

---

# Deep Learning-Ansatz zur Vorhersage der Fußgängerdynamik für Verkehrsknotenpunkte in frühen Entwurfsphasen

---

Jan Clever<sup>1</sup>, Jimmy Abualdenien<sup>1</sup>

<sup>1</sup>Technische Universität München, Lehrstuhl für Computergestützte Modellierung und Simulation

---

---

## Zusammenfassung

Eine nahtlose Integration von Modellanalysen und Simulationen in den Entwurfsprozess ist ein Schlüssel zur Unterstützung der verschiedenen Entscheidungen, einschließlich der Entscheidung über die Position, die Abmessungen und die Materialität von Gebäudeelementen. Solche Entwurfsoptionen werden in den frühen Entwurfsphasen untersucht, wo eine Entscheidung auf der Grundlage ihrer Leistung getroffen wird. Eine wichtige Analyse, die für die verschiedenen Gebäudetypen, insbesondere für Verkehrsknotenpunkte, notwendig ist, ist die Fußgängerdynamik, da sie den Komfort der Gebäudenutzer und die Fähigkeit zur Evakuierung des Gebäudes im Notfall bewertet. Derzeit ist die Analyse des Fußgängerflusses von den BIM-Autorenwerkzeugen entkoppelt, erfordert mehrere manuelle Schritte und ist zeitaufwändig. Daher wird in diesem Beitrag ein Framework vorgeschlagen, das die neuesten Fortschritte des Deep Learning (DL) nutzt, um Simulationen der Fußgängerdynamik durch ein DL-Modell zu ersetzen, das ein Zwischenfeedback liefert. Dabei wird eine Darstellung des Gebäudemodells einschließlich Simulationsparametern als Eingabe vorgeschlagen und eine Convolutional Neural Network (CNN)-Architektur entwickelt und trainiert, um Heatmaps der Personenströme sowie Tracing Maps vorherzusagen.

**Keywords:** Building Information Modeling, Deep Learning, Pedestrian Simulation

---

## 1 Einleitung

Die Architektur-, Ingenieur- und Bauindustrie ist ein multidisziplinärer Sektor, der aus verschiedenen, miteinander verbundenen Fachbereichen besteht. Während des Entwurfsprozesses eines Gebäudes trifft jede Disziplin mehrere Entscheidungen, die sich auf den resultierenden Entwurf und dessen Leistung auswirken. In den letzten zehn Jahren hat Building Information Modeling (BIM) an Popularität gewonnen, da BIM die Zusammenarbeit zwischen den Projektbeteiligten fördert und den Planungsprozess bereits in den frühen Phasen beeinflusst [1].

Durch die Entwurfsphasen hindurch werden die Gebäudemodelle schrittweise von einem groben konzeptionellen Entwurf (bei dem viele Unsicherheiten vorhanden sind) zu hochkomplexen Einzelkomponenten verfeinert. In den frühen Entwurfsphasen (konzeptionelle und vorläufige Phasen) sind BIM-Modelle mehrfachen Änderungen unterworfen [2], wobei Änderungen im Entwurf einen relativ geringen Aufwand erfordern [3]. Normalerweise untersuchen und bewerten Architekten und Ingenieure die Leistung mehrerer Entwurfsoptionen durch den Vergleich ihrer Simulationsergebnisse. Die Bewertung der Leistung eines Entwurfs umfasst zahlreiche Simulationen und Analysen. Bekannt ist die Strukturanalyse des Systems, der grauen (Embodied Energy) und betrieblichen Energie während des Lebenszyklus [4], sowie des Komforts und der Evakuierung von Gebäudenutzern, auch als Fußgänger bezeichnet.

Mithilfe von BIM können die verschiedenen Objekte (wie Wände, Treppen und Zonen) identifiziert werden, wobei jede Instanz eine geometrische Darstellung und einen Satz von Eigenschaften hat [3]. Solche Fähigkeiten bieten die notwendigen Mittel, um einen reibungslosen Arbeitsablauf zwischen BIM-Autorenwerkzeugen und Simulatoren zu etablieren, wobei individuelle Simulationsinformationen in das Modell aufgenommen werden können. Um unabhängig von einem bestimmten Softwarehersteller zu arbeiten, unterstützt eine Vielzahl der vorhandenen Autorenwerkzeuge und Simulatoren den Austausch von Modellen über den offenen Standard Industry Foundation Classes (IFC) [5]. Viele Forscher haben die Möglichkeiten der Verwendung von IFC-BIM-Modellen als Grundlage für Simulationen untersucht und nachgewiesen [5].

Im Allgemeinen kann die Integration von Simulationen in frühe Entwurfsphasen den Entscheidungsprozess unterstützen, was dazu beiträgt, die beabsichtigten Projektziele zu erreichen [3]. Da das Verhalten von Fußgängern in Normal- und Paniksituationen essentiell ist und stark von der Umgebung abhängt [6], erfordern ihre Verkehrswege eine besondere Aufmerksamkeit während des Entwurfsprozesses eines Gebäudes. Daher zielt diese Arbeit darauf ab, die bestehenden Arbeitsabläufe für integrierte Fußgängersimulationen in den Entwurfsprozess zu verbessern, insbesondere für öffentliche Gebäude, wie z. B. Bahnhöfe.

Die Ergebnisse von Fußgängersimulationen geben in der Regel Aufschluss über den Komfort der Fußgänger, den Verkehr und die Evakuierung im Notfall. Der aktuelle Stand der Praxis beinhaltet jedoch mehrere Schritte, einschließlich des Exports von Gebäudemodellen

---

aus dem BIM-Autorenwerkzeug, des Imports in den Simulator, der Durchführung der Simulation und schließlich der Erstellung einer Zusammenfassung der Simulationsergebnisse. Da darüber hinaus agentenbasierte Fußgängersimulationen einen hohen Rechenaufwand und damit einhergehend lange Rechenzeiten erfordern, ist der gesamte Prozess zeitaufwändig und fehleranfällig [7], was die interaktive Erkundung der Entwurfsmöglichkeiten einschränkt.

Um diese Einschränkung zu überwinden, wird in diesem Beitrag ein Framework vorgeschlagen, das Methoden des Deep Learning (DL) nutzt, um eine Echtzeitvorhersage des Komforts und der Verkehrswege von Fußgängern zu ermöglichen. Genauer gesagt können Ansätze des maschinellen Lernens (ML) verwendet werden, um zeitaufwändige Simulationen zu vermeiden, indem sie diese mit prädiktiven Tools unterstützen oder sogar ersetzen [8]. Wir nutzen die reichhaltigen Informationen, die von BIM-Modellen bereitgestellt werden, als Input für das ML-Modell und ermöglichen so eine direkte Interaktion zwischen der Erstellung von verschiedenen Entwürfen und deren Bewertung hinsichtlich der fußgängerdynamischen Leistung.

Dieser Beitrag ist in mehrere Teile gegliedert: Abschnitt 2 führt in Hintergrundwissen und verwandte Arbeiten ein. In Abschnitt 3 wird das Konzept unseres Ansatzes schrittweise beschrieben, während Abschnitt 4 die Ergebnisse präsentiert. In Abschnitt 5 fasst ein Fazit unsere Ergebnisse zusammen und gibt einen Ausblick auf zukünftige Schritte.

---

## 2 Grundlagen

### 2.1 Leistungsorientierte Gebäudeplanung

Die Planung eines Gebäudes erfordert viele verschiedene Schritte und berücksichtigt daher mehrere Abhängigkeiten von Entscheidungen. Daher ist die leistungsorientierte Gebäudeplanung eine entscheidende Methode, um kritische Änderungen, die in der letzten Phase vorgenommen werden müssen, zu reduzieren und die Leistung eines Gebäudes zu maximieren [9]. Um verlässliche Ergebnisse zu erzielen, müssen außerdem ausreichend Daten und Informationen bereitgestellt werden. Besonders in frühen Entwurfsphasen können Entscheidungen die spätere Leistung und die Kosten beeinflussen [10].

Um Entscheidungen in der Entwurfsphase zu verbessern, wurden BIM-basierte Ansätze entwickelt, um die BIM-Modelle im Prozess zu nutzen. In diesem Sinne integrieren die Autoren von [11] Teile der Ökobilanzierung in BIM, indem sie die Materialien des Gebäudes berücksichtigen. Auf diese Weise wird der Planer über die potenziellen Auswirkungen der gewählten Materialien auf deren graue Energie informiert. Darüber hinaus schlagen [12] eine BIM-basierte Optimierungsbewertung des strukturellen Entwurfs eines Gebäudes vor. Dieser Ansatz hilft, die Koordination zwischen Architekten und Statikern während der Entwurfsphase zu verbessern.

### 2.2 Personenstromanalyse und Simulationsmodelle

Die Funktionalität insbesondere von öffentlichen Gebäuden wie Bahnhöfen oder Einkaufszentren ist bei einer Evakuierung im Notfall entscheidend [13]. Darüber hinaus ist die Analyse der Fußgängerdynamik ein wesentlicher Aspekt für eine effiziente Führung der Menschenmenge hinsichtlich Sicherheit und Komfort. Diese ist stark von der Form des Gebäudes abhängig [14].

Beobachtungen zeigen, dass einzelne Fußgänger dazu neigen, polygonförmige Routen zu wählen und in Bezug auf Sichtbarkeit geraden Wegen so lange wie möglich zu folgen. Auch wenn manche Bereiche überfüllt sind, werden längere Wegzeiten und unbekannte Umwege bewusst oder unbewusst in Kauf genommen [15]. Die daraus resultierende Selbstorganisation der Menschenmengen basiert ohne externe Planung eher auf unbewusster als auf kommunikativer oder ausgesprochener Strategie, insbesondere bei unidirektionalen Fußgängerströmen [16]. Außerdem scheinen einzelne Personen ihre Gehgeschwindigkeit anzupassen, wenn sie in einem allgemein überfüllten Bereich auf sich bewegende Menschengruppen treffen. Gleichzeitig interpretieren Einzelpersonen stationäre Gruppen als eindeutige Hindernisse, was zu einer Änderung ihrer Laufwege führt [17].

Bei den Simulationsmodellen werden drei allgemeine Ansätze zur Modellierung des Fußgängerverhaltens unterschieden, abhängig von der Anzahl der virtuellen Fußgänger (Agenten). Mikroskopische Methoden definieren die Reaktion einzelner Agenten, während makroskopische Ansätze das Gruppenverhalten modellieren. Zwischen diesen beiden Ansätzen liegen mesoskopische Modelle, die Informationen über einzelne Agenten liefern und gleichzeitig in der Lage sind, umfangreichere Gruppen zu behandeln [18]. Da sich nur regelbasierte Ansätze als unzureichend erwiesen haben [19], wurde in Helbing et al., 2000 ein verallgemeinertes Kräftemodell entwickelt, das sogenannte Social Force Modell. Im Prinzip berücksichtigen die repulsiven Interaktionskräfte der einzelnen Agenten andere Agenten und Hindernisse, während sie sich mit einer bestimmten Geschwindigkeit bewegen.

Im Gegensatz zum individuellen Verhalten wird das Verhalten von Menschenmengen eher als ein Flussmechanismus verstanden, der die Umgebung und die individuellen Interaktionen der Agenten ignoriert. Genauer gesagt folgt die zugrundeliegende Idee dem Prinzip der Kontinuumstheorie, die von [20] vorgeschlagen wurde. In [21] werden wiederum andere Ansätze vorgestellt, wie z. B. das auf der Fluidmechanik basierende Modell der Aggregatdynamik. Um die verschiedenen Intentionen von Fußgängergruppen zu simulieren, arbeitet das Potentialfeldmodell außerdem mit Navigations- oder Leitfeldern. Aufgrund der strengen Strukturierung von zellulären Automaten können höhere Fußgängerdichten oder nicht vollständig zellfüllende Hindernisse zu einer geringeren Abbildung der Realität führen [22]. Um solche Probleme zu überwinden, berücksichtigen hybride Modelle verschiedene Modellierungsansätze für bestimmte Bereiche oder Regionen, die ein einzigartiges Verhalten hervorrufen [23]. Ein weiterer bekannter Ansatz ist das Optimal Steps Model (OSM). Anstatt das Modell nur auf dichte Menschenmengen oder ein starres räumliches Gitter zu beschränken, nutzen die Autoren von [24] einen kontinuierlichen Raum und befreien die Agenten von einer strikten Zellrepräsentation, während sie die schrittweise Bewegung in einer diskretisierten Weise beibehalten.

---

---

## 2.3 Bahnhöfe und Menschengruppendynamik

Was Wartebereiche in Bahnhöfen betrifft, so neigen Fußgänger dazu, sich gleichmäßig über die jeweiligen Flächen zu verteilen [15]. Darüber hinaus haben Beobachtungen gezeigt, dass wartende Fußgänger einen erheblichen Einfluss auf die Dynamik von Menschengruppen in Bahnhöfen haben können. So kann sich die Gehzeit der ankommenden Zugpassagiere um bis zu 20% erhöhen, wobei der Bahnsteig sowohl durch wartende Fußgänger als auch durch ungünstig positionierte Anziehungspunkte beeinflusst wird [25].

Bei näherer Betrachtung verschiedener Bauelemente untersuchten [26], den Einfluss von Zäunen und Säulen als Trennmodule in belebten Bereichen, insbesondere in Bahnhöfen. Sie weisen darauf hin, dass sich der Fußgängerfluss für nicht unidirektionale Bewegungen erhöht, wenn Pfeiler anstelle anderer oder gar keiner Module verwendet werden. Ebenso konnte ein ähnliches Verhalten von [27] untersucht werden, die eine Verbesserung der Evakuierungszeit für Ausgangsbereiche mit Säulen in deren Nähe aufzeigten.

## 2.4 Deep Learning Methoden

In den vorangegangenen Abschnitten konnte die Komplexität des Fußgängerverhaltens und der daraus resultierenden Simulationsmodelle hervorgehoben werden. Folglich führen Fußgängersimulationen für komplexe Gebäudestrukturen zu einem erheblichen Anstieg der Rechenzeit. Um die Rechenzeit zu reduzieren, werden in der Forschung zunehmend Methoden der künstlichen Intelligenz (KI) berücksichtigt. Ansätze des maschinellen Lernens (ML) als eine spezifische Kategorie von KI-Methoden erlauben es, zeitaufwändige Simulationen durch prädiktive Methoden zu ersetzen. Das Konzept ist auch als Finden und Anwenden einer Ersatzfunktion (Surrogate Function) bekannt. DL-Methoden wurden populär, um mit komplexen Problemen und unterschiedlichen Datentypen umzugehen. Verschiedene Architekturen von Künstlichen Neuronen Netzen (NN) erzielten unterschiedliche Erfolgsquoten bei der Bewältigung verschiedener Aufgaben, wie z. B. der Erkennung und Segmentierung von Objekten in Bildern oder der Verarbeitung natürlicher Sprache. Als grundlegendes Feedforward-NN wird üblicherweise das Multilayer Perceptron (MLP) für verschiedene Problemstellungen eingesetzt. Hier werden Einzelwerte in verbundenen Rechenknoten, die in (versteckten) Schichten organisiert sind, gespeichert und in eine Richtung verarbeitet. Die Wahl der Anzahl der Schichten ist ein entscheidender Bestandteil, um ein individuelles NN zu erstellen, das für die Lösung einer bestimmten Aufgabe geeignet ist. Das Prinzip des Netzes besteht darin, eine gegebene Eingabe auf die gewünschte Ausgabe, d. h. ein klassifiziertes Label, abzubilden. Während des Netzwerktrainings optimiert ein Backpropagation-Algorithmus die Netzparameter und damit die Genauigkeit der Netzausgabe [28].

Um mit Bildern in Form von Matrizen besser umgehen zu können, haben Convolutional Neural Networks (CNNs) einen bemerkenswerten Erfolg erzielt. Diese Art von Feedforward-NN besteht aus mehreren Schichten, von denen jede eine Reihe von Berechnungen durchführt. Zunächst wendet ein Kernel eine Faltungsoperation (Convolution) auf die Eingabematrix an, die zu einer so genannten Feature Map führt. Hierbei kann der Kernel mit einem Filter verglichen werden, wobei verschiedene Kernel mehrere Feature-Maps parallel innerhalb einer Schicht berechnen können, was ein Feature-Set ergibt. Als nächstes wird eine nichtlineare Aktivierungsfunktion wie die Rectified Linear Unit (ReLU)-Funktion auf jedes Feature-Map-Element angewendet. In einem letzten Schritt können die Matrixdimensionen durch eine Pooling-Operation, bekannt als Down-Sampling, reduziert werden, z. B. durch Maximum Pooling. Diese Modifikation senkt den Rechenaufwand der nachfolgenden Schicht. Darüber hinaus können CNNs Muster (Features) innerhalb eines gegebenen Datensatzes herauspicken und auch erkennen [29].

Um ein neuronales Netz zu trainieren, wird eine ausreichende Menge an Daten benötigt. Außerdem können Optimierungstechniken den Trainingsprozess des Netzwerks verbessern. Die Bereitstellung weniger Daten kann zu einer Unteranpassung (Underfitting) führen, während es zu einer Überanpassung (Overfitting) kommen kann, wenn dieselben Trainingsdaten zu oft verwendet werden und sich das Netz daher intensiv auf diese spezifischen Beispiele konzentriert. Overfitting ist der Grund, warum Regularisierungsmethoden wie das Dropout die Berechnungen des Netzes verbessern können, indem einfach die aktivierten Knoten fast zufällig variiert werden. Auf diese Weise wird eine erzwungene Unsicherheit in das Modell eingebracht, und Koadaptionen können verhindert und damit Overfitting reduziert werden [30].

Die Batch-Normalisierung wurde als nützlich entdeckt, um den Trainingsprozess eines Netzwerks zu stärken [31]. Die Eingabewerte jeder Schicht werden normalisiert, bevor sie an die entsprechende Aktivierungsfunktion in den folgenden Rechenknoten weitergegeben werden. Folglich wird der als Kovariatenverschiebung bekannte Nachteil verringert und tiefgehende Abhängigkeiten zwischen mehreren Schichten werden entspannt. Außerdem kann der Bedarf an Regularisierungsmethoden wie Dropout in einem Netzwerk durch die Integration von Batch-Normalisierung reduziert werden [32].

CNNs sind ein spezielles ML-Verfahren, das besonders für Anwendungen in der Bildanalyse zugeschnitten ist. So sind CNNs beispielsweise in der Lage, Zellpartikel zu erkennen und von Nicht-Zellpartikeln zu unterscheiden [33]. In [34], wird ein ML-Ansatz vorgestellt, der die Optimierung und Leistung sowie die Flusskontrolle von Berechnungen in der Fluidynamik verbessert. Ein weiteres Beispiel ist ein ML-Komponenten-basierter Ansatz, der die Schätzung der Heiz- und Kühlenergie eines Gebäudes unterstützt [35]. Darüber hinaus geben die Autoren als zusätzlichen Nutzen an, das Verständnis komplexer Energieberechnungen für bestimmte Parameter zu verbessern.

---

## 3 Methodik

Die Hypothese dieser Arbeit ist, dass DL-Methoden die Beziehung zwischen Gebäudeinformationen und Simulationsergebnissen verstehen können, wodurch es möglich wird, Simulationen durch Echtzeitvorhersagen zu ersetzen. Um dies zu erreichen, müssen zwei Hauptaspekte identifiziert werden: (1) Wie können die geometrischen und semantischen Informationen des Entwurfs dargestellt werden? (2) Welche Art von Simulationsergebnissen versuchen wir vorherzusagen? Die Antworten auf diese Fragen haben einen großen Einfluss darauf, welche Architektur für das neuronale Netz geeignet ist, einschließlich der Frage, welche Operationen auf die verschiedenen Schichten angewendet werden müssen.

Da diese Arbeit darauf abzielt, Simulationsergebnisse zu ersetzen, wird ein Framework für eine automatische Generierung eines Trainingsdatensatzes sowie die Vorhersage der Simulationsergebnisse direkt aus der BIM-Darstellung und den Simulationsparametern vorgeschlagen. Als Teil des in Abbildung 1 dargestellten Workflows wurde ein parametrisches Modell entwickelt, das in der Lage ist, eine

---

Vielzahl von Bahnhofsmodellen zu generieren. Die Bahnhofsmodelle enthalten zusätzliche Parameter, die für die Durchführung der Fußgängersimulation erforderlich sind. Anschließend wird jedes BIM-Modell in IFC exportiert, wo die Geometrie und Semantik verarbeitet werden, um eine Simulationsprojektdatei zu erzeugen.

In dieser Arbeit generieren wir Projektdateien, die die gleiche Struktur wie die des Personenstromsimulators Crowd:it2 aufweisen. Crowd:it verwendet das OSM [24] zur Simulation des Fußgängerverhaltens. Da die Simulationsparameter bereits im BIM-Modell enthalten sind, kann die Simulation anschließend automatisch und ohne manuelle Eingriffe ablaufen. Sobald die Simulation abgeschlossen ist, werden die Ergebnisse nachbearbeitet, um Dichte-Wärmekarten (Heatmaps), Pfadspuren (Tracing Maps) und Evakuierungszeiten zu erstellen. Dieser Prozess wird automatisch für die unterschiedlichen Entwurfsvarianten wiederholt, die aus dem parametrischen Modell generiert werden. Der generierte Datensatz aus BIM-Modellen und Simulationsergebnissen wird dann zum Trainieren eines neuronalen Netzes verwendet.

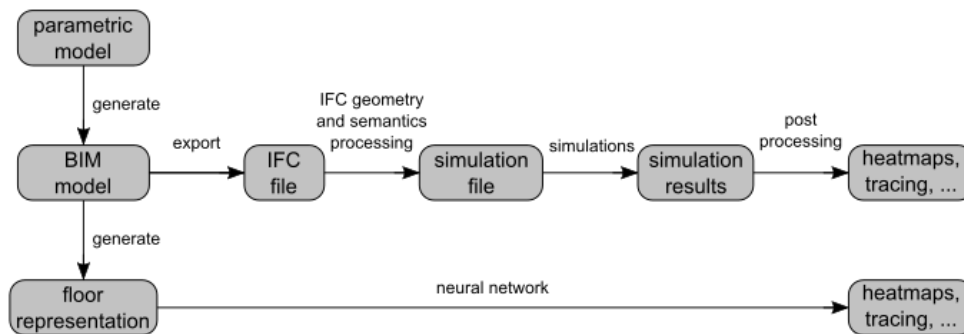


Abbildung 1: Workflow - konventioneller Weg vs. DL-Ansatz

### 3.1 Parametrisches Modell

Wir haben ein parametrisches Modell entwickelt, das einen einfachen Zugriff auf verschiedene Modellparameter zur Variation in den Bahnhofsmodellen ermöglicht, dargestellt in Abbildung . Nun können geometrische Parameter wie die Länge des Bahnhofs, die Breite des Bahnsteigs oder die Anzahl der Rolltreppen im BIM-Modell ohne großen Aufwand angepasst werden. Generell ist die Anzahl der verfügbaren Datensätze entscheidend für das Training eines neuronalen Netzes. In unserem ersten Versuch haben wir insgesamt 432 Variationen von generischen Bahnhöfen erstellt. Die entsprechenden Variationsparameter sind in Tabelle 1 aufgeführt.

Tabelle 12: Parameterwerte für eine generische Bahnhofsvariante

Abkürzung	Bedeutung	Variationen
F	Anzahl der Etagen	2
T	Abstand zwischen den Gleisen	15, 25
W	Anzahl der Spuren	2, 3, 4, 5
L	Länge der Station	150, 200, 250, 300
H	Bodenhöhe	15, 25
E	Anzahl der Rolltreppen	1, 2, 3
P	Anzahl der Agenten (pro Reisebus)	5, 20, 50

Zusätzlich zu den Variationen müssen für die verschiedenen Objekte innerhalb jedes Bahnhofs spezifische semantische Informationen festgelegt werden, um eine automatische Verarbeitung des Modells durch die Personenstromsimulationssoftware zu gewährleisten. Insbesondere müssen spezielle Zonen im Modell markiert werden, die z. B. die Startbereiche und das Ziel der Agenten kennzeichnen. Darüber hinaus muss auch die Anzahl der Agenten und eine Zuordnung der Objekttypen zu den Simulationsobjekttypen festgelegt werden. Abbildung zeigt ein Beispiel für einen parametrischen Bahnsteig mit vier Gleissträngen, drei Rolltreppen an jeder Seite, einem Aufzugskasten in der Mitte und zwei Säulen zwischen den Gleissträngen. Solche Gebäudeelemente werden im Fußgängersimulator in Begrenzungen übersetzt.

<sup>2</sup> <https://www.accu-rate.de/en/software-crowd-it-en/>

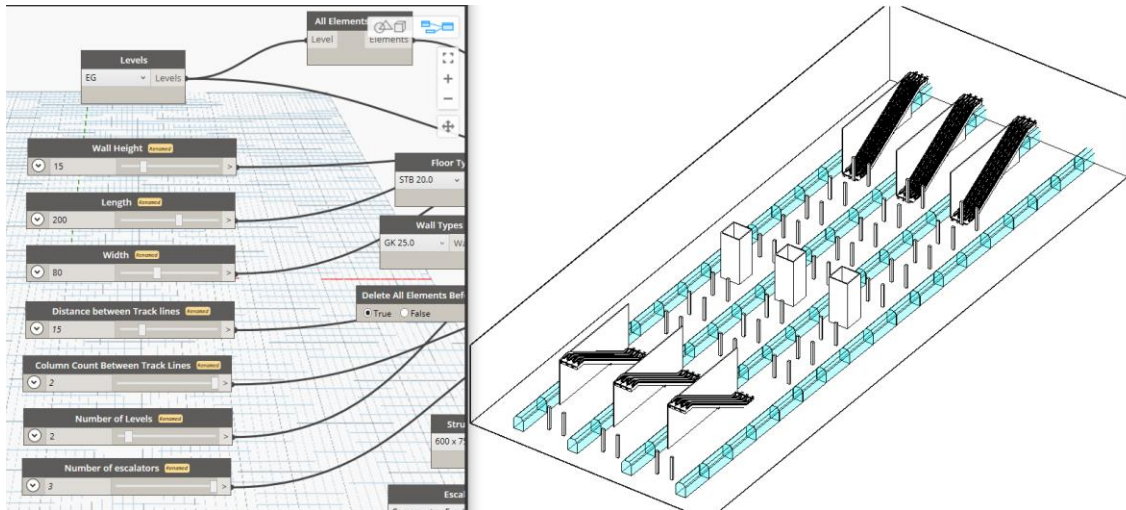


Abbildung 2: Werkzeug zum Variieren von Parametern (l.), die einen generischen Bahnhof erzeugen (r.)

Das verwendete Toolset zur Entwicklung dieses parametrischen Modells sind Autodesk Revit<sup>3</sup> und Dynamo<sup>4</sup>. In diesem Zusammenhang wurden<sup>5</sup> die RIL-Richtlinien der Deutschen Bahn untersucht und in logischen Code umgewandelt, der in den Dynamo-Graphen eingebettet ist. Ein solches parametrisches Modell ermöglicht einen adaptiven Bahnhofsentwurf, bei dem sich die Änderung eines Parameters automatisch auf die anderen Parameter auswirkt und den Bahnhofsentwurf neu generiert. Für die Zwecke dieser Arbeit wurden, wie in Tabelle 1 gezeigt, alle Modelle mit nur zwei Stockwerken erstellt. Die Szenarien, mit denen wir experimentieren, gehen davon aus, dass die Fußgänger den Bahnhof über die Zugwaggons betreten und in die obere Etage gehen. Die Fußgänger wählen die Rolltreppen als Übergangsbereiche, um direkt nach dem Ende jeder Rolltreppe die Zielzone in der nächsten Etage zu erreichen. In jedem Simulationslauf werden die Wege der Fußgänger nach der internen Logik des Simulators gewählt. Jede Simulation wird beendet, sobald der letzte Agent die Zielzone erreicht hat.

### 3.2 Etagedarstellung und Neuronales Netzwerk

Um eine verständliche Darstellung der verschiedenen Objekttypen für das Training eines neuronalen Netzes zu erhalten, schlagen wir die Kombination eines farblich markierten Grundrisses und eines Vektors von Metadaten (dargestellt durch Variationsparameter in Tabelle 1) vor. So werden z. B. Start-Zonen rosa markiert, während begehbare Bereiche weiß eingefärbt werden, siehe Abbildung . Als entsprechende Ausgabe verarbeitet der Simulator crowd:it die Simulationsergebnisse nach und erzeugt Heatmaps der mittleren Dichte (d. h. Durchschnitt der Agenten pro Gebiet) und Tracing Maps entsprechend der von den Agenten gewählten Routen. Abbildung zeigt ein Beispiel für eine generierte Heatmap, in der die mittleren Dichten blau eingefärbt sind, je dunkler die Farbe, desto höher die mittlere Dichte (hellere Zonenfarbe bei Start-Zonen). Die Spuren der Agenten in oranger Farbe sind rechts in Abbildung sehen.



Abbildung 3: Grundrissdarstellung mit Farbgebung




Abbildung 4: Heatmap (l.) und Tracing Map (r.) Beispiele mit 5 Agenten pro Zugwaggon

<sup>3</sup> <https://www.autodesk.com/products/revit/overview?term=1-YEAR>

<sup>4</sup> <https://www.autodesk.com/products/dynamo-studio/overview>

<sup>5</sup> <https://www1.deutschebahn.com/sus-infoplattform/start/regelwerk>



## 4 Neuronales Netzwerk - Architektur

Obwohl viele verschiedene Ansätze zur Anwendung von ML in diesem Kontext denkbar sind, liegt der Fokus in dieser Arbeit darauf, eine Bildrepräsentation als Eingabe zu verwenden und ein Bild mit Dichten und Spuren als Ausgabe vorherzusagen. Daher bauen wir auf der Architektur vom U-Net [36] auf, einem vollständig faltbaren Netzwerk, bei dem Pooling-Operatoren durch Upsampling-Operatoren ersetzt werden, was die Trainingsleistung und die Auflösung der Ausgabe verbessert. Zusätzlich implementiert das U-Net Skip-Verbindungen zwischen den Schichten und kombiniert diese dann mit einer Verkettungsschicht.

Unsere Implementierung erweitert die U-Net-Architektur um eine zusätzliche Eingabeschicht für die Metadaten, die die Stationsabmessungen und die Parameter der Fußgängersimulation enthält. In diesem Zusammenhang sollte die Platzierung der Metadaten-Eingabeschicht sorgfältig vorgenommen werden, um das Problem des verschwindenden Gradienten [37] zu vermeiden. Wir optimieren unser Netzwerk mit Minibatch-SGD und wenden den Adam-Solver [38] an, mit einer Lernrate von 0,002 und den Impulsparametern  $\beta_1 = 0,5$ ,  $\beta_2 = 0,999$ , gemäß den Empfehlungen von [39]. Zur Inferenzzeit wenden wir Dropout und Batch-Normalisierung an [32]. Abbildung zeigt die Netzwerkarchitektur. Das NN erwartet Bilder mit einer Auflösung von  $1024 * 1024$  und erzeugt Bilder mit der gleichen Größe. Dazwischen gibt es eine Reihe von Downsampling- und Upsampling-Operationen, die die verschiedenen Merkmale aus dem Bild extrahieren. In der Mitte, direkt nach der Verkleinerung des Bildes, wird die zweite Eingabe der Metadaten bereitgestellt und mit den extrahierten Merkmalen verkettet. Die Linien zwischen den Abtastvorgängen zeigen auf die verketteten Merkmale, die von jeder Seite übergeben werden.




Abbildung 2: Architektur des neuronalen Netzes

## 5 Neuronales Netzwerk - Ergebnisse & Auswertung

Der Trainingsprozess begann mit der Aufteilung des Datensatzes in Trainings- und Testdaten. Die Größe des Datensatzes beträgt 432 Projekte mit ihren Simulationsergebnissen, wobei 20% (87 Projekte) zum Testen verwendet wurden. Vor dem Start des Trainingsprozesses haben wir eine Datenerweiterung vorgenommen, einschließlich Größenänderung, Zuschneiden und Drehen, um die Menge der Trainingsdaten auf 690 Projekte zu verdoppeln. Um die Modelleleistung während des Trainings sicherzustellen, wurden in jeder Epoche 20% der Trainingsdaten zur Validierung verwendet. Das Training verwendete eine Stapelgröße von vier und lief über 300 Epochen. Als Verlustfunktion zur Quantifizierung der Qualität der vorhergesagten Heatmaps und Spuren im Vergleich zur Ground Truth während des Trainings und der Validierung wurde der mittlere absolute Fehler (MAE) pro Pixel verwendet [40].

Abbildung 3 zeigt den MAE pro Pixel sowohl für die Trainings- als auch für die Validierungsdatsätze für das Training zur Erzeugung von Bildern mit Heatmaps. In dieser Hinsicht wurde der Fehler auf beiden Sets relativ schnell (nach wenigen Epochen) kleiner als 0,05. Aus unseren Beobachtungen während des Trainings konnten wir feststellen, dass ab Epoche 20 die vorhergesagten Bilder anfangen, Heatmaps über der richtigen Position zu generieren, die Dichte dieser Heatmaps war jedoch gering. In Epoche 300 wurde die Dichte der generierten Heatmaps ziemlich vergleichbar mit der Ground Truth durch das menschliche Auge. Dies unterstreicht die Notwendigkeit der menschlichen Wahrnehmung zusätzlich zum MAE pro Pixel, um die Qualität der Vorhersagen zu identifizieren.




Abbildung 3: Heatmap - MAE pro Pixel

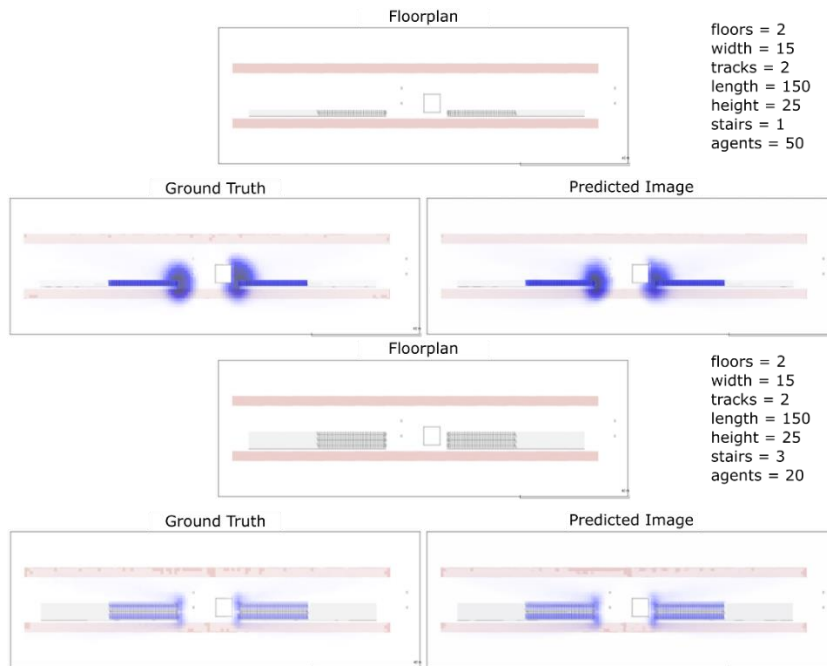


Abbildung 4: Heatmap - Ergebnisse Fall 1 (o.) und Fall 2 (u.)

Die Vorhersage von Bildern aus dem Testset ist in Abbildung dargestellt, wobei der Eingabegrundriss und die Metadaten, die Ground Truth und das vorhergesagte Bild verglichen werden. Das vorhergesagte Bild im ersten Fall hat eine ähnliche Gesamtverteilung, jedoch ist die Dichte am Anfang der rechten Treppe geringer als in der Ground Truth. Im zweiten Fall hat das vorhergesagte Bild eine etwas dichtere Heatmap als die Ground Truth. Anschließend wurde derselbe Prozess für das Training des Netzes auf Tracing Maps wiederholt, mit denselben Netzparametern und derselben Verlustfunktion. Da die Tracing Maps detaillierte Linien für die verschiedenen Fußgänger enthalten, ist der MAE pro Pixel höher als im Fall der Heatmaps (siehe Abbildung 5).

Die vorhergesagten Tracing Maps aus dem Testset sind in Abbildung dargestellt, wobei der Eingabegrundriss und die Metadaten, die Ground Truth und das vorhergesagte Bild verglichen werden. In beiden Fällen war das Netzwerk in der Lage, vernünftige Muster vorherzusagen, die nahe an der Ground Truth liegen. Allerdings weichen die Dichten, ähnlich wie bei den Heatmaps, ab.

Insgesamt war das Netzwerk in der Lage, die Beziehung zwischen der Eingabe (Grundriss + Metadaten) und den Simulationsergebnissen (Heatmaps und Tracing Maps) zu verstehen. Dies zeigt sich durch die Vorhersage unterschiedlicher Ergebnisse für verschiedene Treppenbreiten und Anzahl der Fußgänger. Wie in den Verlustzahlen für Training und Validierung gezeigt wird, hat eine Vergrößerung des Datensatzes jedoch ein hohes Potenzial zur Verbesserung der Ergebnisse. Zusätzlich könnte eine andere Verlustfunktion als der MAE pro Pixel eine vernünftige Bewertung der Qualität der vorhergesagten Bilder liefern.




Abbildung 5: Tracing Map - MAE pro Pixel

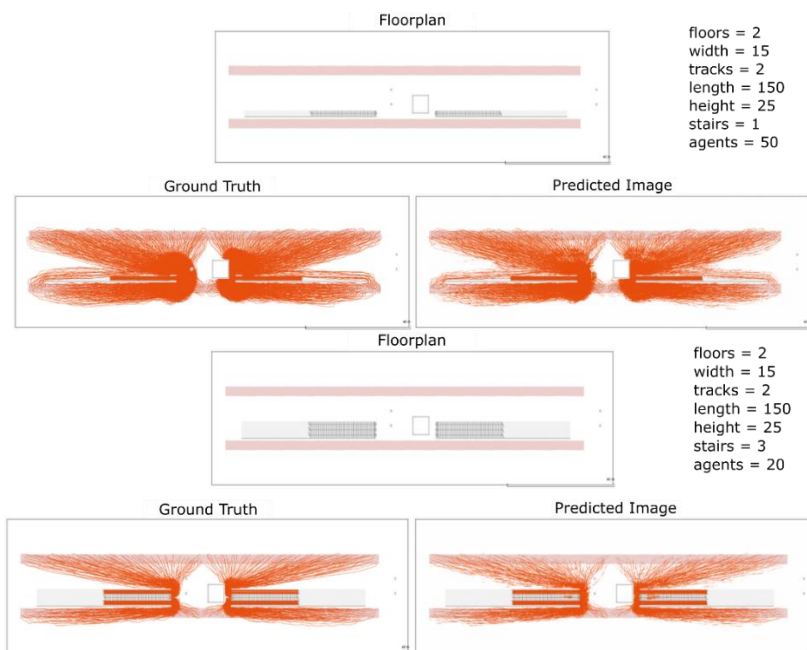


Abbildung 6: Tracing Map - Ergebnisse Fall 1 (o.) und Fall 2 (u.)

## 6 Schlussfolgerung und zukünftige Arbeit

In diesem und einem weiteren Beitrag [41] haben wir erste Ergebnisse vorgestellt, die für eine gegebene Bahnhofsgometrie Echtzeit-Ergebnisse zum Fußgängerverhalten liefern. Herkömmliche Fußgängersimulationen können leicht sehr teuer hinsichtlich der Berechnungszeit werden. In unserem Ansatz, ein CNN mit Bilddaten des BIM-Modells zu trainieren, haben wir einen ersten Blick auf praktische Ergebnisse zur Vorhersage von mittleren Dichten von Fußgängern und deren Laufwege geworfen. Der Ansatz zeigt vielversprechende Ergebnisse und soll weiter untersucht werden. In erster Linie sehen wir deutlich die Möglichkeit, komplexere Daten zu verwenden. Das heißt, dass generische Bahnhöfe ähnliche und eher einfache geometrische Informationen liefern. Dies hat zur Folge, dass bemerkenswerte Änderungen im Design vom Netzwerk möglicherweise nicht berücksichtigt oder verstanden werden. Verbesserungen innerhalb eines prädiktiven Werkzeugs für das Fußgängerverhalten, wie es in diesem Beitrag vorgestellt wird, können zu einer einfach zugänglichen Bewertung von Engpässen führen, die durch eine noch im Entwurf befindliche Gebäudeumgebung verursacht werden. So kann eine optimale Entwurfslösung mit weniger Rechenaufwand und merklichen Einsparungen bei der Projektzeit entwickelt werden.

## 7 Danksagung

Wir bedanken uns bei mFUND - Bundesministerium für Verkehr und digitale Infrastruktur (BMVI) für die Förderung des Forschungsprojekts BEYOND.

## 8 Referenzen

- [1] A. Borrmann, M. König, C. Koch, and J. Beetz, Eds., *Building Information Modeling*. Cham: Springer International Publishing, 2018.
- [2] V. Knotten, F. Svalestuen, G. K. Hansen, and O. Lædre, "Design management in the building process - a review of current literature," *Procedia Econ. Financ.*, vol. 21, pp. 120–127, 2015.
- [3] J. Abualdenien and A. Borrmann, "A meta-model approach for formal specification and consistent management of multi-LOD building models," *Adv. Eng. Informatics*, vol. 40, pp. 135–153, Apr. 2019, doi: 10.1016/j.aei.2019.04.003.
- [4] J. Abualdenien *et al.*, "Consistent management and evaluation of building models in the early design stages," *J. Inf. Technol. Constr.*, vol. 25, pp. 212–232, 2020, doi: 10.36680/j.itcon.2020.013.
- [5] F. Mirahadi, B. McCabe, and A. Shahi, "IFC-centric performance-based evaluation of building evacuations using fire dynamics simulation and agent-based modeling," *Autom. Constr.*, vol. 101, pp. 1–16, May 2019, doi: 10.1016/j.autcon.2019.01.007.
- [6] D. J. Low, "Following the crowd," *Nature*, vol. 407, no. 6803, pp. 465–466, Sep. 2000, doi: 10.1038/35035192.



- 
- [7] A. Andriamamonjy, D. Saelens, and R. Klein, "An automated IFC-based workflow for building energy performance simulation with Modelica," *Autom. Constr.*, vol. 91, pp. 166–181, Jul. 2018, doi: 10.1016/j.autcon.2018.03.019.
- [8] J. Kim, J. Moon, E. Hwang, and P. Kang, "Recurrent inception convolution neural network for multi short-term load forecasting," *Energy Build.*, vol. 194, no. 2019, pp. 328–341, 2019, doi: 10.1016/j.enbuild.2019.04.034.
- [9] S. Mehrbod, S. Staub-French, and M. Tory, "BIM-based building design coordination: processes, bottlenecks, and considerations," *Can. J. Civ. Eng.*, vol. 47, no. 1, pp. 25–36, Jan. 2020, doi: 10.1139/cjce-2018-0287.
- [10] T. Østergård, R. L. Jensen, and S. E. Maagaard, "Building simulations supporting decision making in early design – A review," *Renew. Sustain. Energy Rev.*, vol. 61, pp. 187–201, Aug. 2016, doi: 10.1016/j.rser.2016.03.045.
- [11] M. Röck, A. Hollberg, G. Habert, and A. Passer, "LCA and BIM: Visualization of environmental potentials in building construction at early design stages," *Build. Environ.*, vol. 140, pp. 153–161, Aug. 2018, doi: 10.1016/j.buildenv.2018.05.006.
- [12] T. Hamidavi, S. Abrishami, and M. R. Hosseini, "Towards intelligent structural design of buildings: A BIM-based solution," *J. Build. Eng.*, vol. 32, p. 101685, Nov. 2020, doi: 10.1016/j.jobe.2020.101685.
- [13] G. G. Løvås, "Modeling and simulation of pedestrian traffic flow," *Transp. Res. Part B Methodol.*, vol. 28, no. 6, pp. 429–443, Dec. 1994, doi: 10.1016/0191-2615(94)90013-2.
- [14] A. Hanisch, J. Tolujew, K. Richter, and T. Schulze, "Online simulation of pedestrian flow in public buildings," in *Proceedings of the 2003 International Conference on Machine Learning and Cybernetics (IEEE Cat. No.03EX693)*, 2003, pp. 1635–1641, doi: 10.1109/WSC.2003.1261613.
- [15] D. Helbing, P. Molnár, I. J. Farkas, and K. Bolay, "Self-organizing pedestrian movement," *Environ. Plan. B Plan. Des.*, vol. 28, no. 3, pp. 361–383, 2001, doi: 10.1068/b2697.
- [16] D. Helbing, L. Buzna, A. Johansson, and T. Werner, "Self-organized pedestrian crowd dynamics: Experiments, simulations, and design solutions," *Transp. Sci.*, vol. 39, no. 1, pp. 1–24, 2005, doi: 10.1287/trsc.1040.0108.
- [17] S. Yi, H. Li, and X. Wang, "Understanding pedestrian behaviors from stationary crowd groups," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Jun. 2015, pp. 3488–3496, doi: 10.1109/CVPR.2015.7298971.
- [18] K. Ijaz, S. Sohail, and S. Hashish, "A Survey of Latest Approaches for Crowd Simulation and Modeling using Hybrid Techniques," *17th UKSIM-AMSS Int. Conf. Model. Simul.*, pp. 111–116, 2015, doi: 10.1109/UKSim.2015.46.
- [19] S. Yang, T. Li, X. Gong, B. Peng, and J. Hu, "A review on crowd simulation and modeling," *Graph. Models*, vol. 111, no. October 2019, p. 101081, 2020, doi: 10.1016/j.gmod.2020.101081.
- [20] D. Helbing, I. Farkas, and T. Vicsek, "Simulating dynamical features of escape panic," *Nature*, vol. 407, no. 6803, pp. 487–490, 2000, doi: 10.1038/35035023.
- [21] R. L. Hughes, "A continuum theory for the flow of pedestrians," *Transp. Res. Part B Methodol.*, vol. 36, no. 6, pp. 507–535, 2002, doi: 10.1016/S0191-2615(01)00015-7.
- [22] D. H. Biedermann *et al.*, "A Hybrid and Multiscale Approach to Model and Simulate Mobility in the Context of Public Events," *Transp. Res. Procedia*, vol. 19, pp. 350–363, 2016, doi: 10.1016/j.trpro.2016.12.094.
- [23] D. H. Biedermann, J. Clever, and A. Borrmann, "A generic and density-sensitive method for multi-scale pedestrian dynamics," *Autom. Constr.*, vol. 122, p. 103489, Feb. 2021, doi: 10.1016/j.autcon.2020.103489.
- [24] M. J. Seitz and G. Köster, "Natural discretization of pedestrian movement in continuous space," *Phys. Rev. E*, vol. 86, no. 4, p. 046108, Oct. 2012, doi: 10.1103/PhysRevE.86.046108.
- [25] M. Davidich, F. Geiss, H. G. Mayer, A. Pfaffinger, and C. Royer, "Waiting zones for realistic modelling of pedestrian dynamics: A case study using two major German railway stations as examples," *Transp. Res. Part C Emerg. Technol.*, vol. 37, pp. 210–222, Dec. 2013, doi: 10.1016/j.trc.2013.02.016.
- [26] J. Ma, S. M. Lo, W. G. Song, W. L. Wang, J. Zhang, and G. X. Liao, "Modeling pedestrian space in complex building for efficient pedestrian traffic simulation," *Autom. Constr.*, vol. 30, pp. 25–36, 2013, doi: 10.1016/j.autcon.2012.11.032.
- [27] G. A. Frank and C. O. Dorso, "Room evacuation in the presence of an obstacle," *Phys. A Stat. Mech. its Appl.*, vol. 390, no. 11, pp. 2135–2145, 2011, doi: 10.1016/j.physa.2011.01.015.
- [28] M. A. Nielsen, *Neural networks and deep learning*, vol. 2018. Determination press San Francisco, CA, 2015.
- [29] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
-

- 
- [30] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 56, pp. 1929–1958, 2014, [Online]. Available: <http://jmlr.org/papers/v15/srivastava14a.html>.
- [31] S. Santurkar, D. Tsipras, A. Ilyas, and A. Madry, "How Does Batch Normalization Help Optimization?," May 2018, [Online]. Available: <http://arxiv.org/abs/1805.11604>.
- [32] S. Ioffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," Feb. 2015, [Online]. Available: <http://arxiv.org/abs/1502.03167>.
- [33] K. Nishida and K. Hotta, "Robust cell particle detection to dense regions and subjective training samples based on prediction of particle center using convolutional neural network," *PLoS One*, vol. 13, no. 10, p. e0203646, Oct. 2018, doi: 10.1371/journal.pone.0203646.
- [34] S. L. Brunton, B. R. Noack, and P. Koumoutsakos, "Machine Learning for Fluid Mechanics," *Annu. Rev. Fluid Mech.*, vol. 52, no. 1, pp. 477–508, Jan. 2020, doi: 10.1146/annurev-fluid-010719-060214.
- [35] P. Geyer and S. Singaravel, "Component-based machine learning for performance prediction in building design," *Appl. Energy*, vol. 228, no. July, pp. 1439–1453, 2018, doi: 10.1016/j.apenergy.2018.07.011.
- [36] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," May 2015, [Online]. Available: <http://arxiv.org/abs/1505.04597>.
- [37] S. Hochreiter, "The vanishing gradient problem during learning recurrent neural nets and problem solutions," *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, vol. 6, no. 02, pp. 107–116, 1998.
- [38] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv Prepr. arXiv1412.6980*, 2014.
- [39] P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-image translation with conditional adversarial networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1125–1134.
- [40] D. Asamoah, E. Ofori, S. Opoku, and J. Danso, "Measuring the Performance of Image Contrast Enhancement Technique," *Int. J. Comput. Appl.*, vol. 181, no. 22, pp. 6–13, 2018.
- [41] J. Clever, J. Abualdenien, and A. Borrmann, "Deep learning approach for predicting pedestrian dynamics for transportation hubs in early design phases," 2021.
-