell wird verwendet, um das parametrische Modell der gesamten Brücke aus den Punktwolkendaten zu erstellen. Zu diesem Zweck müssen die aus den PPMs extrahierten Parameter zusammengestellt und in die Parameterliste des Dummy-Modells der Brücke importiert werden.

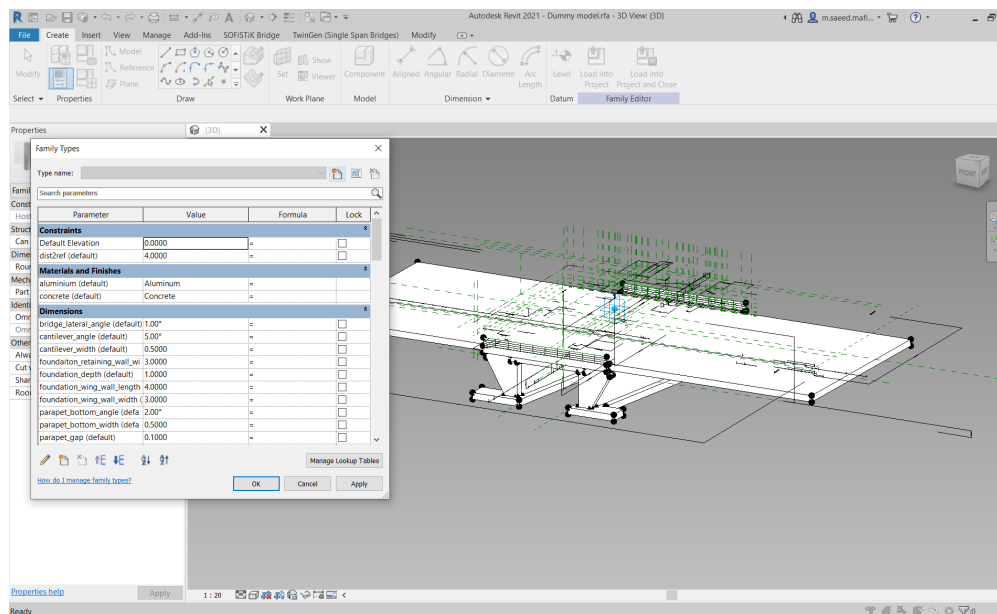


Abbildung 67: Dummy-Modell der Brücke mit deren Parametern.

Wir schlagen einen Top-Down-Ansatz für die Zusammenstellung von PPMs vor. Dieser Ansatz speichert die Beziehungen zwischen den Elementen und hält das Modell parametrisch. Abbildung 68 zeigt ein Widerlager, dessen drei Flächen durch PPMs angepasst wurden. Unter der Annahme, dass der Wert der Höhe, der sich aus allen Flächen ergibt, gleich sein muss, müssen die Parameter p_1 , p_2 und p_3 zusammengesetzt werden. Zu diesem Zweck bilden wir einen Satz dieser Parameter $s = p_1, p_2, p_3$ und berechnen den maximalen ($\text{Max}(s)$) und minimalen ($\text{Min}(s)$) Wert dieser Parameter. Für das Modell des Widerlagers gibt es den Parameter P_2 so, dass $\text{min}(s) \leq P_2 \leq \text{max}(s)$. Daher kann für P_2 ein zufälliger Wert in diesem Bereich gewählt werden, und die elementweisen Optimierungsprobleme werden erneut unter Verwendung dieser unteren und oberen Schranken gelöst. Als Ergebnis erhält man einen Wert für P_2 , der in allen drei Flächen verwendet werden kann.

Dieses Verfahren kann auf alle Elemente der Brücke ausgedehnt werden, und man erhält die erforderliche Liste für das Dummy-Modell der Brücke.




Abbildung 68: Verfahren zur Zusammensetzung eines Widerlagers.

7.3 Anreicherung von bestehenden Raster- und Vektor-Zeichnungsdaten mit bidirektionalen Links in weitere Datenmodelle

Um die im AP 7.1 verarbeiteten Pläne mit in die Linked Data Struktur des digitalen Zwillings zu übertragen, werden diese im ICDD Container gespeichert und mithilfe der ICDD Technologie (s. Kapitel 3.2) mit den anderen Ressourcen verlinkt. Die Segmentierung der Pläne erlaubt zudem eine objektscharfe Verlinkung der Planinhalte. So können bestimmte Bereiche des Plans (die ein bestimmtes Bauteil zeigen) mit den entsprechenden Repräsentationen/ Dokumentationen dieses Bauteils aus dem IFC Modell und dem Bauwerksbuch aus SIB-Bauwerke verknüpft werden. So können als Ergänzung zu den geometrischen und semantischen Daten, konstruktive Details, unsichtbare/ innenliegende Aufbauten und genaue Vermaßungen abgerufen werden.

Die ICDD Technologie wird auch genutzt um die Schadenfotos und Zeichnungen, die zuvor nur lose den Schadensbeschreibungen zugeordnet waren explizit zu verlinken. Mithilfe der Metadaten der Fotos (Exif-daten) und der Namen der Fotos, die in SIB-Bauwerke gespeichert sind, konnte die Verknüpfung zwischen Schaden und Foto automatisiert und in chronologischer korrekter Reihenfolge erfolgen.

AP 8: Semantische Anreicherung der Modelle mit Hilfe von Expertenwissen

Beim Einsatz der in den vorangegangenen APs entwickelten Verfahren werden im Ergebnis in der Regel rein geometrische Modelle erzeugt. Dies ist aber für die Aufgabenstellung der Bereitstellung eines Digitalen Zwillings für die Bewirtschaftung und Instandhaltung nicht ausreichend. Stattdessen ist es notwendig, Bauteile mit einer entsprechenden Semantik zu versehen, d.h. sie entsprechend ihrer Funktion zu klassifizieren, mit Attributen zu Materialinformationen zu versehen und entsprechende Bauteil-Beziehungen zu setzen. Hierfür wurden aus dem Bereich der künstlichen Intelligenz bekannte regelbasierte Ansätze und maschinelle Lernverfahren eingesetzt. Es wurden Muster in den vorhandenen Daten erkannt und dann mit Hilfe von Regeln und Assistenzsystemen schrittweise in semantische Modelle überführt.

8.1 Algorithmen zur Erkennung von Objekten in Bildern und Punktwolken auf Basis von Mustern

Die wahre Geometrie eines Bauwerks soll durch das iterative Anpassen von Bauteilprimitiven an eine Punktwolke extrahiert werden. Dazu ist es notwendig, die Zugehörigkeit der einzelnen Punkte zu den jeweiligen Bauteilen zu kennen. Im Projekt werden hierzu künstliche neuronale Netze (KNN) aus dem Bereich des Deep Learning eingesetzt. Die Zugehörigkeitserfassung wird als semantische Segmentierung bezeichnet und ist aktuell ein durch großen Forschungsvortrieb gekennzeichnete Bereich.

Für die semantische Segmentierung von dreidimensionalen Punktwolken werden verschiedene Verfahren eingesetzt, welche sich übergreifend in zwei Ansätze aufgliedern lassen. Auf der einen Seite existieren Verfahren, die eine vorangegangene Quantisierung (Vereinfachung) der Punktwolke erfordern, auf der anderen Seite gibt es Methoden, die direkt auf der Punktwolke arbeiten. Zu Ersterem gehören Ansätze, die eine gleichmäßige räumliche Unterteilung der Punktwolke vornehmen, zum Beispiel Voxelisierung. Dabei wird ein Raster mit gleichmäßigen Abständen über die Punktwolke gelegt, ähnlich dem Pixelraster bei Fotos, und innerhalb dieser Volumenpixel (Voxel) die darin enthaltenen Punkte vereinheitlicht. So kann mit traditionellen Bilderkennungsverfahren wie 3D-CNN auf dem Raster gearbeitet werden. Andere Vorverarbeitungen sind das Trennen der Punktwolke in Scheiben, auf welchen dann 2D-Bildverfahren agieren. Die Dreidimensionalität der Eingangsdaten wird dabei durch das Schneiden aus verschiedenen Blickrichtungen (MultiView) beachtet.

Bei allen oben genannten Ansätzen geht durch die Vereinfachung der Daten wichtige Informationen zum lokalen und globalen Bezug der betrachteten Punkte verloren. Aus diesem Grund wurden Verfahren entwickelt, die direkt auf den Punktdaten agieren, hierbei gilt PointNet (Qi et al., 2016) als Vorreiter. Aus diesem Grund wird PointNet in dem Projekt für die Segmentierung der Punktwolken eingesetzt. Initial wird die KNN-Architektur angelernt. Dem Netz werden dazu annotierte Punktwolken gezeigt, sodass dieses lernt, Vorhersagen über die Zugehörigkeit von Punkten selbstständig durchzuführen. Um eine ausreichende Quantität der Trainingsdaten zu gewährleisten, werden




Abbildung 69: Vorläufige Ergebnisse der semantischen Punktwolkensegmentierung. Links ist die Grundwahrheit, rechts die Vorhersage des KNN.

synthetische Punktwolken nach dem in Abschnitt 2.3 vorgeschlagenen Verfahren erzeugt. Das Anlernen soll zukünftig an mehr Punktwolken und an Bauwerken größerer Diversität durchgeführt werden. Eine qualitative Validierung wird darüber hinaus an reellen Punktwolken stattfinden. Auch werden im weiteren Verlauf des Projektes andere neuronale Netze eingesetzt und deren Performanz untereinander verglichen.

In Abbildung 69 ist eine erste Validierung der Vorhersagegenauigkeit innerhalb der synthetischen Datensätze zu sehen. Das Verfahren zeigt gute Ergebnisse.

8.2 Entwicklung eines Verfahrens zur Zuweisung von Semantik für Brückenbauteile

Um das parametrische Modell der gesamten Brücke zu erstellen, muss die Punktwolke in Teile segmentiert werden, die die Brückenkomponenten darstellen. Dieser Prozess liefert eine Aussage über die Semantik der Brückenelemente. Anschließend können die Flächen und Querschnitte der segmentierten Teile durch Lösen elementweiser Optimierungsprobleme auf der Grundlage von PPMs angepasst werden. Diese Teile werden schließlich zusammengesetzt und die Werte werden in das Dummy-Modell importiert, um die Punktwolke der Brücke darzustellen.

Input Features

Input Features (Eingabemerkmale) sind die ursprünglichen Eingaben, die in ein neuronales Netz (NN) eingespeist werden. Die ersten Schichten eines tiefen Netzes verarbeiten sie im Allgemeinen, um weitere Merkmale zu extrahieren, die zu genaueren Vorhersagen führen. Bei der PCD von Brücken kann die Berechnung und Hinzufügung einiger dieser Eingabemerkmale die Ergebnisse verbessern, so dass eine Mischung aus *feature engineering* und *feature exploration* entsteht.

XYZ-Koordinaten und RGB-Kanäle

XYZ-Koordinaten von Punkten und RGB-Kanäle sind die Standardmerkmale, die in den meisten NN-Modellen mit der Fähigkeit, Punkte zu verarbeiten, verwendet werden. In Brücken kann xyz von Punkten die lokale, globale und relative Position von Elementen darstellen. RGB kann auch ein Merkmal sein, das die Teile hervorhebt, die unterschiedliche Farben haben (z. B. der Hintergrund, der Brückenkörper, die Straßenoberfläche und das Gelände).

Normalenvektoren

Brücken bestehen meist aus horizontalen und vertikalen Elementen. Normalenvektoren können daher eine wichtige Informationsquelle für das Netz darstellen. Normalenvektoren (n_x, n_y, n_z) sind Merkmale auf Punktebene, die sich aus der Kovarianzmatrix benachbarter Punkte ergeben und den Unterschied zwischen diesen Elementen anzeigen. Horizontale Elemente haben im Allgemeinen höhere n_z und niedrigere n_x und n_y als die vertikalen Elemente. Da die Punktwolke von Brücken eine Rotation um die z -Achse aufweisen kann, können n_x und n_y in verschiedenen Stichproben unterschiedliche Werte aufweisen. Um das Netz drehungsinvariant zu machen, wird der Betrag des resultierenden Vektors aus n_x und n_y berechnet und als Merkmal verwendet.

Lokale Varianz in z-Richtung

Die Varianz als Maß für die Streuung zeigt den Abstand der Punktmenge zu ihrem Mittelwert an. Vertikale Elemente in Brücken haben eine höhere lokale Varianz in z -Richtung als horizontale Elemente. Dieses Merkmal kann lokal in einer Kugel mit einem vordefinierten Radius berechnet werden, wobei der Wert der Varianz für die z -Komponente der Punkte ermittelt wird.

2D-Dichte

Ein weiteres Merkmal zur Unterscheidung zwischen horizontalen und vertikalen Elementen ist die 2D-Dichte der Punkte. Dieses Merkmal kann berechnet werden, indem die Anzahl der Punkte in einem Kreis nach der Projektion auf die xy -Ebene gezählt wird. Vertikale Elemente haben eine höhere 2-D-Dichte als horizontale Elemente, was auf die Überlagerung von Punkten zurückzuführen ist. Dieses Merkmal ist im Gegensatz zu *normal vectors* unempfindlich gegenüber Rauschen und kann vertikale Elemente auch unter verrauschten Bedingungen veranschaulichen. Es ist zu beachten, dass die resultierende PCD von Brücken aus Erfassungsmethoden möglicherweise nur eine Rotation um die z -Achse aufweist. Daher kann dieses Merkmal berechnet werden, ohne dass die Ausrichtung der Brücken vorausgesetzt wird.

3D-Dichte Je nach Lage eines Punktes und seinem relativen Abstand zu anderen Punkten in einer PCD kann er unterschiedliche 3D-Dichten aufweisen. Im Falle von Brücken weisen Geländer und einige Teile des Hintergrunds, wie z. B. Geräusche, eine geringere 3-D-Dichte auf. Dieses Merkmal kann berechnet werden, indem man eine Kugel um jeden Punkt betrachtet und die Anzahl der Punkte innerhalb der Kugel zählt.

Datensatz

Die Punktwolke von sechs einfeldrigen RC-Brücken wird für das geometrische Digital Twinning verwendet. Dieser Datensatz wurde durch UAV-Photogrammetrie erfasst und mit Structure from Motion (SfM) verarbeitet. Wie in Abbildung 70 zu sehen ist, sind die Brückenkomponenten in allen

Beispielen vom gleichen Typ, aber ihre Abmessungen sind unterschiedlich. Die Rohpunktcloud der Brücken enthält x-, y- und z-Koordinaten sowie RGB-Farbcodes. Jede Stichprobe der Punktclouden besteht aus einem Brückendeck, Widerlagern, Geländern und einem Hintergrund. Daher werden diese vier Klassen für die semantische Segmentierung berücksichtigt. Zur Verringerung des Verarbeitungsaufwands wird jede Probe mit der Methode der gleichmäßigen Rasterunterteilung mit einer Rastergröße von 5 cm unterabtastet. Dieser Vorverarbeitungsschritt führt zu Punktcloudproben mit einer Anzahl von etwa ein bis zwei Millionen Punkten.




Abbildung 70: Beispielbrücken

Vorverarbeitung und Verbesserung der Daten

Zur Berechnung der Eingabemerkmale wird die PCD aller Brücken durch einheitliche Rasterabtastung in Voxel mit einer Länge von 5 cm unterteilt. Dies führt zu Punktclouden mit ein bis zwei Millionen Punkten. Alle nachbarschaftsbasierten Merkmale werden in Kreisen (Kugeln) mit einem Radius von 20 cm berechnet. Um die Auswirkungen der eingegebenen Merkmale auf das Modell auszugleichen, werden alle Merkmale im Bereich von null bis eins normalisiert. Zur Vergrößerung des Datensatzes wird die PCD von Brücken auch in den Koordinatenursprung übersetzt und um einen zufälligen Winkel um die z-Achse gedreht. Außerdem werden sie mit einer Standardabweichung von 1 mm gejittert und zufällig mit einem Wert zwischen 0,9 und 1,1 nach oben oder unten skaliert. Aufgrund der unterschiedlichen Anzahl von Punkten in jeder Klasse (Ungleichgewichtsdatensatz) werden die Klassengewichte auf der Grundlage der Anzahl der Punkte aller Trainingsmuster in jeder Klasse berechnet. Anschließend wird den Klassen mit einer geringeren Anzahl von Punkten ein höheres Gewicht zugewiesen und umgekehrt. Dies führt dazu, dass jede Klasse den gleichen Einfluss auf die Verlustfunktion des NN hat.

Deep-Learning-Modell

Als Deep-Learning-Modell, das Punkte verarbeiten kann, wird das RandLA-Net (Hu et al., 2020) verwendet. Dieses Modell kann Merkmale von großen Punktclouden verarbeiten und lernen. Es wendet Zufallsstichproben in den nachfolgenden Schichten des Netzes an, um die Anzahl der Punkte zu reduzieren. Um den Verlust von Schlüsselmerkmalen durch das Sampling zu verhindern, wird gleichzeitig ein Modul zur lokalen Merkmalsaggregation vorgeschlagen, um das rezeptive Feld für jeden Punkt schrittweise zu vergrößern. Dieses Modul enthält eine lokale räumliche

Codierung (LocSE) und einen aufmerksamen Pooling-Block, wie in Abbildung 71 dargestellt. LocSE berechnet die Nachbarpunkte eines jeden Punktes mit Hilfe von K-nearest neighbors (KNN) und sendet den relativen euklidischen Abstand des Punktes zu seinen Nachbarn an ein mehrschichtiges Perzeptron (MLP). Anschließend werden die resultierenden Merkmale mit den Eingangsmerkmalen des Punktes verkettet. In der aufmerksamen Pooling-Einheit werden diese Merkmale durch eine gewichtete Summe aggregiert. Die Gewichte (Scores) der Operation werden aus einem gemeinsamen MLP gewonnen, um die wichtigeren Merkmale hervorzuheben. Schließlich werden jeweils zwei Module zur Merkmalsaggregation übereinander gelegt, um das rezeptive Feld des Punktes zu erweitern.

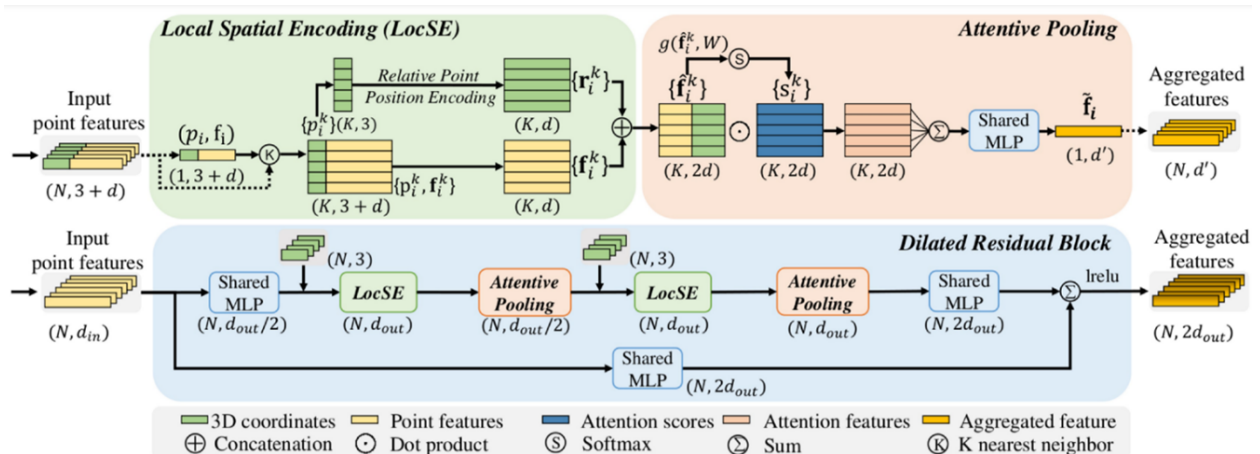


Abbildung 71: Architektur des RandLA-Net.

Hyperparameter

RandLA-Net kann durch eine Reihe von Hyperparametern konfiguriert werden. Zu diesen Parametern gehören die Anzahl der Abtastschichten und deren Verhältnis, die Anzahl der für KNN erforderlichen Nachbarn und die Dimension der Merkmale für ein aufmerksames Pooling. Außerdem wird ein anfängliches Gittersampling verwendet, das nicht notwendig ist, aber die Leistung des Modells beeinflusst. Die übrigen Parameter, wie z. B. die Stapelgröße und die Lernrate, beziehen sich hauptsächlich auf die Trainingsphase des Modells. Alle diese Parameter werden durch ein Trial-and-Error-Verfahren ermittelt, und die Werte, die zu den besten Ergebnissen führen, werden angegeben. Für den Brückendatensatz werden vier Sampling-Schichten mit einem Verhältnis von 1/4 verwendet, so dass nur 25% der Punkte in jeder Schicht beibehalten werden. Für KNN werden 16 Nachbarn berücksichtigt, und für die Verarbeitung von Merkmalen im aufmerksamen Pooling werden 8 Neuronen ausgewählt. Für das Training des Modells werden eine Stapelgröße von 3 und eine Lernrate von 0,01 verwendet.

Ergebnisse

Das RandLA-Netz mit den extrahierten Eingabemerkmale wurde 512 Epochen lang auf den von LOOCV erhaltenen Faltungen trainiert. Jeder Fold enthielt fünf Proben von Brücken für das Training und eine ungesehene Probe für den Test. Die Testergebnisse zeigten eine Gesamtgenauigkeit

(OA) von mehr als 96 % und eine mittlere Überschneidung über die Vereinigung von 89 % für die meisten Proben. Abbildung 72 zeigt die Ergebnisse des Modells nach dem Training. Wie man sehen kann, wurden die meisten Elemente in der Punktwolke der Brücken korrekt erkannt.

Nach der semantischen Segmentierung werden die Flächen der einzelnen Elemente erkannt und die Grenzkanten extrahiert. Anschließend werden die PPMs durch ein elementweises Optimierungsverfahren angepasst. Die Partikelschwarmoptimierung (PSO) mit einem Koeffizientenfaktor $c_1 = 2$ $c_2 = 2$ und 300 Iterationen wurde für alle Stichproben verwendet. Anschließend wurden die optimierten PPMs zusammengesetzt und die Parameterwerte in das Dummy-Modell der Braut importiert. Abbildung 73 zeigt die Ergebnisse der Anpassung von 3 der Brückenmuster.

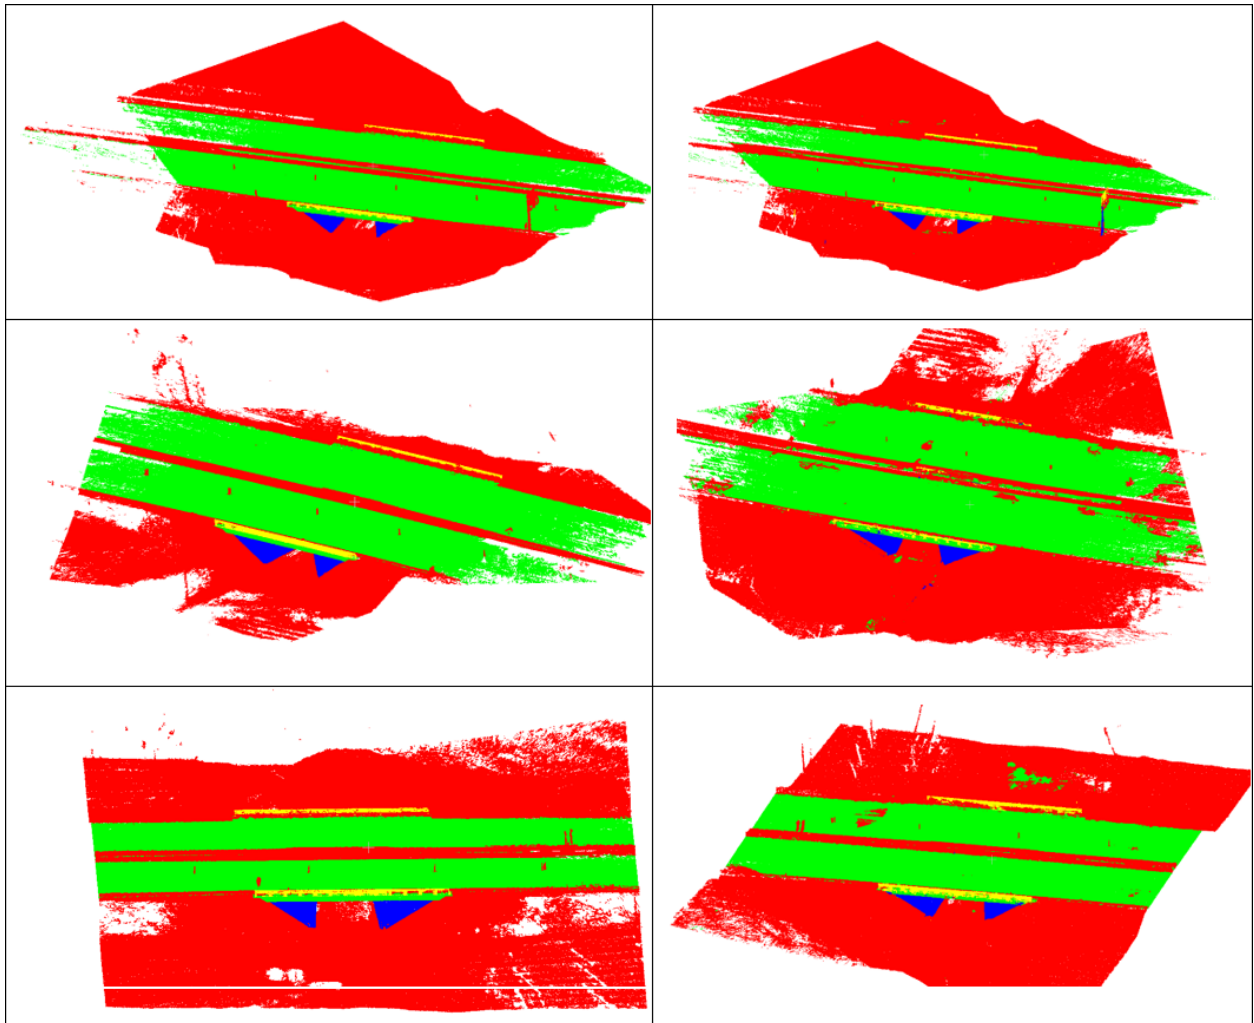


Abbildung 72: Ergebnis des trainierten Modells: (a) Ground Truth; (b) Testergebnis.

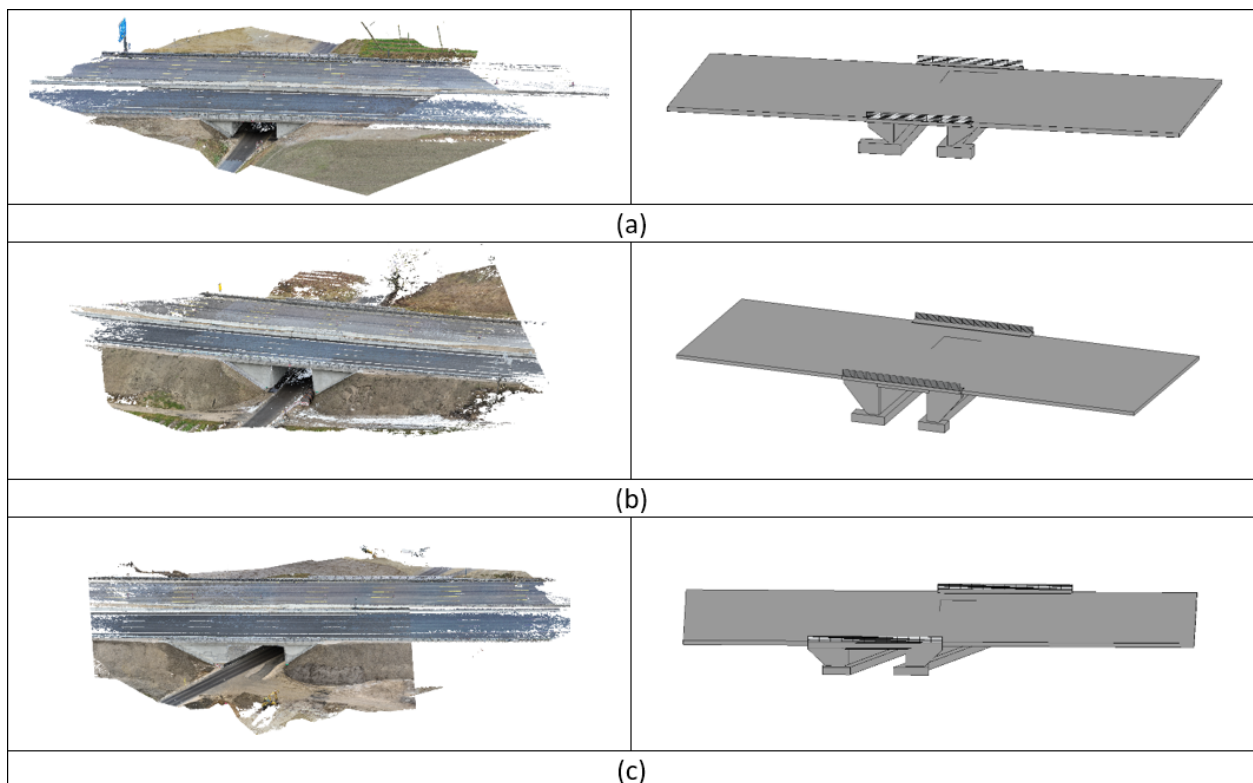


Abbildung 73: Das parametrische Modell der Punktwolke von drei Brücken.

8.3 Beschreibung und bauteilorientierte Verknüpfung der semantischen Anreicherung und Regeln durch Linked Data Verfahren

Wesentliche Informationsquelle für die semantischen Anreicherung der erstellten Geometriemodelle ist die Dokumentation über das Bauwerk und dessen Inspektionshistorie in SIB-Bauwerke. Durch die Konvertierung der darin enthaltenen Daten in einen RDF-Graph (vgl. Abschnitt 9.1) sind die Informationen einfach und strukturiert über Abfragen (SPARQL) zugänglich. Die Umwandlung der neuen ASB-ING in eine Ontologie (vgl. Abschnitt 9.1) erleichtert zudem die Verknüpfung zwischen den SIB-Bauwerke Daten und dem Geometriemodell (IFC Modell).

Basierend auf einem Mapping der ASB-ING Ontologie Klassen (Bauwerk, Teilbauwerk, Kappe, Widerlager, Fahrbahn etc.) zu den Bauteilklassen in IFC(owl) (Bridge, Abutment, Wall, Slab, etc.) kann eine automatisierte, regelbasierte Verknüpfung der Instanzdaten erfolgen. So können die Materialangaben, Einbaudaten, Bauteiltypen, usw., die in SIB-Bauwerke zu dem jeweiligen Bauteil oder Bauteilgruppen gespeichert wurden, die entsprechenden IFC-Bauteile/Objekte anreichern.

Um die automatisierte Verknüpfung der SIB-Bauwerke und IFC Daten zu ermöglichen, müssen zwei Vorbereitungen getroffen werden. Da die Ortsangaben aus SIB-Bauwerke abhängig von der Blickrichtung sind, muss das interne Koordinatensystem des IFC Modells mit dieser übereinstimmen. Basierend darauf, muss ein Referenzmodell erstellt werden, das bauwerksbezogene Ortsangaben, wie rechte/linke Seite der Brücke, Anfang/Ende des Bauwerks, x.Feld, 1.Stützenbereich abbildet.

Die Anpassung des Modells an die dokumentierte Prüf-, bzw. Bauwerksrichtung aus SIB-Bauwerke haben wir in dem prototypischen Ansatz manuell vorgenommen. Es wurde festgelegt, dass die

Hauptachse des Brückenmodells parallel zur X-Achse des Koordinatensystem liegt, und der Ursprung des Koordinatensystem in der Mitte der Brücke liegt. Negative X-Werte wurden als "Vorne/Äm Anfang der Brücke festgelegt", und negative Y-Werte "Rechte Seite". Für die Anwendung des Ansatzes auf viele Brückenmodelle kann dieser Prozess durch Transformationen zwischen der Position der Brücke im geografischem Koordinatensystem und der Ausrichtung des Brückenmodells im Modellkoordinatensystems verbessert/automatisiert werden.

Das korrekt ausgerichtete Modell wird im nächsten Schritt in Zonen aufgeteilt, welche die bauwerksbezogenen Ortsangaben darstellen (siehe Abb. Abbildung 74). Dafür werden Bounding Boxes erstellt, die bspw. die rechte/linke Seite des Modells, ein Feld, oder den Anfang des Bauwerks umfassen. Die Definitionen dieser Bereiche sind in der ASB-ING enthalten, so wird der Anfang und das Ende des Bauwerks mit den Positionen der Fahrbahnübergangen gleichgesetzt, und die Brückenfelder spannen sich zwischen den Unterbauten (Widerlagern und Stützen) auf.

Für die Zuordnung von individuellen Bauteilen aus SIB-Bauwerk zu IFC Elementen, wird die in Kapitel 6.1 beschriebene "Bauteildefinition" verwendet. Sie gibt an um welche Bauteilgruppe/Bauteiltyp es sich handelt, und wo das Bauteil eingebaut ist (bspw. "Bauteilgruppe:Überbau", "Bauteil:Kappe", Ortsangabe:Links").




Abbildung 74: Aufteilung des IFC Modells in Zonen.

Mithilfe des oben beschriebenen Mappings und dem erstellten Zonenmodell, kann dann beispielsweise nach einem Element im Modell gesucht werden, dass der Klasse `äsb:Kappe` bzw. `ifc:Beamëntspricht` und innerhalb der Zone "Link Seite" liegt. Ist das Element gefunden wird zwischen dem Bauteileintrag aus SIB-Bauwerke und dem IFC Modell ein Link (`asb:hasModelRepresentation`)

erstellt. Ist die Ortsangabe des Bauteils komplexer (siehe Abb. Abbildung 75) ("9. Balken von links") kommen zusätzlich noch Algorithmen zum Einsatz, die mithilfe des internen Modellkoordinatensystems die Position der Bauteile untereinander zuordnen kann und so bspw. den neunten Balken von links bestimmen kann.




Abbildung 75: Graphbasierte Verknüpfung von SIB-Bauwerke Daten und IFC Elementen.

Falls das Bauteil beschädigt ist, kann die Ortsangabe des verbundenen Schadens (bspw. "Vorne", "Oberseite", "Rechts") (gespeichert als Area of Interest Objekt (s. Abschnitt 6.1)), dazu genutzt werden, den beschädigten Bereich des Bauteils zu identifizieren und darzustellen. Als Vorbereitung wurden dafür die verschiedenen Ortsangaben analysiert und den drei Achsen zugeordnet (rechts/links = Y, oben/unten = z, hinten/vorne = x). Eine Bounding Box, die das Bauteil umschließt, wird dann entlang der entsprechenden Achsen in jeweils drei Bereiche eingeteilt (s. Abb. 76). Um den Schadensbereich eines Bauteils zu erstellen, werden dann die entsprechenden Bounding Boxen der Ortsangaben (bspw. Vorne, Oben, Rechts) miteinander verschnitten (s. Abb. Abbildung 77). Die resultierende Schnittmenge stellt den geschädigten Bereich des Bauteils da und wird als separate Bounding Box, bzw. als IFCPProxyElement, gespeichert.




Abbildung 76: Aufteilung eines Bauteils in drei Bereiche entlang der x,y,z -Achsen

Um die Verknüpfungen zwischen dem SIB-Bauwerke Daten und dem IFC Modell zu erstellen, wird das IFC Modell der Brücke, und das IFC Modell der Schadensrepräsentationen (Bounding Boxes) mittels des "IFCtoLBD Konverters" BONDUEL et al., 2018 in RDF Graphen umgewandelt. Wie oben beschrieben kann dann das SIB-Bauwerke Bauteil mit dem entsprechenden IFC Bauteil, und auch das AreaOfInterestObjekt mit der entsprechenden Bounding Box via




Abbildung 77: Aufteilung eines Bauteils in Zonen zur Bestimmung des Schadenbereichs (finale Ergebnis in Orange).

äsb:hasModelRepresentation"verbunden werden. Alle originalen und konvertierten Daten werden dann für die strukturierte Speicherung in einem ICDD Container abgelegt (s.AP .9.1). Die Skriptdateien für die automatische Umsetzung des Lokalisierungsprozess sind über GitHub zugänglich <https://github.com/AnneGoebels/DamageLocation>.

Abbildung 78 zeigt wie im entwickelten prototypischen Viewer (<https://design-computation-rwth.github.io/LinkedDataViewerPublic/>), die erstellten Verknüpfungen und Schadensrepräsentationen zwischen Inspektionsdaten und Modell praktisch genutzt werden können um eine modellbasierten, intuitiven Zugang zu den Daten zu ermöglichen, der die räumlichen, zeitlichen und semantischen Zusammenhänge visualisiert.




Abbildung 78: Zugang der Bauteilinformationen aus SIB-Bauwerke über das IFC Modell / Anzeige eines Schadensbereichs (rot) im Modell.

8.4 Übertragung in die Praxis

Zu Beginn des Projektes wurden in Projektgesprächen wünschenswerte Veränderungen für den Betrieb und die Instandhaltung baulicher Infrastruktur aus Sicht der Praxis ermittelt. Anhand der daraus resultierten Liste wurden die Projektergebnisse kritisch diskutiert. Aus dieser Diskussion hat sich ergeben, dass vor allem die Weiterverarbeitbarkeit von Bauwerksinformationen als Planungsgrundlage verbessert werden kann sowie eine leichtere Verortung von Schäden ermöglicht wird. Ferner ermöglichen die Projektergebnisse eine Verschlankung des Aufnahmeprozesses von Bauwerken und tragen zu einer Vermeidung analoger Informationsaufnahme vor Ort am Bauwerk bei. Eine kollaborative Speicherung und Bearbeitung von Bauwerksdaten birgt darüber hinaus noch weiteres Potential, was im Zuge dieses Projektes noch nicht vollständig ausgeschöpft wurde. Die Projektergebnisse können somit Wegbereiter sein, für eine Abfrage von Informationen zum Bauwerk direkt vor Ort als grundlegende Unterstützung zukünftiger Bauwerksprüfungen.

AP 9: Infrastruktur semantisch reicher Digitaler Zwillinge

9.1 Umsetzung von Linked Data Ansätzen zur Verknüpfung heterogener Datenbestände

Da der digitale Zwilling Zugriff auf alle vorhandenen Informationen aus unterschiedlichen Datenquellen und in unterschiedlichen Formaten benötigt, ist eine geeignete Form der Speicherung und Verknüpfung dieser Informationen notwendig. Ein „Information Container for Linked Document Delivery“ (ICDD) *ICDD, 2020* ermöglicht es durch Einsatz von Linked Data Technologien, ebenjene heterogenen Datensätze verknüpft und strukturiert zu speichern und bereitzustellen (vgl. Abschnitt 3.1). Alle notwendigen Dateien, Dokumente und Modelle sind in dem Container gespeichert und können untereinander verlinkt werden. Besonders hervorzuheben ist hier, dass auch Fragmente von Dokumenten verknüpft werden können (beispielsweise Plan -oder Fotoausschnitte, einzelne Modellobjekte (Bauteile) oder Informationsobjekte). Dies ermöglicht ein zielgerichtetes Bearbeiten, Abfragen und Analysieren von Informationen auf Bauteilebene.

Aktuell werden die Bauwerks- und Inspektionsdaten von Infrastrukturbauwerken in Deutschland in dem Systemprogramm SIB-Bauwerke auf Grundlage der ASB-ING 2013 gespeichert und verwaltet (vgl. Abschnitt 2.2). Das relationale Datenbankprogramm speichert die Informationen (Schäden, Maßnahmeempfehlungen, Baustoffe, Verwaltungsdaten, etc.) im Bezug zum jeweiligen Teilbauwerk ab. In manchen Fällen erfolgt auch eine Referenzierung einer Bauteilgruppe oder Bauteilart. Die Teilbauwerke sind wiederum mit dem Gesamtbauwerk verbunden. In der gegenwärtigen Version von SIB-Bauwerke ist es allerdings nicht möglich auf Instanzobjektebene Informationen zu verbinden (beispielweise einen Schaden direkt mit dem betroffenen Bauteil zu verknüpfen), da die Bauteile nicht als individuelles Objekt im Datensatz vorhanden sind. Schäden werden lediglich Bauteilgruppen- und arten zugewiesen und mit einer textlichen Ortsangabe versehen (Bsp. „3. Bauteil von rechts“).

In der nächsten Version der ASB-ING, welche noch unveröffentlicht ist, wird dieses Defizit behoben, und ein objektorientiertes Datenmodell eingeführt. Dieses ermöglicht es, dass alle Bauteile und andere Informationsobjekte individuelle Datenobjekte sind, welche direkt miteinander verbunden werden können (vgl. Abschnitt 2.2). Des Weiteren verbindet das neue UML-Modell durch Generalisationen, Assoziationen oder Aggregationen auch die Klassen untereinander, um logische und bauwerksstrukturbezogene Beziehungen und Regeln abzubilden.

Die Klassen des UML Modells sind die Dokumentationsbereiche der ASB-ING (Schäden, Bauteile, Maßnahmen, Baustoffe, etc.). Jede Klasse hat definierte Attribute (ID, Bearbeiter, Datum etc., und klassenspezifische Eigenschaften) welche entweder mit Freitextwerten oder vordefinierten Schlüsseln befüllt werden können. Die einzelnen Schlüssel werden je „Thema“ in Schlüssel Tabellen-Klassen gespeichert (bspw. „Schlüssel-tabelle: Art Unterbau“). Für die Freitextwerte sind vordefinierten Datentypenklassen zugeordnet, welche ebenfalls im UML-Modell enthalten sind (bspw. „String“, „Laenge“, „Datum“), sodass die Werte korrekt interpretiert werden können.

Wir haben vom Landesamt für Straßenbau und Verkehr Mecklenburg-Vorpommern ein vorläufiges UML-Modell dieser Version bekommen und dieses in eine Ontologie umgewandelt („ASB-ING

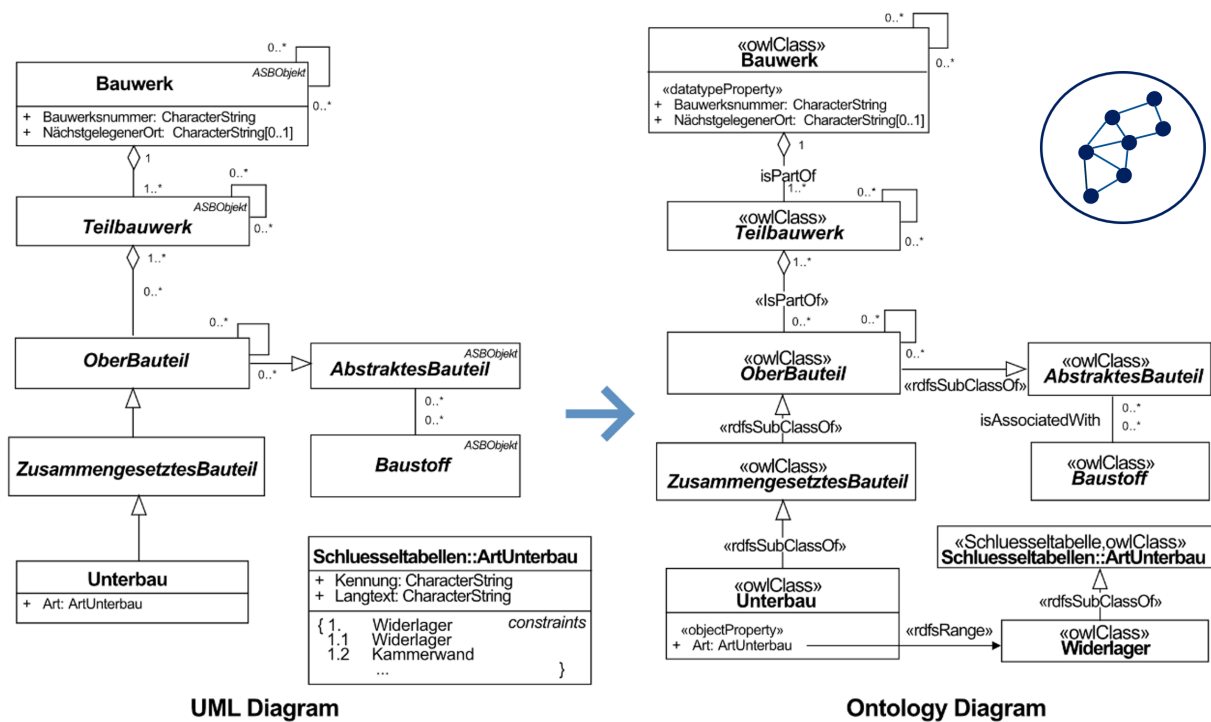


Abbildung 79: Konvertierung des neuen ASB-ING UML Modells in die ASB-ING Ontologie.

Ontology“, veröffentlicht unter : <https://w3id.org/asbingowl/core#>) GÖBELS und BEETZ, 2021. Die Ontologie ist direkt vom UML-Modell abgeleitet und enthält somit alle Klassen-, Attribut-, und Datentypdefinitionen des originalen ASB-ING UML-Modells, ermöglicht zusätzlich jedoch die Abbildung der Bauwerks- und Inspektionsdaten als Linked-Data-Modell. Wie in Abbildung 79 zu dargestellt, ist die Struktur des UML-Modells und der Ontologie sehr ähnlich. Die Klassen sind nun als Web-Ontology-Language (OWL) Klassen definiert, die Attribute sind sogenannte „ObjectProperties“, sofern sie sich auf andere Klassen/Objekte beziehen, oder „DatatypeProperties“, wenn Freitext-/numerische Angaben als Wert angegeben werden kann. Die o.g. Klassenbeziehungen sind als *asb:isPartOf*, *asb:isAssociatedWith* und *rdfs:subClassOf* umgesetzt.

Eine Änderung gegenüber der UML-Modells ist der Umgang mit den Schlüsseltabellenklassen. Wir haben uns dazu entschlossen, jedes einzelne Schlüssel-Wert-Paar aus den Tabellenklassen in eine Ontologiekategorie zu übersetzen. Somit ist der Schlüssel unkompliziert im Linked Data Modell zu nutzen und zu interpretieren. Da die bestehenden SIB-BW Daten vorrangig Werte aus den Schlüsseltabellen der ASB-ING 2013 verwendet, haben wir auch die einzelnen Schlüssel-Wert-Paare der „alten“ Schlüsseltabellen jeweils in Ontologieklassen umgewandelt, um die darin gespeicherten Werte auch im Linked Data Graph nutzen zu können (s. Abbildung 82).

Um die vorhandenen SIB-Bauwerke Daten mithilfe dieser Ontologie abbilden zu können, muss jedoch zuerst ein Mapping der ASB-ING Version von 2013 (mit welcher SIB-Bauwerke aktuell noch arbeitet) und der neuen Version durchgeführt werden. Wir haben die Mappingtabellen freundlicherweise vom Regierungspräsidium Tübingen bereitgestellt bekommen, welche das offizielle Migrationsprojekt leitet.

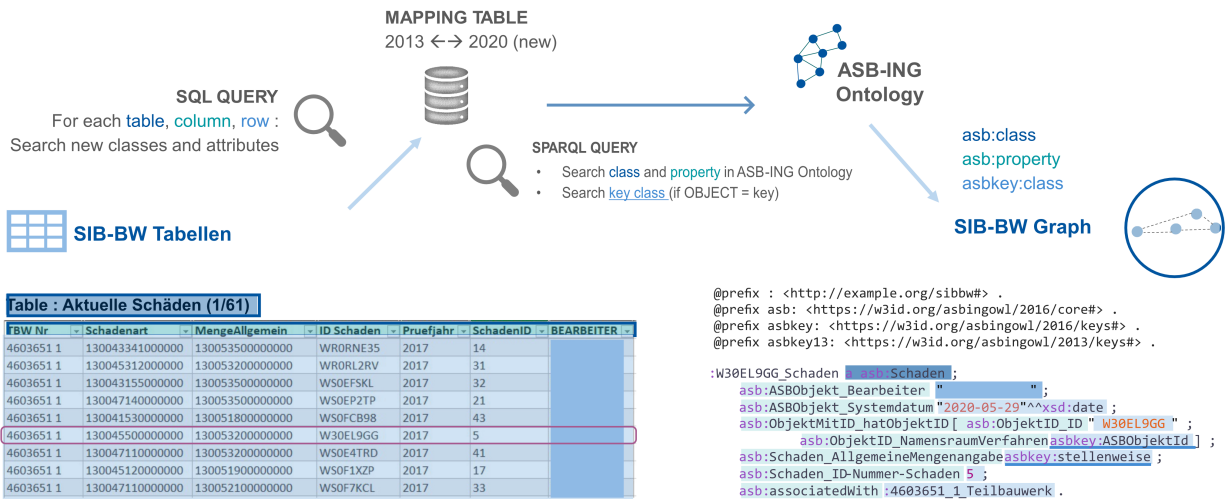


Abbildung 80: Detailprozess der Konvertierung der SIB-Bauwerke Daten in ein Linked Data Modell.

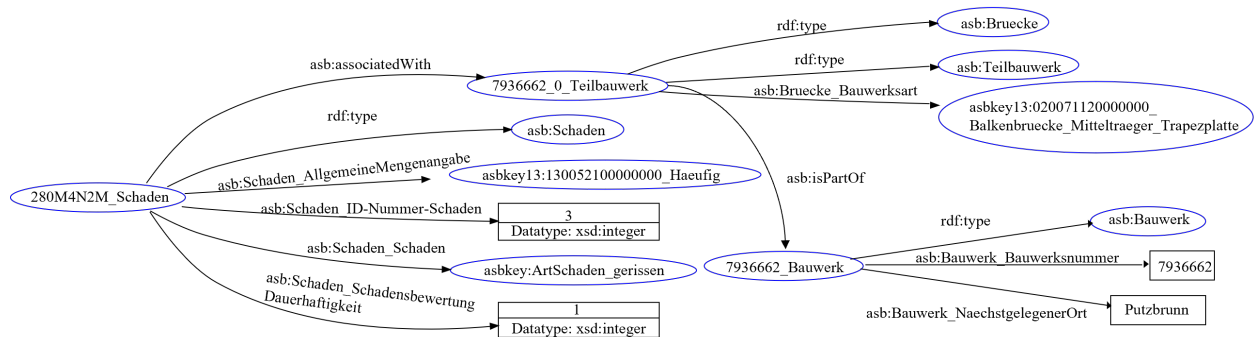


Abbildung 81: Visualisierung eines Bauwerksgraphen (Ausschnitt).

Mithilfe der Ontologie und der Mappingtabellen kann nun ein Konvertierungsprozess stattfinden, der die exportierten Datenbanktabellen aus SIB-Bauwerke in einen Linked Data Graph im Resource Description Format (RDF) umwandelt (s. Abbildung 80 GÖBELS, 2021). Die Themen/Tabellen der SIB-BW Datenbank wurde als OWL Klassen übersetzt und die Spalten als OWL Properties. Jede Reihe stellt somit eine Datenobjekt (bspw. ein Schaden oder ein Bauteil) dar, das als Instanzobjekt des RDF Graphen abgebildet wird, und über die Properties mit den entsprechenden Werten angereichert wird (s. Abb. Abbildung 81).

In diesem Graph, der die gesamten konvertierten Daten eines Bauwerks aus SIB-Bauwerke enthält, sind nun alle Informationen als individuelle Objekte vorhanden und zudem im Linked Data Format




Abbildung 82: Konvertierung der Schlüsseltabellen der ASB-ING 2013 in OWL Klassen.

abgebildet, welches ein unkompliziertes Verknüpfen dieser Daten zu Informationen und Objekten aus anderen Datensätzen (bspw. IFC Modell, 2D Dokumenten, Fotos, Sensoren etc.) ermöglicht (s. Abbildung 83). Zeitgleich ist der Graph kompatibel zu den Definitionen der ASB-ING und stellt keine komplett neue Struktur dar, sondern eine erweiterte Repräsentation der vorhandenen SIB-BW Daten und der unterliegenden ASB-ING-Struktur.

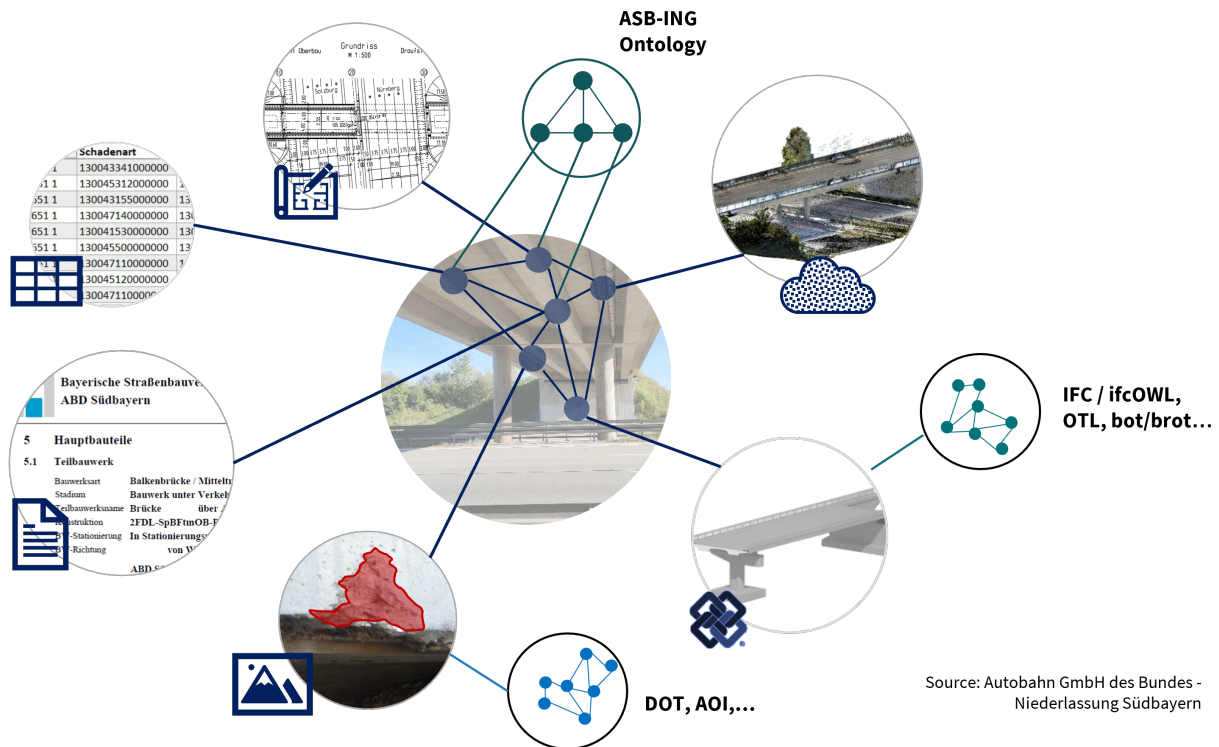


Abbildung 83: Verknüpfung aller bauwerks- und inspektionsrelevanter Daten in einem Linked Data Modell.

Dieser Prozess wurde mit 26 SIB-Bauwerke Datensätzen getestet, die wir von dem Projektpartner *ZPP-Ingenieure* und der *Autobahn GmbH des Bundes - Niederlassung Südbayern* zur Verfügung gestellt bekommen haben. Bis auf wenige Daten, zu welchen die entsprechenden Schlüssel Tabellen noch nicht konvertiert sind (bspw. interne Verwaltungsnummern), wurden die gesamten Informationen aus SIB-Bauwerke erfolgreich in eine Linked Data Version umgewandelt. Im nächsten Schritt erfolgt die strukturierte Versionierung der Daten, da auch die Archivdaten von Schäden, Maßnahmen und Prüfungen übernommen wurden. Dadurch ist es möglich, auch die Daten aller vorangegangener Prüfungen für Analysen und Vorhersagen zu nutzen.

Die konvertierten SIB-Bauwerke Daten werden dann, für die in Kapitel Abschnitt 6.1 und Abschnitt 8.4 beschriebene, objekt-orientierte Verknüpfung von Schadens- und Bauteildaten zum IFC Modell, sowie zu Foto-und Plandaten verwendet.

Schließlich werden alle Daten und Verknüpfungen inklusive ihrer Metadaten (Ersteller, Datum, Format, etc.) im ICDD Container abgelegt (s. Abb. Abbildung 84). Dort werden auch die Dokumente, welche mit in SIB-Bauwerke gespeichert werden (Pläne, Schadensfotos, Schadenszeichnungen) abgelegt und mit den einzelnen Objekten im Bauwerksgraph und dem IFC Modell verknüpft (bspw. Schadensfoto zu Schadensobjekt, IFC Bauteil zum Planausschnitt (vgl. Abschnitt 7.3)).

Der ICDD Container kann somit als Basis für vollumfängliche Analysen und Verarbeitungen als auch zur Speicherung / Archivierung der Daten genutzt werden. Innerhalb dieses Projektes, wurde auf Basis der verknüpften Informationen im ICDD Container, ein prototypischer Viewer erstellt, welche die enthaltenen Daten visualisiert (s. AP 10.3).

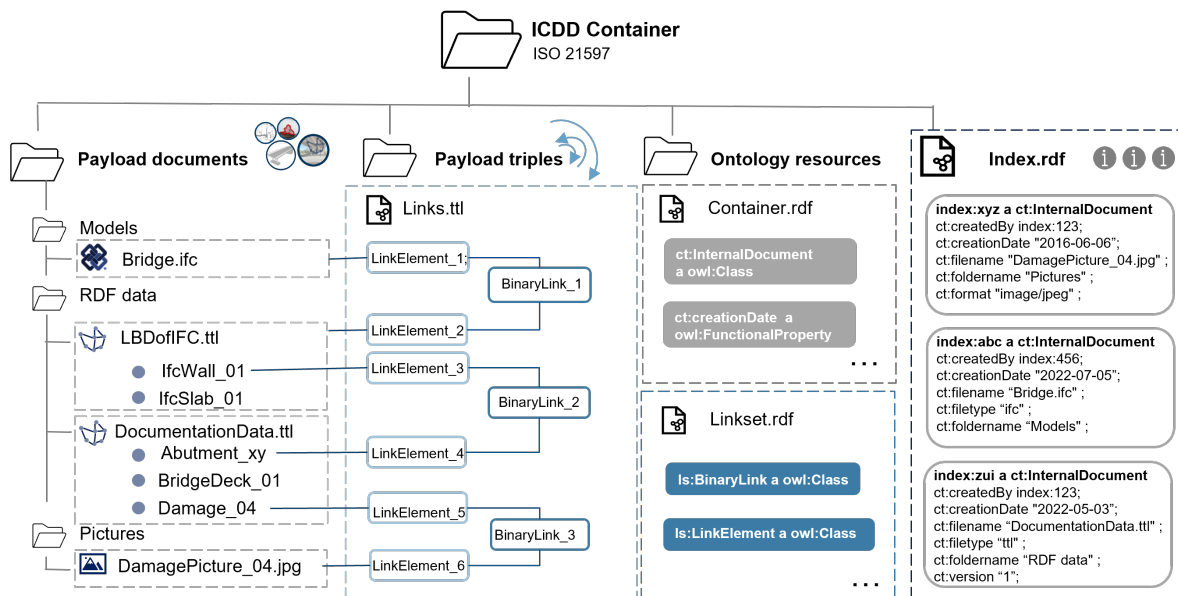


Abbildung 84: Verknüpfte Speicherung heterogener Datensets für die Brückeninstandhaltung.

9.2 Entwicklung einer App für die Vor-Ort-Erfassung

Zur Sicherstellung eines durchgängigen Workflows der Datenaufnahme und Datenverarbeitung zur Erstellung digitaler Zwillinge wurde eine App entwickelt, mit deren Hilfe Brückenschäden vor Ort aufgenommen und dokumentiert werden können. Die App wurde auf dem Betriebssystem Android entwickelt und ist für die Nutzung auf einem mobilen Endgerät vorgesehen. Die durchgängig digitale Erfassung aller Daten ersetzt die häufig handschriftlichen Notizen, welche dann im Nachgang in die Anwendung SIB Bauwerke eingepflegt wurden.

So werden bspw. handschriftliche Notizen ersetzt durch Auswahllisten auf Basis der ASB ING direkt in der App. Diese können bei Bedarf um Notizen in Freitextform ergänzt werden. Dokumentierte Schäden werden dann aus der App heraus fotografiert und sind somit automatisiert mit dem entsprechenden Schaden verknüpft. Ferner kann direkt vor Ort eine Schadensbewertung vorgenommen werden. Die Ergebnisse einer Prüfung können dann bspw. per Mail in Form einer Datenbank im csv-Format verteilt werden. Getrennt von der App wandelt ein Konverter diese Datei in eine von SIB-Bauwerke verwertbare Importdatei um.

Durch die Nutzung offener Datenformate können alle im Projekt TwinGen erarbeiteten Workflows verlustfrei zur Inspektion von Bauwerken genutzt werden

Aktuelles Bauwerk: A221
 Schadensnummer: 1
 Bauwerksart: Plattenbrücke***

Hauptbauteil:

alternativ Hauptbauteil:

Konstruktionsteil:

Schaden:

Menge allgemein:

Menge mit Dimensionen:

Ortsangabe längs:

Ortsangabe quer:

Ortsangabe hoch:

weitere Anmerkungen:

Schadensbild:



Abbildung 85: Aufnahmemaske zur digitalen Aufnahme und Verortung von Bauwerksschäden nach den Vorgaben DIN 1076 (Quelle: ZPP Ingenieure AG).

Aktuelles Bauwerk: A221

Schadensnummer 1

S	V	D
0	0	0
1	1	1
2	2	2
3	3	3
4	4	4

Abbrechen

Speichern

Abbildung 86: Schadensbewertung nach DIN 1076 (Quelle: ZPP Ingenieure AG).

AP 10: Validierung

Anhand von ausgewählten Bauwerken aus dem Straßen- und Wasserstraßenbau wurden die entwickelten Verfahren evaluiert. Die Bauwerke wurden mit den oben beschriebenen Verfahren erfasst und die entwickelten Technologien angewandt, um hochwertige digitale Zwillinge zu erzeugen. Wesentlich ist hierfür die Definition von Metriken, um die Qualität eines digitalen Zwillings in Abweichung vom realen Zwillings zu definieren. Als Referenzobjekt für die Validierung wurde die in Abschnitt 2.2 beschriebene Brücke an der A99 nahe München gewählt. Abbildung 87 zeigt den Workflow in dem die verschiedenen Arbeiten und Ergebnisse der einzelnen Projektpartner zu einem Prozess zusammengesetzt und auf die erfassten Daten des Referenzobjekts angewendet wurden.

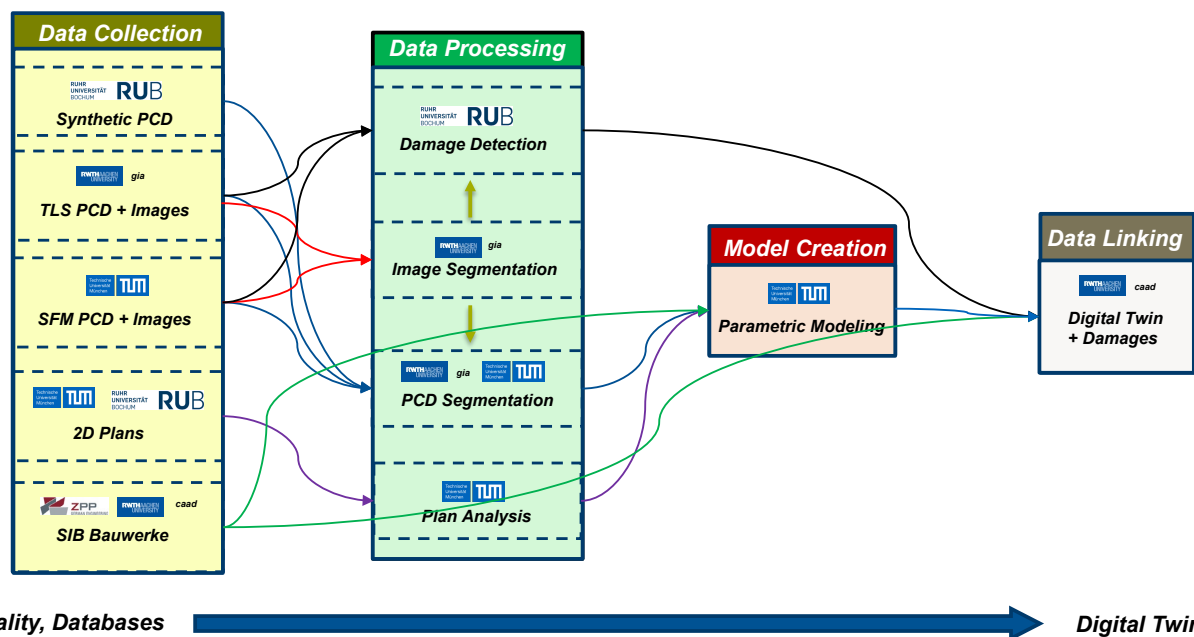


Abbildung 87: Workflow und Interaktionen der einzelnen Arbeitspakete von Datenaufnahme bis hin zum Digital Twin.

10.1 Schadenerkennung

Zur Validierung des Schadenssegmentierungsmodells wurden Schadensbilder von der Brücke St209/A99 aus SIB-Bauwerke genutzt. Die Bilder wurden von der Autobahn GmbH Südbayern zur Verfügung gestellt. In der Abbildung 88 werden die Segmentierungsergebnisse auf den Schadensbildern gezeigt. Es wird deutlich, dass das KI-Modell auch bei Bildern aus anderer Herkunft und bei vergleichsweise schlechter Qualität (hier: JPEG-Komprimierung und kleine Auflösung) gute Ergebnisse liefert. So werden alle Abplatzungsobjekte nahezu vollständig erfasst. In der Teilabbildung oben links wird ein sehr feiner Riss, der farblich unscheinbar ist, teilweise erkannt. Zudem werden Quer- und Längsrisse wie in Abbildung 88 auf der Fahrbahn unten links zu sehen ist, fast vollständig durch das KI-Modell erfasst. Das KI-Modell scheint, unabhängig des Materials, die Schäden zu erkennen, obwohl es ausschließlich auf Betonbildern trainiert wurde. Es wird deutlich, dass die Anwendung des KI-Modells auf Asphalt Schäden, wie Risse und Schlaglöcher, erweitert

werden könnte. Mit einer Vergrößerung des Datensatzes und einer Erweiterung des Datensatzes auf Asphalt Schäden könnte das KI-Modell zuverlässigere Ergebnisse liefern. Eine Validierung des Schadenssegmentierungsmodells auf Punktwolkenbilder der Brücke St209/A99 konnte nicht erfolgen, weil die Punktwolke zu der Brücke nicht die nötige Auflösung aufweist, um die kleinen Schadensobjekte aufzunehmen. Für die Schadenerfassung in Punktwolkenbildern wird eine hohe Auflösung benötigt, die unter anderem durch eine erhöhte Scananzahl an deutlich mehr Stellen als üblich, erreicht werden kann.



Abbildung 88: Segmentierungsergebnisse auf Beispielbildern von Schäden der Demonstratorbrücke St209/A99. Die Beispielbilder stammen aus der SIB-Bauwerke Datenbank.

10.2 Cross Domain Matching

Der entwickelte Cross Domain Matching Ansatz besteht aus mehreren Stufen, mit der Vorsegmentierung und Feinsegmentierung als wesentliche Schritte. Die Validierung wird daher ebenfalls in zwei Schritten durchgeführt.

Für die Vorsegmentierung wurden die Objektmasken aus der DL-Bildklassifizierung zur Validierung mit den Referenzmasken verglichen. Als Objektkategorien für die Klassifizierung wurden die drei Klassen Widerlager, Oberbau und Geländer ausgewählt und jeweils farblich unterschiedlich hervorgehoben. Eine Übereinstimmung der Masken mit dem Bauwerk ist grundsätzlich gut erkennbar, insbesondere werden Hintergrundobjekte wie Autos und Vegetation nur äußerst selten fälschlicherweise als Bauteile klassifiziert. Eine pixel-genaue Abgrenzung verschiedener Bauteile ist nicht immer möglich, da Kameraperspektive, begrenzte Bildauflösung und leichte Überlappungen der Masken eine eindeutige Bauteilzuordnung erschweren.

Zur Validierung der Feinsegmentierung wurden die verfeinerte Segmentierungsergebnisse mit der händisch semantisch segmentierten Referenzpunktwolke verglichen. Der automatische Filter zum Entfernen von Ausreißern wurde hierbei als Nachbearbeitungsschritt angewendet. Visuell ist




Abbildung 89: Vergleich generierter Klassifizierungsmasken mit Referenz. Obere Reihe: Aufnahmen der Brücke. Mittlere Reihe: Generierte Klassifizierungsmasken. Untere Reihe: Referenzmasken.

erkennbar, dass nahezu keine Hintergrundobjekte markiert wurden. Fehlende Segmente befinden sich überwiegend auf der Fahrbahn des Oberbaus, da diese visuell nicht von der Fahrbahn anderer Straßenkörper zu unterscheiden ist. Beide Effekte sind in AS 3.1 in Abbildung 25 sichtbar. Die Klassifizierung von Brückenwiderlager und Oberbau gelingt nahezu vollständig und fehlerfrei, das Brückengeländer wird dagegen nicht vollständig erkannt, was die gemittelte Fehlerrate erhöht und sich negativ auf Recall und IOU auswirkt (s. Abbildung 90). Insgesamt ist die Präzision des Verfahrens annähernd 100%, sodass keine Hintergrundobjekte als Bauteile fehlklassifiziert werden. Die gemittelte Genauigkeit (accuracy) des Verfahrens ist ebenfalls sehr hoch und unterstreicht somit die hohe Güte der Klassifizierung.

Abschließend lässt sich feststellen, dass die Methodik zur Kombination bildbasierter Klassifizierungsverfahren mit Vorwissen-basierter Feinsegmentierung Brückenbauteile in 3D-Punktwolken mit hoher Zuverlässigkeit erkennt und von Hintergrundobjekten unterscheiden kann. Eine noch bessere (zuverlässiger und robuster) Unterscheidung zwischen verschiedenen Bauteilen, könnte durch ergänzende Verfeinerungen des Verfahrens insbesondere im Feinsegmentierungsschritt erreicht werden, was als Aufgabenstellung für folgende bzw. zukünftige Forschungsarbeiten identifiziert wurde. Neben dem Einbinden zusätzlicher Trainingsdaten erscheint auch eine vergleichende Untersuchung verschiedener Netzwerkarchitekturen interessant, um die Ergebnisse der Bildklassifizierung und damit der Vorsegmentierung weiter zu verbessern. Weitere Verfahren zur geometrischen Nachbearbeitung zeigen ebenfalls großes Potenzial, da viele Brückenbauteile aus planaren Abschnitten

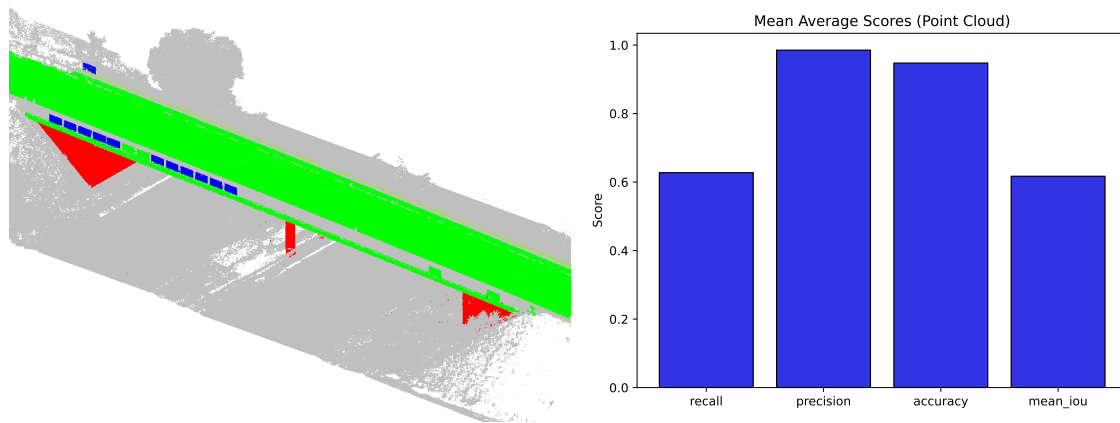


Abbildung 90: Ergebnis der projizierten und automatisch nachbearbeiteten Brückensegmentierung (links) und statistische Qualitätsmaße (rechts).

bestehen, sodass eine geometrische Vorsegmentierung und anschließendes Labeling mithilfe der bildbasierten Klassifizierung einen untersuchenswerten alternativen Ansatz darstellt.

10.3 Linked Data Viewer

Als Validierung der vorherigen Arbeitsschritte in Bezug auf die Verarbeitung von vorhandenen Brückendaten, und die bauteilorientierte Verknüpfung der verschiedenen Projektergebnisse (s. AS 6.1, 8.4, 9.1) wurde ein prototypischer „Linked Data Viewer“ entwickelt. Der Viewer zeigt die Daten der Brücke St209/A99 von der die SIB-Bauwerke Daten von der Autobahn GmbH Südbayern zur Verfügung gestellt worden sind und im Rahmen des Projekts ein Laserscan angefertigt wurde. Aufgrund der parallelen Bearbeitung der Arbeitspakete, wurde das Brückenmodell für diesen Viewer, auf Basis der Punktwolke, manuell modelliert.

Der Viewer ist unter <https://design-computation-rwth.github.io/LinkedDataViewerPublic/> zu erreichen. Zentral ist das Brückenmodell zu sehen, welches mit den Schadensinformationen aus SIB-Bauwerke überlagert wurde (s. Abb. 91). Zu jedem Schaden wird, falls vorhanden, das Schadensbild, die Schadensart, und die textliche Beschreibung des geschädigten Bauteils angezeigt. Durch das Auswählen eines Schadens oder eines Modellelementes werden in einem Infowindow, die zugehörigen, im ICDD Container verknüpften, Informationen aus SIB-Bauwerke angezeigt. Für jeden Begriff der in der ASB-ING (Ontologie) definiert ist, können die entsprechenden Metadaten abgerufen werden (bspw. Kennung (Schlüsselnummer), übergeordnete Hierarchieelemente, Kommentare etc.). Für jeden Schaden (falls vorhanden) kann ein (vergrößertes) Schadensbild und der entsprechende Schadensbereich im Modell angezeigt werden. Zudem kann zwischen der vorherigen, bzw. nächsten Version (Inspektionsjahr) des Schadens gewechselt werden.

Der zeitliche Verlauf der Inspektionsdaten kann zudem mit dem Schieberegler am unteren Rand visualisiert werden. Der Regler kann auf die verschiedenen Inspektionsjahre eingestellt werden und zeigt die entsprechenden Schäden aus diesem Jahr im Modell an. So kann visuell nachvollzogen werden, wann welcher Schaden aufgetreten, bzw. repariert worden ist. In der unteren Menüleiste kann zudem auch eine „Analyse“- Ansicht eingeschaltet werden, welcher die Schäden entsprechend ihres Schädigungsgrades (S/V/D) in rot / gelb / grün einfärbt. Diese Ansicht soll lediglich

das Potenzial der visuellen Aufarbeitung deutlich machen und basiert nicht auf dem offiziellen Algorithmus zur Schadensbewertung nach SIB-Bauwerke/ASB-ING.

Auf der linken Seite gibt es drei Navigationsbäume, mit dem die Modellelemente ausgehend von der IFC-Struktur oder SIB-Bauwerke-Struktur (Bauwerk, Teilbauwerk, usw.) ausgewählt werden können. In dem dritten Reiter sind die Schäden nach Prüfjahren und Schaden-ID sortiert und können von dort direkt ausgewählt werden.

Der Viewer zeigt deutlich den Mehrwert der geometrischen Anreicherung der vormalig rein textlichen Daten aus SIB-Bauwerke. Die Daten sind intuitiver zugänglich und der Bezug zur Brücke ist direkt visualisiert. Somit kann eine nachvollziehbare Kommunikation über Schäden, auch mithilfe des Modells stattfinden, ohne dass man vor Ort sein muss. Der Mehrwert des Viewers wurde auch von der Autobahn GmbH Südbayern, sowie Anwendern von SIB-Bauwerke bestätigt, welchen er zuvor zur Freigabe der Daten vorgestellt wurde.

Bei der Arbeit mit dem Viewer, zeigen sich allerdings auch die Schwächen des Verortungsprozesses. So stimmen manche Schadensorte am Modell nicht mit ihrer textlichen Beschreibung über ein (bspw. "Widerlagerwand, Rechts" wurde als rechte Flügelwand des Widerlagers interpretiert, anstatt als rechte Seite der Frontwand). Hier muss der Verortungsprozess nachjustiert werden. Allgemein konnte festgestellt werden, dass die Durchführung der Verortung von Schäden von der Qualität der vorhandenen Dokumentation abhängt. So sind textliche Beschreibungen, die auch für (nachfolgende) Inspektoren schwer zu verstehen sind (aufgrund fehlender oder vager Beschreibung), für die computergestützte Verarbeitung unbrauchbar. Eine Verbesserung des gesamten Verortungsprozesses und der Interpretation der textlichen Begriffe, könnte zukünftig durch die Anwendung des Ansatzes auf eine größere Menge an Datensätzen erzielt werden.



Abbildung 91: Screenshot des Linked Data Viewers

10.4 Bewertung hinsichtlich praxisrelevanter Kriterien

In einem gemeinsamen Workshop des Projektteams mit der Abteilung Bauwerksinspektion/Brückenprüfung ist eine Validierung der Projektergebnisse vorgenommen worden. Dabei wurde eine potenzielle Verbesserung des Aufwand-Nutzen-Verhältnisses zwischen der Ist-Situation und einer zukünftigen Situation unter Nutzung der Projektergebnisse bewertet. Dazu wurden sechs praxisrelevante Kriterien ermittelt und diese den Projektergebnissen gegenübergestellt. Die Ergebnisse der Validierung sind folgender Matrix zu entnehmen.

Projektergebnisse / Kriterien	Punktwolken-Segmentierung	Generierung von Volumenmodellen durch parametrisches Model-to-Cloud Fitting	Extraktion von Informationen aus technischen Zeichnungen	Detektion von Schäden	Informationsstruktur/Ontologie
Verschlanung des Aufnahmeprozesses von Bauwerksdaten	↗	↑	↑	↗	→
Vermeidung von analoger Informationsaufnahme vor Ort	↑	→	↑	↑	→
Leichtere Verortung von Schäden	→	→	→	↑	↗
Direktes Abfragen von Informationen zu Bauwerken vor Ort	→	→	→	→	↑
Kollaborative Speicherung und Bearbeitung von Bauwerksdaten	→	→	→	→	↑
Weiterverarbeitbarkeit von Bauwerksinformationen als Planungsgrundlagen	→	↑	↗	↗	↑

Abbildung 92: Qualitative Bewertung des Verbesserungspotentials durch die Anwendung der einzelnen Projektergebnisse für praxisrelevante Kriterien

Veröffentlichungen im Rahmen des Forschungsprojekts

CELIK, F., FALTIN, B., & KÖNIG, M. (2022). Improving 2D construction plans with cycle-consistent generative adversarial networks. *Proc. of ASCE International Conference on Computing in Civil Engineering 2021*. <https://doi.org/10.1061/9780784483893.007>

GÖBELS, A. (2021). Conversion of infrastructure inspection data into Linked Data models. *Proceedings of 32. Forum Bauinformatik*.

GÖBELS, A., & BEETZ, J. (2021). Conversion of legacy domain models into ontologies for infrastructure maintenance. *Proceedings of the 9th Linked Data in Architecture and Construction Workshop (LDAC)*. https://linkedbuildingdata.net/ldac2021/files/papers/CIB_W78_2021_paper_176.pdf

GÖBELS, A. (2022). Enabling object-based documentation of existing bridge inspection data using Linked Data. *Proceedings of 33. Forum Bauinformatik*. <https://mediatum.ub.tum.de/doc/1688385/>

GÖBELS, A., RIVADENEYRA, F., & BEETZ, J. (2023). A text-to-model approach to transfer natural language-based location descriptions in three-dimensional model contexts. *Submitted*.

MAFIPOUR, M. S., VILGERTSHOFER, S., & BORRMANN, A. (2021). Deriving Digital Twin Models of Existing Bridges from Point Cloud Data Using Parametric Models and Metaheuristic Algorithms. *Proceedings of EG-ICE 2021 Workshop on Intelligent Computing in Engineering*. <https://mediatum.ub.tum.de/doc/1624475/>

MAFIPOUR, M. S., VILGERTSHOFER, S., & BORRMANN, A. (2022). Creating digital twins of existing bridges through AI-based methods. *Proceedings of the IABSE Symposium—Challenges for Existing and Oncoming Structures*. https://publications.cms.bgu.tum.de/2022_IABSE_Mafipour.pdf

MAFIPOUR, M. S., ALICI, C., SHAKEEL, S. S., & KALKAVAN, A. (2022). Semantic Segmentation of Real and Synthetic Point Cloud Data for Digital Twinning of Bridges. *Proceedings of 33. Forum Bauinformatik*. <https://mediatum.ub.tum.de/doc/1688410/>

MAFIPOUR, M. S., VILGERTSHOFER, S., & BORRMANN, A. (2022). Digital twinning of bridges from point cloud data by deep learning and parametric models. *Proceedings of European Conference on Product and Process Modeling*. https://publications.cms.bgu.tum.de/2022_Mafipour_ECPPM.pdf

MARTENS, J., BLUT, T., & BLANKENBACH, J. (2022). Cross Domain Matching for Semantic Point Cloud Segmentation based on Convolutional Neural Networks. *Proceedings of PhD Colloquium of the DGK Section on Geoinformatics 2022*.

MARTENS, J., BLUT, T., & BLANKENBACH, J. (2022). Cross Domain Matching for Semantic Point Cloud Segmentation based on Convolutional Neural Networks. *Proceedings of the 29th EG-ICE International Workshop on Intelligent Computing in Engineering*. <https://ebooks.au.dk/aui/catalog/download/455/312/1857-2?inline=1>

MARTENS, J., BLUT, T., & BLANKENBACH, J. (2023). Cross Domain Matching for Semantic Point Cloud Segmentation based on Image Segmentation and Geometric Reasoning, *In Advanced Engineering Informatics (submitted in December 2022, currently under review)*.

VILGERTSHOFER, S., MAFIPOUR, M. S., BORRMANN, A., MARTENS, J., BLUT, T., BECKER, R., BLANKENBACH, J., GLÖBELS, A., BEETZ, J., CELIK, F., FALTIN, B., & KÖNIG, M. (2022). TwinGen: Advanced technologies to automatically generate digital twins for operation and maintenance of existing bridges. *In Proc. of European Conference on Product and Process Modeling 2022*. https://publications.cms.bgu.tum.de/2022_TwinGen_ECPPM.pdf

Literaturverzeichnis

(n. d.).

- BECKER, R. & KNAPP, S. (2020). BIM im Bestand für Betrieb und Unterhaltung von Wasserbauwerken – Das Initialprojekt» Neue Schleuse Trier «. *Interdisziplinärer Wasserbau im digitalen Wandel*, (63), 245–354.
- BEETZ, J., BORRMANN, A. & WEISE, M. (2015). Prozessgestützte Definition von Modellinhalten. In A. BORRMANN, M. KÖNIG, C. KOCH & J. BEETZ (Hrsg.), *Building Information Modeling: Technologische Grundlagen und industrielle Praxis* (S. 129–147). Springer Fachmedien Wiesbaden. https://doi.org/10.1007/978-3-658-05606-3_7
- BEETZ, J., van LEEUWEN, J. & de VRIES, B. (2009). IfcOWL: A case of transforming EXPRESS schemas into ontologies. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 23(1), 89–101.
- BONDUEL, M., ORASKARI, J., PAUWELS, P., VERGAUWEN, M. & KLEIN, R. (2018). The IFC to Linked Building Data Converter - Current Status. *Proceedings of the 6th Linked Data in Architecture and Construction Workshop*, 34–43. <https://ceur-ws.org/Vol-2159/04paper.pdf>
- BUNDESMINISTERIUM FÜR VERKEHR, BAU UND STADTENTWICKLUNG, ABTEILUNG STRASSENBAU. (2013). *Anweisung Straßeninformationsbank Segment Bauwerksdaten*.
- CHAURASIA, A. & CULURCIELLO, E. (2017). Linknet: Exploiting encoder representations for efficient semantic segmentation. *2017 IEEE Visual Communications and Image Processing (VCIP)*, 1–4.
- CHEN, L.-C., ZHU, Y., PAPANDREOU, G., SCHROFF, F. & ADAM, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. *Proceedings of the European conference on computer vision (ECCV)*, 801–818.
- CHU, L., PAN, H. & WANG, W. (2021). Unsupervised Shape Completion via Deep Prior in the Neural Tangent Kernel Perspective. *ACM Trans. Graph.*, 40(3). <https://doi.org/10.1145/3459234>
- GIANNATTASIO, C., PAPA, L. M. & D'AGOSTINO, P. (2019). BIM-oriented algorithmic reconstruction of building components for existing heritage. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-2/W15*, 513–518. <https://doi.org/10.5194/isprs-archives-XLII-2-W15-513-2019>
- GÖBELS, A. (2021). Conversion of infrastructure inspection data into Linked Data models. *Proceedings of the 32. Forum Bauinformatik 2021*.
- GÖBELS, A. (2022). Enabling object-based documentation of existing bridge inspection data using Linked Data. *Proceedings of 33. Forum Bauinformatik*, 148–155.
- GÖBELS, A. & BEETZ, J. (2021). Conversion of legacy domain models into ontologies for infrastructure maintenance. *Proceedings of the 9th Linked Data in Architecture and Construction Workshop - LDAC 2021*, 3081, 12.
- GUO, Y., WANG, H., HU, Q., LIU, H., LIU, L. & BENNAMOUN, M. (2020). Deep learning for 3d point clouds: A survey. *IEEE transactions on pattern analysis and machine intelligence*.
- HAMDAN, A.-H., BONDUEL, M. & SCHERER, R. J. (2019). An ontological model for the representation of damage to constructions. *7th Linked Data in Architecture and Construction Workshop*.

- HAMDAN, A.-H. & SCHERER, R. J. (2021). Areas of Interest - Semantic description of component locations for damage assessment. *EG-ICE 2021 Proceedings: Workshop on Intelligent Computing in Engineering (EG-ICE)*.
- HAN, X., LI, Z., HUANG, H., KALOGERAKIS, E. & YU, Y. (2017). High-Resolution Shape Completion Using Deep Neural Networks for Global Structure and Local Geometry Inference. *2017 IEEE International Conference on Computer Vision (ICCV)*, 85–93. <https://doi.org/10.1109/ICCV.2017.19>
- HU, Q., YANG, B., XIE, L., ROSA, S., GUO, Y., WANG, Z., TRIGONI, N. & MARKHAM, A. (2020). RandLA-Net: Efficient Semantic Segmentation of Large-Scale Point Clouds. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- ISO 21597-1:2020 Information container for linked document delivery - Exchange specification - Part 1: Container (Standard). (2020). International Organization for Standardization, Geneva.
- KENNEDY, J. & EBERHART, R. C. (1997). A discrete binary version of the particle swarm algorithm. *1997 IEEE International conference on systems, man, and cybernetics. Computational cybernetics and simulation*, 5, 4104–4108.
- LIN, T.-Y., DOLLÁR, P., GIRSHICK, R., HE, K., HARIHARAN, B. & BELONGIE, S. (2017). Feature pyramid networks for object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2117–2125.
- LIN, T.-Y., MAIRE, M., BELONGIE, S., HAYS, J., PERONA, P., RAMANAN, D., DOLLÁR, P. & ZITNICK, C. L. (2014). Microsoft coco: Common objects in context. *European conference on computer vision*, 740–755.
- LU, R., BRILAKIS, I. & MIDDLETON, C. R. (2019). Detection of structural components in point clouds of existing RC bridges. *Computer-Aided Civil and Infrastructure Engineering*, 34(3), 191–212.
- QI, C. R., SU, H., MO, K. & GUIBAS, L. J. (2016). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. *arXiv preprint arXiv:1612.00593*.
- RASMUSSEN, M. H., PAUWELS, P., HVIID, C. A. & KARLSHØJ, J. (2017). Proposing a Central AEC Ontology That Allows for Domain Specific Extensions. *Proceedings of the Joint Conference on Computing in Construction*, 237–244.
- RONNEBERGER, O., FISCHER, P. & BROX, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*, 234–241.
- SCHENK, D. & LAURSEN, C. (2018). WinD, DIBS und Co. *Digitalisierung im Verkehrswasserbau*, 52–57.
- TAN, M. & LE, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *International conference on machine learning*, 6105–6114.
- WPM INGENIEURE GMBH. (2022). *SIB-Bauwerke* [Version 1.9]. Bundesanstalt für Straßenwesen.
- XUE, F., LU, W., CHEN, K. & WEBSTER, C. J. (2019). BIM reconstruction from 3D point clouds: A semantic registration approach based on multimodal optimization and architectural design knowledge. *Advanced Engineering Informatics*, 42, 100965. <https://doi.org/https://doi.org/10.1016/j.aei.2019.100965>
- YIN, M., TANG, L., ZHOU, T., WEN, Y., XU, R. & DENG, W. (2020). Automatic layer classification method-based elevation recognition in architectural drawings for reconstruction of 3D BIM

- models. *Automation in Construction*, 113, 103082. <https://doi.org/https://doi.org/10.1016/j.autcon.2020.103082>
- ZHAO, Y., DENG, X. & LAI, H. (2021). Reconstructing BIM from 2D structural drawings for existing buildings. *Automation in Construction*, 128, 103750. <https://doi.org/https://doi.org/10.1016/j.autcon.2021.103750>
- ZHOU, Z., SIDDIQUEE, M. M. R., TAJBAKSH, N. & LIANG, J. (2018). Unet++: A nested u-net architecture for medical image segmentation. *Deep learning in medical image analysis and multimodal learning for clinical decision support* (S. 3–11). Springer.
- ZHU, J.-Y., PARK, T., ISOLA, P. & EFROS, A. A. (2017). Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. *2017 IEEE International Conference on Computer Vision (ICCV)*, 2242–2251. <https://doi.org/10.1109/ICCV.2017.244>