

Machine-Learning Methoden zur frühzeitigen Prognose von Bewehrungsstahlmengen im Stahlbetonhochbau

Marcel Heiß¹

¹ Institut für Numerische Methoden und Informatik im Bauwesen, Technische Universität Darmstadt,
Franziska-Braun-Straße 7, 64287 Darmstadt, Deutschland

E-mail(s): heiss@iib.tu-darmstadt.de

Abstract: Zum Arbeitsalltag von Ingenieuren und Architekten gehören immer noch viele sich wiederholende Arbeitsprozesse, welche einen hohen Zeitbedarf einnehmen. Dies hat zur Folge, dass die kreative Lösung von Problemen oftmals in den Hintergrund gerät. Abhilfe leisten können KI-basierte Assistenzsysteme, welche in der Planung die Entscheidungsfindung unterstützen und Arbeitsprozesse automatisieren. Mit dem Einsatz von BIM-Daten in Machine-Learning Methoden zur frühzeitigen Prognose von Bewehrungsstahlmengen im Stahlbetonhochbau wird ein möglicher Anwendungsfall für ein KI-basiertes Assistenzsystem in der Tragwerksplanung hinsichtlich seiner Potentiale und Grenzen im Detail untersucht. Hierbei werden entsprechende Daten aus BIM-Modellen gewonnen und diese für das Machine-Learning vorverarbeitet. In einem Vergleich unterschiedlicher Machine-Learning Algorithmen werden deren Leistungsfähigkeit beurteilt und vielversprechende Lernmodelle werden nochmals optimiert. Ziel ist die Entwicklung eines Machine-Learning Algorithmus, welcher in der Entwurfsplanung die Bewehrungsstahlmenge eines Gebäudes automatisiert auf Basis eines BIM-Modells der Tragwerksplanung entsprechend gewisser Vorgaben genau bestimmt. Die Ergebnisse zeigen, dass dieser Ansatz bereits mit einer geringen Menge an zu Verfügung stehenden Daten und Informationen unter Einschränkungen möglich ist und außerdem noch weitere Potentiale birgt.

Keywords: Building Information Modeling, Datenaufnahme/ Data Mining, Machine Learning und KI

1 Einführung

Bauwerke stellen im Regelfall Unikate dar, weswegen zu Planungsbeginn die Baukosten und die Bauzeit immer neu abgeschätzt werden müssen. Die Kostenberechnung in der Entwurfsplanung verwendet die Entwurfszeichnungen und sich daraus ergebenden Mengen zu Bauteilen wie Wänden als Grundlage hierfür. In diesem Projektstadium erschweren jedoch viele weitere noch unbekannt Planungsgrößen eine zuverlässige Prognose der Kosten. Dies bedeutet für alle Beteiligten eine

Planungsunsicherheit und damit ein gewisses Risiko in jedem Bauprojekt. Eine in einem Stahlbetonhochbauprojekt erst spät in der Planung bekannte Größe ist die Bewehrungsmenge. Diese wird erst mit Abschluss der Bewehrungsplanung durch die Tragwerksplanung in Leistungsphase 5 gemäß Anlage 14 der HOAI [1] bekannt. Die Bewehrungsmenge hat jedoch Einfluss auf die Kosten und den Ablauf eines Stahlbetonbauprojektes. Deswegen ist eine Grundleistung der Leistungsphase 3 im Rahmen der Tragwerksplanung eine überschlägige Ermittlung der Betonstahlmenge eines Projektes vor der eigentlichen Statik und Bewehrungsplanung. Hierzu wird oftmals auf den Baustoffkennwert Bewehrungsgrad [2] zurückgegriffen, welcher durch den Quotienten aus **Bewehrungsmenge ($BW_{M,i}$)** und **Betonmenge ($BT_{M,i}$)** definiert wird. In der bisherigen Praxis finden u.a. Werte für den **Bewehrungsgrad einzelner Bauteile ($bw_{g,bt,i}$)** aus unterschiedlichen Literaturen wie [3], eigene Erfahrungswerte und mittels einer überschlägigen Bemessung für einzelne Bauteile ermittelte Werte Anwendung. Wissenschaftliche Veröffentlichungen wie [4] beschäftigen sich mit der Validierung von Werten aus etablierten Literaturen und der Herleitung eigener, statischer Werte auf Basis statistischer Auswertungen analoger Unterlagen wie Bewehrungsplänen und statischen Bemessungen. Unter Mittelwertbildung werden dabei abhängig des Bauteiltyps und davon abhängenden, identifizierten Einflussgrößen wie Belastung, Beanspruchung oder Spannweite Werte für den Bewehrungsgrad ermittelt. In der Praxis muss der Ingenieur aufwändig Planungsunterlagen wie 2D-Pläne oder BIM-Modelle sichten, für die ermittelten Bauteile individuelle Bewehrungsgrade schätzen und daraufhin die benötigte Bewehrungsmenge hochrechnen. Je nach Größe und Komplexität des Gebäudes kann die überschlägige Ermittlung der Bewehrungsmenge in der Entwurfsplanung jedoch sehr aufwendig werden und bietet dabei nur eine geringe Sicherheit bezüglich der Genauigkeit der Prognose.

2 Konzept

Zur datengestützten Optimierung dieses Prozesses können Machine-Learning Methoden zu dieser überschlägigen Bewehrungsermittlung Anwendung finden. **Maschinelles Lernen** (engl. machine learning) (ML) ist ein Ansatz aus dem Gebiet der **künstlichen Intelligenz** (KI) und beschreibt die Fähigkeit von Systemen und Algorithmen, Fertigkeiten zu erlernen ohne dafür explizit programmiert zu sein und damit Wissen zu erzeugen [5]. Die Ansammlung der für den Einsatz von ML oftmals notwendigen großen Datenmengen wird durch die starke Fragmentierung der Bauwirtschaft erschwert, weswegen noch keine Anwendungen zur Automatisierung von Planungsprozessen, zu denen auch der vorgestellte Prozess der Bewehrungsermittlung zählt, ihren Weg in die Praxis gefunden haben. Das Forschungsprojekt „Smart Design and Construction (SDaC)“ [6] beschäftigt sich mit dem vorangestellten Problem und u.a. mit dem Einsatz von KI zur Planungsautomatisierung. Spezifische Anwendungsgebiete im Stadium der Forschung sind der Einsatz von KI im Designprozess der Architektur wie in [7] und bei der Dimensionierung von Bauteilen im Rahmen der Tragwerksplanung wie in [8]. Die Verwendung von überwachtem maschinellem Lernen zur Bewehrungsermittlung hat eine Automatisierung des Prozesses und eine höhere Sicherheit bezüglich der Genauigkeit der Prognose zum Ziel. Zielgröße des überwachten Lernens stellt der Bewehrungsgrad einzelner Stahlbetonbauteile dar, welcher auf Basis sogenannter Merkmale (engl. Features) wie Bauteiltyp, Abmessungen und Ma-

terialeigenschaften prognostiziert wird. Die **Gesamtbewehrungsmenge eines Bauwerks ($BW_{M,bwk}$)** ergibt sich aus der Iteration über alle Bauteile eines Bauwerks (n) gemäß Gleichung (1).




Abbildung 1: Prozess der überschlägigen Ermittlung der Betonstahlmenge mit ML in der Entwurfsplanung auf Basis eines BIM-Modells

$$BW_{M,bwk} = \sum_{i=0}^n BW_{M,bt,i} = \sum_{i=0}^n BT_{M,bt,i} \cdot bw_{g,bt,i} \tag{1}$$

3 Rohdaten, Datenaufbereitung und Datenanalyse

Die notwendigen Rohdaten zu den einzelnen Bauteilen können durch die Planungsweise des **Building Information Modelling** (BIM) automatisiert aus abgeschlossenen Projekten gewonnen werden. Die in BIM modellierten Bauteile besitzen neben den geometrischen Informationen des 3D-Körpers zusätzliche Informationen wie beispielsweise zu dem Bauteiltyp, dem Material oder der Betongüte in Form von angehängten Attributen. Die verwendeten Rohdaten stammen aus BIM-Modellen der Tragwerksplanung, welche die Extraktion der in Tabelle 1 dargestellten Features und des Zielwertes ermöglichen. Die Extraktion der Daten ist direkt aus dem Autorensystem Allplan 2019 des Herstellers Nemetschek erfolgt. Eine mittels einer Schnittstelle entwickelte Erweiterung ermöglicht den Zugriff auf alle Bauteile und deren Informationen und das Überführen dieser in Datensätze, welche in einer csv-Datei gesammelt werden. Die Information über den Bewehrungsgrad ist nur implizit in den BIM-Modellen vorhanden. Die semantisch unabhängige Modellierung von Bauteilen und Bewehrung macht eine nachträgliche Berechnung des Bewehrungsgrades der Bauteile mittels Algorithmen erforderlich, welche sich die eindeutige Positionierung von Bewehrung und Bauteilen im Raum zunutze macht. Zur Erhöhung der Qualität für das ML wird zunächst eine **Datenvorverarbeitung** durchgeführt, in welcher unter anderem fehlerhafte Werte in Datensätze korrigiert werden. Außerdem werden Features, welche mehrere oder implizite Informationen enthalten, in gesonderte Features überführt. Im Rahmen dieses Prozesses wird die Anzahl der zu Verfügung stehenden Datensätzen von 7042 auf 4901 reduziert. In der anschließenden **Feature Transformation** wird eine Kodierung der kategorischen, ordinalen und binären Features in ganze Zahlen vorgenommen. Die Features werden normalisiert um einen wertebedingten Einfluss in auf Ähnlichkeitsmessungen basierenden Lernmodellen zu verhindern.

Im Rahmen einer Datenanalyse werden die auftretenden Häufigkeiten der unterschiedlichen Ausprägungen in den einzelnen ordinalen und kategorischen Features mittels Histogrammen auf Unaus-

geglichenheit untersucht. Eine gewisse Verteilung der Werte der Features ist in den meisten Fällen gegeben. Die Verteilung des Features Projekttyp zeigt dabei eine starke Konzentration der Daten auf dem Wohnungsbau. Von den insgesamt 48 ausgewerteten Projekten sind nur 7 dem Wohnungsbau zuzuordnen. Demnach enthalten die ausgewerteten Wohnungsbauprojekte immer eine hohe Anzahl an Bauteilen. Gleiches gilt für die Projekte aus dem Parkhausbau, jedoch nicht für die Projekte aus dem Industriebau. Im Allgemeinen sind in allen Features, welche direkt oder indirekt in eine statische Bemessung einzelner Stahlbetonbauteile mit eingehen, Informationen zum Bewehrungsgrad eines Bauteils zu vermuten. Generell richtet sich die Bemessung nach dem genauen Bauteiltyp, welcher auch in bisherigen Literaturen als einziges Kriterium für den Bewehrungsgrad eines Bauteils verwendet wird. Das Feature Projekttyp kann implizit Informationen zu Lastannahmen und Gebäudestruktur, welche beispielsweise Spannweiten von Decken beeinflussen, enthalten. Mit dem Feature Material gehen oftmals besondere Anforderungen an die Bewehrung des Bauteils, wie zur Betondeckung, einher. Die Druckfestigkeitsklasse in dem Feature Betongüte kann Hinweise zur generellen Beanspruchung des Tragwerks geben, da hohe Betongüten bei starken beanspruchten Tragwerken Einsatz finden. Die Abmessungen eines Bauteils geben Aufschluss über die Geometrie, welche in einer Bemessung eine maßgebliche Größe darstellt, aber unter Umständen auch über statische Randbedingungen wie Spannweiten. Außerdem geht das Volumen des Bauteils direkt in die Berechnung des Bewehrungsgrades eines Bauteils ein und bestimmt diesen daher mit.

Tabelle 1: Entwicklung der Daten im Rahmen der Datenvorverarbeitung

Features der Rohdaten	Features nach Datenverarbeitung	Featuretyp	Wertebereich
Projektbezeichnung	Bauherr Projekttyp	kategorisch kategorisch	Bauherr A, Bauherr B, und Weitere Wohnungsbau, Industriebau, Parkhausbau
Bauteiltyp Funktion	Bauteiltyp	kategorisch	Stütze, Wand, Decke und Weitere
Material	Material	kategorisch	Stahlbeton, wasserundurchlässiger Stahlbeton, flüssigkeitsdichter Stahlbeton
Betongüte	Betongüte	ordinal	C 25/30, C 30/37, C 35/45, höhere Betongüte
Außenbauteil	Außenbauteil	binär	Ja, Nein
Statisch Tragend	Statisch Tragend	binär	Ja, Nein
3D-Kordinaten des Bauteilmittelpunktes	x-Koordinate	kontinuierlich	-
	y-Koordinate	kontinuierlich	-
	z-Koordinate	kontinuierlich	-
Abmessungen des Bauteils	Länge	kontinuierlich	-
	Breite	kontinuierlich	-
	Höhe	kontinuierlich	-
Nettovolumen	Nettovolumen	kontinuierlich	-

4 Training und Validierung

Die vorverarbeiteten Daten werden an ausgewählte Lernmodelle übergeben und deren Lernerfolg anhand von Metriken betrachtet. In der praktischen Anwendung erhält der Algorithmus ein neues Projekt mit beliebig vielen Bauteilen in Form von Datensätzen. Um diesen Anwendungsfall auch in der Validierung zu beachten, erfolgt die Einteilung in Trainings- und Testdaten in Form einer k-fachen Kreuzvalidierung. Dabei ist k gleich der Anzahl an verfügbaren Projekten. So werden immer die Datensätze eines Projektes zum Testen zurückgehalten, während die Datensätze aller anderen Projekte zum Trainieren verwendet werden. Metriken erlauben dann einen Vergleich der Lernmodelle zwischen einander. Jedoch wird durch diese nicht deutlich ob das letztendliche Ziel, die Ermittlung der Gesamtbewehrungsmenge, eines Bauwerks ebenfalls erreicht ist. Deswegen wird außerdem die Gesamtbewehrungsmenge jedes Bauwerks ermittelt und der tatsächlichen Gesamtbewehrungsmenge gegenübergestellt. Es werden die fünf Lernmodelle k-Nearest-Neighbor, Gradient Boosting, Random Forest, Support Vector und Neuronale Netze herangezogen. Als Metrik dient der mittlere absolute Fehler (MAE), welcher dieselbe Einheit wie die Zielgröße ausweist. Zur Beurteilung des Lernerfolgs werden zum einen der Mittelwert und die Streuung des MAE und zum anderen der Mittelwert und die Streuung bezüglich der Abweichung von der Gesamtbewehrungsmengen herangezogen. Während für den MAE keine Zielwerte definiert werden können und dieser daher nur relativ betrachtet werden kann, sind Abweichungen von der tatsächlichen Gesamtbewehrungsmenge unter 20 % als Ziel fest definiert.

5 Ergebnisse

Beim Training der unterschiedlichen Lernmodelle unter den zu Verfügung stehenden Daten zeigt sich früh, dass die erzielten Resultate der Lernmodelle vom Projekttyp abhängen. Deswegen erfolgt die Auswertung der Resultate der Lernmodelle getrennt für die unterschiedlichen Projekttypen. Während alle Lernmodelle im Wohnungsbau hinsichtlich der gesetzten Kriterien aussichtsreiche Ergebnisse liefern, schwanken die Ergebnisse im Industriebau je Projekt unabhängig des Lernmodells sehr stark. Dies kann auf die starke Variation der kleinen Industriebauprojekte und den wenigen zu Verfügung stehenden Datensätzen aus diesem Bereich im Vergleich zum Wohnungsbau zurückgeführt werden. Sowohl bei den Wohnungsbauprojekten als auch bei den Parkhausprojekten handelt es sich um große Bauwerke, welche eine starke Ähnlichkeit untereinander hinsichtlich der Bauweise aufweisen, und einen Großteil der Daten ausmachen. Das Gradient Boosting erweist sich unter den zu Verfügung stehenden Daten sowohl im Wohnungsbau als auch im Parkhausbau als aussichtsreichstes Lernmodell und die Ergebnisse zum Wohnungsbau sollen im Folgenden genauer vorgestellt werden. In diesem Fall wird ebenfalls eine k-fache Kreuzvalidierung angewendet, bei der jedoch k gleich der Anzahl an Wohnungsbauprojekten zuzüglich eins ist. Es ergeben sich deswegen sieben Folds, von denen sechs die sechs Wohnungsbauprojekte darstellen, welche auch als Testdatensätze verwendet werden. Eine erneute Feature Transformation muss nicht erfolgen, da auf Entscheidungsbäumen basierende Lernmodelle kategoriale und ordinale Features ohne eine aufwendige Kodierung ve-

arbeiten können. Außerdem ist keine Skalierung notwendig. Eine erste Lernkurve des Gradient Boosting in Abbildung 4 zeigt einer Annäherung der beiden Scores. Dies deutet eine sich ausbildende Generalisierungsfähigkeit des Modells an. Der Score (MAE) für die Trainingsdaten weist im Vergleich zu dem Cross-Validation Score eine wesentlich geringe Streuung und einen wesentlich geringeren Wert für den MAE auf, wodurch eine Überanpassung des Modells an die Trainingsdaten und damit die Erzeugung eines zu komplexes Modell deutlich wird. Um den Effekt der Überanpassung zu reduzieren wird auf die Erzeugung eines einfacheren Modells durch die Verringerung der Features zurückgegriffen. Im Rahmen einer Merkmalsauswahl sollen zunächst aussagekräftige Features ermittelt werden. Abbildung 2 zeigt die im Rahmen des Gradient Boosting implizit ermittelten Merkmalswichtigkeiten im Ranking. Hieraus wird deutlich, dass die wichtigsten vier Features bereits ca. 75 % des gesamten Informationsgehaltes aufweisen. Das gleiche Ergebnis liefert die Gegenüberstellung der Mittelwerte für den Cross-Validation Score und den Trainings-Score unter zunehmender Anzahl an Features in Abbildung 3. Das Modell mit dem höchsten mittleren Cross-Validation Score und der geringsten Differenz zwischen Cross-Validation Score und Trainings-Score weist die geringste Überanpassung auf.




Abbildung 2: Ranking der Features unter Anwendung eines eingebetteten Verfahrens




Abbildung 3: Entwicklung des Cross-Validation Score und des Trainings-Score mit zunehmender Anzahl an Features

Im Rahmen einer sich anschließender Hyperparameterabstimmung werden die Hyperparameter Learning-Rate, n-estimators und max-depth mittels Validierungskurven getrennt und mittels Raster-suche kombiniert untersucht. Die abschließende Lernkurve in Abbildung 5 zeigt, dass trotz der geringeren Komplexität des Modells durch die Merkmalsauswahl die Performance geringfügig gesteigert werden konnte. Die Annäherung der Scores zeigt den Lernprozess des Modells. Die Lernkurven schließen jeweils bei einem Wert von 28 bzw. 47 für den MAE ab. Die Annäherung der beiden Kurven in einem so hohen Wertebereich deutet auf eine große Verzerrung und eingeschränkte Generalisierungsfähigkeit des Modells hin. Bei der Ermittlung der Bewehrungsgrade einzelner Bauteile verschiedener Projekte wird deutlich, dass die zum derzeitigen Stand vorliegenden Daten nicht ausreichen um den Bewehrungsgrad eines Bauteils entsprechend genau zu prognostizieren.

Die Auswertung des Bewehrungsgrades zeigt, dass der Bewehrungsgrad vorrangig Werte zwischen 100 und 200 kg/m³ annimmt. Bei einem angenommenen Wert von 150 kg/m³ für den Bewehrungsgrad

eines beispielhaften Bauteils bedeutet ein MAE in Höhe von 45 kg/m^3 eine prozentuale Abweichung von 30 %, welche oberhalb der angesetzten 20 % Abweichung von der Gesamtbewehrungsmenge liegt. Die hohen mittleren absoluten Fehler deuten darauf hin, dass zum einen gewisse Informationen, welche für den Bewehrungsgrad entscheidend sind, nicht enthalten sind und zum anderen, dass die Menge an Daten noch nicht ausreichend ist, wodurch der Informationsgehalt vieler Features unter Umständen nicht erfasst werden kann. Dies bewirkt, dass die Lernmodelle nur aus wenigen Features einen Performancezuwachs erzielen. Es fehlen Informationen zu der genauen Beanspruchung der Bauteile in Form von Schnittgrößen, aber auch Belastungen auf die Bauteile oder die Expositionsklassen können vielversprechende Informationsquellen sein. Trotz der geringeren Generalisierungsfähigkeit ist es mit dem ausgearbeiteten Lernmodell möglich die Gesamtbewehrungsmengen von Projekten, welche in den Daten in ausreichender Häufigkeit und Ähnlichkeit vertreten sind, zuverlässig zu prognostizieren. Grund hierfür ist die in der Verallgemeinerungsfähigkeit und im MAE nicht erfasste Streuung des Fehlers in positive und negative Richtung. Demnach kann die Bewehrung eines Bauteils unterschätzt und die des nächsten überschätzt werden. So werden Fehler bei den Bewehrungsgraden einzelner Bauteile bei der Ermittlung der Gesamtbewehrungsmenge wieder ausgeglichen. Dies setzt voraus, dass die Bewehrungsgrade ausgewogen über- und unterschätzt werden und dass das Bauwerk eine hohe Anzahl an Bauteilen besitzt, sodass sich dieser Effekt auch einstellen kann. Zum anderen sind für die Gesamtbewehrungsmenge vor allem die voluminösen Bauteile relevant, da diese mit einer höheren Gewichtung eingehen. Deswegen besitzt der MAE in Bezug auf die Gesamtbewehrungsmenge nur eine bedingte Aussagekraft. Eine Metrik, die den Fehler anhand des Volumens gewichtet wäre in diesem Fall zielführender.

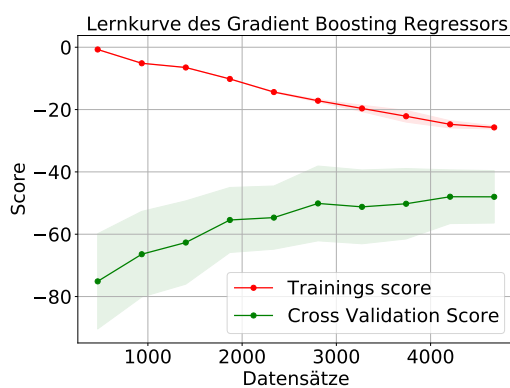


Abbildung 4: Lernkurve unter Verwendung aller Features




Abbildung 5: Lernkurve nach Feature Selection und Hyperparameterabstimmung

6 Fazit und Ausblick

Die Ergebnisse zeigen, dass die Anwendung des überwachten, maschinellen Lernens zur Ermittlung der Bewehrungsmenge von Stahlbetonhochbauprojekten in der Entwurfsplanung in der Praxis bereits mit der geringen Menge an Daten und Informationen unter Einschränkungen möglich ist und in der Theorie außerdem noch weitere Potentiale birgt. So konnte mit dem entwickelten Lernmodell bei

Wohnungsbauprojekten die Zielvorgabe von einer Abweichung von weniger als 20 % der tatsächlichen Gesamtbewehrungsmenge eingehalten werden. Um eine ausreichende Repräsentativität der Ergebnisse zu gewährleisten ist jedoch eine umfangreichere Validierung der Lernmodelle unabdingbar. Eine Einschränkung ergibt sich aus der zur erfolgreichen Prognose der Gesamtbewehrungsmenge notwendigen Ähnlichkeit des neuen Projektes mit den Projekten, welche Grundlage der Trainingsdaten sind. Drei große Probleme, die sich im Rahmen dieser Arbeit herauskristallisierten, sind die geringe Menge an Daten, deren ungleichmäßige Verteilung und deren für dieses Anwendungsziel nicht vollständiges Informationsprofil. Dies führt zu einer unzureichenden Generalisierungsfähigkeit des entwickelten Lernmodells hinsichtlich des Bewehrungsgrades eines Bauteils. Durch die sich immer weiterverbreitende BIM Planungsweise, kommt es zwangsläufig zu einer weiteren Ansammlung von strukturierten Daten, die genutzt werden können. BIM-Modelle befinden sich zudem in einer ständigen Entwicklung. So wird der Informationsgehalt in den BIM-Modellen mit dieser Entwicklung noch zunehmen und diese können wiederum im überwachten Lernen genutzt werden. Informationen wie die Expositionsklassen, Feuchtigkeitsklassen, Einwirkungen oder die Beanspruchungen der einzelnen Bauteile in Form der Schnittgrößen können einen immensen Mehrwert bieten. Um dies zu erreichen ist es jedoch erforderlich derzeit bestehende Datensilos wie BIM-Daten und Statik-Daten im Rahmen eines ganzheitlichen Datenmanagements gezielt zu verknüpfen.

Literatur

- [1] HOAI.de, *HOAI 2021: Volltext der aktuellen HOAI online auf HOAI.de*, Okt. 2021. Adresse: <https://www.hoai.de/hoai/volltext/hoai-2021/#A14> (besucht am 24. 05. 2022).
- [2] C. Hofstadler, *Baublaufplanung und Logistik im Baubetrieb: Mit 5 Tabellen*. Berlin, Heidelberg und New York: Springer, 2007, ISBN: 3-540-34320-2.
- [3] R. Rybicki und F. U. Prietz, *Faustformeln und Faustwerte für Tragwerke im Hochbau: Geschossbauten, Konstruktionen, Hallen*, 6. aktualisierte Auflage. Köln: Reguvis, 2021, ISBN: 978-3-8462-1095-6.
- [4] D. Dix, *Kalkulation im Schlüsselfertigbau leicht gemacht: Stahlbedarfsfaktoren für den Hochbau*. Hamburg: Diplomica Verl., 2010, ISBN: 3836696940.
- [5] P. Wennker, *Künstliche Intelligenz in der Praxis: Anwendungen in Unternehmen und Branchen: KI wettbewerbs- und zukunftsorientiert einsetzen*. Wiesbaden, Germany und Heidelberg: Springer Gabler, 2020, ISBN: 978-3-658-30479-9. DOI: 10.1007/978-3-658-30480-5.
- [6] sdac.tech, *Smart design and construction - SDAC - smart design and construction through Artificial Intelligence*, Feb. 2022. Adresse: <https://sdac.tech/> (besucht am 01. 07. 2022).
- [7] C. Frías, J. Peña, É. Sánchez und L. Almeida, »BIMBOT-(Artificial intelligence applied to BIM design)«, *EGE-Expresión Gráfica en la Edificación*, S. 45, Juli 2020. DOI: 10.4995/ege.2020.13942.
- [8] K. Chang und C. Cheng, »Learning to simulate and design for structural engineering«, *CoRR*, Jg. abs/2003.09103, 2020. arXiv: 2003.09103. Adresse: <https://arxiv.org/abs/2003.09103>.