

BBSR-
Online-Publikation
121/2024

Neufert 4.0

Künstliche Intelligenz zur Erzeugung von Entwurfsheuristiken für den Wohnbau

von

Dr. Martin Bielik
Dr. Sven Schneider
Luyang Zhang
Dr. Milan Valášek
Ekaterina Fuchkina
Dr. Matthias Standfest



Neufert 4.0

Künstliche Intelligenz zur Erzeugung von Entwurfsheuristiken für den Wohnbau

Gefördert durch:



Bundesministerium
für Wohnen, Stadtentwicklung
und Bauwesen

aufgrund eines Beschlusses
des Deutschen Bundestages

ZUKUNFT BAU
FORSCHUNGSFÖRDERUNG

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

Aktenzeichen: 10.08.18.7-21.16

Projektlaufzeit: 04.2022 bis 11.2024

IMPRESSUM

Herausgeber

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

Fachbetreuer

Bundesinstitut für Bau-, Stadt- und Raumforschung
Referat WB 3 „Forschung und Innovation im Bauwesen“
Felix Lauffer
felix.lauffer@bbr.bund.de

Autorinnen und Autoren

Bauhaus-Universität Weimar
Informatik in der Architektur und Urbanistik
Dr. Sven Schneider (Projektleitung)
sven.schneider@uni-weimar.de

Dr. Martin Bielik
martin.bielik@uni-weimar.de

Luyang Zhang, M. Sc.
luyang.zhang@uni-weimar.de

Dr. Milan Valášek
milan.valasek@uni-weimar.de

Ekaterina Fuchkina
ekaterina.fuchkina@uni-weimar.de

Archilyse AG, Zürich
Dr. Matthias Standfest
ms@standfest.science

Redaktion

Bauhaus-Universität Weimar
Informatik in der Architektur und Urbanistik
Dr. Martin Bielik
Dr. Sven Schneider

Stand

November 2024

Gestaltung

Bauhaus-Universität Weimar
Informatik in der Architektur und Urbanistik
Dr. Martin Bielik
Dr. Sven Schneider

Bildnachweis

Titelbild: Luyang Zhang

Vervielfältigung

Alle Rechte vorbehalten

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

Zitierweise

Bielik, Martin; Schneider, Sven; Zhang, Luyang; Valášek, Milan; Fuchkina, Ekaterina; Standfest, Matthias, 2024: Neufert 4.0: Künstliche Intelligenz zur Erzeugung von Entwurfsheuristiken für den Wohnbau. BBSR-Online-Publikation 121/2024, Bonn.
<https://doi.org/10.58007/p2vc-gg64>

DOI 10.58007/p2vc-gg64

ISSN 1868-0097

Bonn 2024

Inhaltsverzeichnis

1	Kurzfassung.....	1
2	Einführung.....	3
2.1	Problemstellung	3
2.2	Ausgangslage	4
2.3	Ziel.....	5
2.4	Forschungsdesign	6
2.4.1	Forschungsfragen	6
2.4.2	Arbeitsablauf.....	7
2.4.3	Projektteam.....	8
3	Datenaufbereitung.....	9
3.1	Intro	9
3.2	Bereinigung des Datensatzes	11
3.2.1	Filtern des Datensatzes.....	11
3.2.2	Automatische Umrissgenerierung	15
3.2.3	Manuelle Korrektur der Umrisslinie.....	16
3.3	Geometrische Features der Umrisslinie.....	18
3.4	Merkmalsanalyse.....	21
4	Entwurfsheuristiken.....	30
4.1	Suche nach ähnlichen Grundrissen	30
4.1.1	Einführung.....	30
4.1.2	Datenrepräsentation und KI-Modell.....	30
4.1.3	Ergebnisse.....	32
4.2	Umrisspotential.....	34
4.2.1	Einführung.....	34
4.2.2	Datenrepräsentation.....	34
4.2.3	KI-Modell.....	34
4.2.4	Ergebnisse.....	35

4.3	Raumdiagramme	38
4.3.1	Einführung.....	38
4.3.2	KI-Modell.....	39
4.3.3	Datenaufbereitung.....	44
4.3.4	Ergebnisse.....	48
4.4	Grundrissgeometrie	50
4.4.1	Einführung.....	50
4.4.2	Datenrepräsentation.....	50
4.4.3	KI-Modell.....	51
4.4.4	Ergebnisse.....	53
5	Validierung	59
5.1	Webbasiertes User Interface „floorAI“	59
5.2	Workshops	62
5.2.1	Expertenmeetings.....	62
5.2.2	Anwendertest	63
6	Zusammenfassung & Ausblick	71
6.1	Zusammenfassung	71
6.2	Ausblick	72
	Literaturverzeichnis	73
	Anhang.....	75
	Publikationsliste.....	75
	Datenveröffentlichung.....	75

1 Kurzfassung

Im Projekt „Neufert 4.0“ werden innovative Methoden der Künstlichen Intelligenz adaptiert, um aus einer umfangreichen Datenbank bestehender Wohnungsgrundrisse Entwurfsheuristiken abzuleiten. Ziel ist es, Architekten und Planern Werkzeuge an die Hand zu geben, die die Gestaltung nutzungsgerechter Wohnbauten effizient unterstützen. Die Grundlage des Projekts bildet eine umfassende Sammlung von mehr als 35.000 Wohnungsgrundrissen. Diese Grundrisse enthalten nicht nur geometrische Daten, sondern auch detaillierte semantische Informationen zu den einzelnen Bauteilen, Raumarten sowie dem städtebaulichen Umfeld. Darüber hinaus sind nutzungsrelevante Aspekte wie Tageslicht, Sichtbeziehungen und Raumzusammenhänge hinterlegt.

Durch den Einsatz maschineller Lernverfahren werden in diesem Projekt Zusammenhänge zwischen der räumlichen Anordnung, dem städtebaulichen Kontext und nutzungsbezogenen Qualitäten identifiziert. Verschiedene Ansätze des maschinellen Lernens werden evaluiert, um herauszufinden, welche Methoden sich besonders gut zur Erzeugung von Entwurfsheuristiken eignen. Zusätzlich werden Visualisierungstechniken entwickelt, um diese komplexen Zusammenhänge auf eine für Architekten und andere Fachleute verständliche Weise darzustellen. Die Praxistauglichkeit der entwickelten Methoden wurde im Rahmen eines Workshops getestet, in dem die Verfahren in realen Entwurfsszenarien angewendet wurden.

Der Anwendungsfall konzentriert sich auf den Grundrissentwurf einer Wohnung, wobei der Wohnungsumriss und die Eingangstürposition als Input dienen. Vier Entwurfsheuristiken wurden hierfür entwickelt: Zunächst ermöglicht die **Suche nach ähnlichen Grundrissen**, in einer Datenbank nach ähnlichen Wohnungen zu suchen, um bewährte Raumkonzepte zu finden. Zweitens hilft das **Umrisspotential** dabei, die zu erwartenden Wohnqualitäten basierend auf dem Umriss zu bewerten und Optimierungspotenziale frühzeitig zu identifizieren. Drittens wird durch die **Erstellung von Raumdiagrammen** visualisiert, wo Räume sinnvoll positioniert werden können, um die an sie gestellten Anforderungen zu erfüllen. Abschließend unterstützt die **Erzeugung der Grundrissgeometrie** bei der konkreten Positionierung von Wänden, Türen und Fenstern.

Die im Projekt entwickelte Methodik bietet wertvolle Erkenntnisse über den Einsatz von Künstlicher Intelligenz im architektonischen Entwurfsprozess und eröffnet zugleich neue Perspektiven in der Wohnbauforschung.

Abstract

The "Neufert 4.0" project adapts innovative methods of artificial intelligence to derive design heuristics from an extensive database of existing apartment floor plans. The aim is to provide architects and planners with tools that efficiently support the design of residential buildings that are suitable for use. The basis of the project is a comprehensive collection of approx. 35,000 apartment floor plans. These floor plans contain not only geometric data, but also detailed semantic information on the individual components, room types and the urban environment. In addition, experience and use - related aspects such as daylight, visual relationships and spatial contexts are taken into account.

Through the use of machine learning methods, this project identifies relationships between the spatial configuration, the urban context and user-centered qualities. Different approaches to machine learning are evaluated to find out which methods are particularly suitable for generating design heuristics. In addition, visualization techniques are developed to present these complex relationships in a way that architects and other professionals can understand. The practicality of the developed methods was tested in workshops in which the methods were applied in real design scenarios.

The use case focuses on the floor plan design of an apartment, with the apartment outline and the entrance door position serving as input. Four design heuristics have been developed for this purpose: First, the **search for similar floor plans** makes it possible to search for similar boundary conditions in a database in order to find proven room concepts. Secondly, **outline affordance** allows to assess the most probable qualities that are achievable with the given outline. Thirdly, the **creation of room diagrams** visualises how rooms can be sensibly positioned in relation to each other in order to meet the requirements. Finally, the **generation of the floor plan geometry** supports the concrete positioning of walls, doors and windows.

The methodology developed in the project offers valuable insights into the use of artificial intelligence in the architectural design process and at the same time opens up new perspectives in housing research.

2 Einführung

2.1 Problemstellung

Der Entwurf von Wohnbauten ist eine komplexe Aufgabe, da zahlreiche Anforderungen zu erfüllen sind und gleichzeitig viele Stellschrauben existieren, welche diese Anforderungen beeinflussen. Trotz der langfristigen Auswirkungen, die die Entwurfsplanung für die gebaute Umwelt und die darin lebenden Menschen hat, werden zahlreiche Entscheidungen (insbesondere hinsichtlich nutzungsbezogener Kriterien) nach wie vor intuitiv getroffen. Neben dem Rückgriff auf die eigene Erfahrung werden dazu einerseits Beispielsammlungen [Heckmann & Schneider, 2011; Stamm-Teske, Fischer & Haag, 2011] genutzt, um nach Lösungsansätzen für ähnliche Problemstellungen zu suchen. Andererseits wird auf Regelwerke [Neufert et al., 2018] zurückgegriffen, um Orientierungswerte für die Dimensionierung und Lage von Bauteilen und Räumen zu erhalten. Bei Ersterem ergibt sich das Problem der Übertragbarkeit auf die eigene projektspezifische Problemstellung (z.B. anderer städtebaulicher Kontext, andere Nutzeranforderungen). Letztere sind häufig beschränkt auf einfache Richtwerte (z.B. Zimmerbreite, Ausrichtung der Räume). Komplexe Zusammenhänge (wie z.B. widersprüchliche Anforderungen oder Sonderfälle) sind nicht abgebildet.

Mittels digitaler Methoden lassen sich Grundrisse automatisiert analysieren und generieren. Dies birgt ein enormes Potential für die Lösung komplexer Entwurfsaufgaben, da eine große Anzahl an Varianten systematisch untersucht werden kann. Allerdings sind reale Entwurfsräume so groß, dass Generative Algorithmen, welche nicht auf die bloße Reproduzierung gängiger Typologien beschränkt sind, zum Großteil unbrauchbare Grundrisse erzeugen. Sowohl für manuelle als auch für automatisierte Entwurfsprozesse fehlt es an systematisiertem und leicht zugänglichem digitalem Grundrisswissen, um evidenzbasiert, flexibel und effizient Wohnungsgrundrisse zu generieren. Im Projekt Neufert 4.0 wurde versucht, solches Wissen aus einer großen Grundrissdatenbank aufbereiten und mittels Entwurfsheuristiken, welche an die jeweilige Problemstellung angepasst sind, darzustellen.

Grundlage des Projektes waren folgende Prämissen:

1. Entwurfsheuristiken sind ein wichtiges und einflussreiches Werkzeug im Entwurfsprozess [3]. Sie enthalten Angaben über die Dimensionierung und Platzierung von Bauteilen und Räumen zur Erreichung bestimmter Qualitäten (z.B. Helligkeit oder Möblierbarkeit von Räumen, Kosten- oder Energieeffizienz). Dadurch werden Entwurfsräume verkleinert, wodurch diese sich effizienter nach geeigneten Lösungen durchsuchen lassen.
2. Die Zusammenhänge zwischen Grundrissform, städtebaulichem Kontext und Wohnungsqualitäten sind in aller Regel sehr komplex und lassen sich nicht durch einfache Kennzahlen oder Formeln abbilden. Daher sind Standardsammlungen häufig nicht ausreichend, um für spezifische Problemstellungen passende Heuristiken zu liefern.
3. Aus Grundrissammlungen gebauter Beispiele lässt sich wertvolles Wissen für die Planung ableiten, da sie Lösungen für konkrete Problemstellungen (bestimmter städtebaulicher Kontext und bestimmte Anforderungen) darstellen. Mittels Beispielsammlungen (analog oder digital) lässt sich zwar nach ähnlichen Beispielen für die eigene Problemstellung suchen, die Ableitung von Entwurfsheuristiken geschieht jedoch intuitiv. Ein solches implizites Wissen ist allerdings

fehleranfällig [Hölscher & Dalton, 2016; Kahnemann, 2012] und nicht transparent, wodurch es für Dritte nur schwer zugänglich ist [Zeisel, 2006].

4. Aus einer großen Grundrissdatenbank mit detaillierten Informationen zur Grundrissgeometrie und zu Grundrissqualitäten lassen sich Entwurfsheuristiken automatisiert ableiten. Hierdurch ergibt sich einerseits der Vorteil der Objektivität. Andererseits lassen sich solche digitalisierten Entwurfsheuristiken schnell und flexibel für projektspezifische Problemstellungen kontextsensitiv erstellen (z.B. angepasst an die vorhandene Belichtungssituation in einem dichten städtebaulichen Kontext; an die geometrischen Beschränkungen eines Grundstücks/Gebäudeform oder an besondere Nutzerbedürfnisse).

2.2 Ausgangslage

Ausgangsbasis für das Projekt bildete die von unserem Praxispartner Archilyse AG zur Verfügung gestellte Datenbank mit 35.000 Wohnungsgrundrissen. Jeder dieser Grundrisse beinhaltet neben den geometrischen Daten semantische Informationen zu Bauteilen (z.B. tragende/nicht tragende Wand, Fenster, Tür, Versorgungskanal) und Räumen (z.B. Größe, Art der Nutzung). Jede der Wohnungen ist mit einem Geo-Tag versehen, wodurch die exakte Lage im städtischen Kontext ermittelt, und die Qualitäten des Wohnungsumfeldes analysiert werden können (z.B. Ausblick auf eine Gebäudewand oder einen Park). Für den Innenraum existieren detaillierte Analyseergebnisse zu Tageslicht, Sichtbarkeit und Wegebeziehungen. Somit lassen sich für jeden Grundriss wichtige nutzungsbezogene Wohnqualitäten bestimmen.

Methoden für das Suchen in Grundrissdatenbanken sind ein etabliertes Feld in der KI [Richter, 2011]. Besonders hervorzuheben sind dabei aktuellere Projekte, wie das DFG Projekt metis [Ahmed, 2013] zur skizzenbasierten Suche nach ähnlichen Raumzusammenhängen oder das auf Deep Neural Networks System DANIEL zur Suche nach ähnlichen Grundrissformen [Sharma et al., 2019].

Zur Erzeugung von Entwurfsheuristiken auf Basis von Grundrissammlungen existierten zur Antragstellung nur wenige Arbeiten. Merrell et al. [2010] trainieren Bayessche Netzwerke mit 120 Grundrissen und berechnen Wahrscheinlichkeiten für bestimmte Raumprogramme (so treten bspw. ab einer bestimmten Wohnungsgröße bestimmte Raumgrößen für Küche und Bad sowie bestimmte Nachbarschaftsbeziehungen zwischen den Räumen auf). Eisenstadt et al. [2019] nutzen Convolutional Neural Networks um Vorschläge für die Vervollständigung einer unvollständigen Topologie zu generieren. Chaillou [2019] nutzt Generative Adversarial Networks, um auf Basis von 700 existierenden Grundrissbildern Generierungsprinzipien zu identifizieren.

Während der Projektlaufzeit kamen im Zuge des KI-Booms einige weitere interessante Arbeiten dazu. So schlagen bspw. Zeng et al. [Zeng et al., 2024] eine multikonditionale zweistufige generative Methode vor, die auf einem rauschenden diffusionsprobabilistischen Modell (DDPM) basiert. Dieses Modell generiert zunächst ein Raumlayout, gefolgt von einem vollständigen Grundriss, der Wände, Fenster und Türen basierend auf dem Layout umfasst. Das Modell unterstützt mehrfach konditionierte Bilder als Eingabe, sodass Benutzer den Grundriss anhand bekannter Wohnungskonturkanten und Rauminformationen wie Typ, Größe und Position anpassen können. Dupty et al. [Dupty et al., 2024] entwickeln eine Generierungsmethode, die auf einem Faktordiagramm basiert, das ein Raumnachbarschaftsdiagramm und eine binäre Maske der Wohnungsgrenze verwendet, um die Koordinaten des Raumbegrenzungsrahmens zu

generieren, was zu einem Grundrissbild führt. Shabani et al. [Shabani et al., 2023] präsentieren das HouseDiffusion-Modell welches diskrete und kontinuierliche Rauschunterdrückungs-Diffusionsmodelle kombiniert, um präzise geometrische Vektorgrundrisse auf der Grundlage eines Blasendiagramms zu erstellen. Darüber hinaus haben Ploennigs et al. [Ploennigs et al., 2023] und Leng et al. [Leng et al., 2023] jeweils sprachgesteuerte Methoden zur Erstellung von Grundrissen entwickelt. Ploennigs et al. (2023) wandten ein Diffusionsmodell an, um Grundrisse auf der Grundlage von Beschreibungen in natürlicher Sprache zu generieren, die die Anzahl, Art, Größe und Beziehungen von Räumen angeben. Leng et al. entwickelten einen Datensatz namens Tell2Design (T2D), der über 80.000 Grundrisse und entsprechende Anweisungen in natürlicher Sprache enthält, die die Semantik (Art und Funktion), die geometrische (Form und Größe) und topologische (relative Positionen und Verbindungen zwischen Räumen) detailliert beschreiben. Sie schlugen auch ein Seq2Seq-Modell vor, das Informationen über Wohnungsgrenzen mit Anweisungen in natürlicher Sprache integriert, um Grundrisse zu erstellen.

2.3 Ziel

Ziel unseres Projektes war es, mit Methoden der künstlichen Intelligenz aus vorhandenen Wohnungsgrundrissen Entwurfsheuristiken abzuleiten, welche dabei helfen, effizient nutzungsgerechte Wohnbauten zu entwerfen. Auf Basis einer umfangreichen Wohnungsgrundrissdatenbank sollten Zusammenhänge zwischen Wohnungsgeometrie, städtebaulichem Kontext und nutzungsbezogenen Qualitäten identifiziert werden. Hierfür wurden verschiedene Methoden des maschinellen Lernens eingesetzt und auf ihre Geeignetheit für die Erzeugung von Entwurfsheuristiken getestet. Darüber hinaus wurden Visualisierungsmethoden entwickelt, um die gefundenen Zusammenhänge verständlich darzustellen. In Workshops mit Architekten wurden diese Methoden auf ihre Tauglichkeit beim Einsatz in konkreten Entwurfsituationen getestet.

Als Anwendungsfall haben wir uns auf den Grundrissentwurf einer Wohnung fokussiert. Die Inputparameter waren dabei der Umriss der Wohnung (mit Unterscheidung von Außenwänden und Wohnungstrennwänden) und die Position der Eingangstür. Für diesen Anwendungsfall haben wir Methoden für vier verschiedenen Entwurfsheuristiken entwickelt:

- 1) **Suche nach ähnlichen Grundrissen:** Die Datenbank wird nach Wohnungsgrundrissen durchsucht, die dem vorgegebenen Umriss möglichst ähnlich sind. Diese Heuristik hilft Planern, effizient auf bewährte Raumkonzepte zurückzugreifen, die den gegebenen Umriss optimal ausnutzen.
- 2) **Vorhersage der erwartbaren Wohnqualitäten:** Die zweite Methode zielt darauf ab, anhand des Umrisses und anderer Kontexteigenschaften die zu erwartenden Qualitäten der Wohnung zu bewerten. Durch die Vorhersage dieser Qualitäten können Planer bereits in der Entwurfsphase erkennen, wie gut die geplanten Räume den Nutzungsanforderungen gerecht werden. Diese Methode unterstützt somit die frühe Identifikation von Optimierungspotenzialen.
- 3) **Erstellung von Raumdiagrammen:** Diese Diagramme verdeutlichen, wie die einzelnen Räume zueinander positioniert werden können, um die Wohnungsanforderungen zu erfüllen. Planer können so erkennen, welche Raumbeziehungen sinnvoll sind und wo Anpassungen notwendig sein könnten, um eine optimale Raumaufteilung zu erreichen.
- 4) **Erzeugung der Grundrissgeometrie:** Diese vierte Methode bietet eine Unterstützung bei der Erzeugung der konkreten Grundrissgeometrie, also der Positionierung von Wänden, Türen und

Fenstern innerhalb des Umrisses. Diese Heuristik nutzt die Informationen aus den vorherigen Methoden und liefert Vorschläge, wie die Räume im Detail ausgeformt werden sollten, um den Anforderungen an Nutzungsqualität und funktionale Anordnung zu entsprechen.

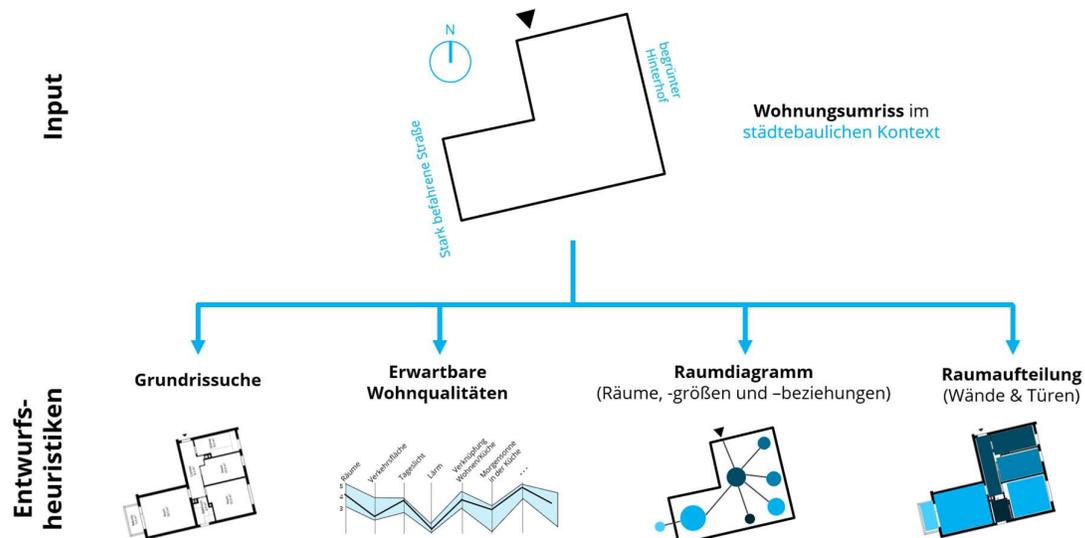


Abbildung 1: Überblick zu den im Projekt bearbeiteten Entwurfsheuristiken.

2.4 Forschungsdesign

2.4.1 Forschungsfragen

Die das Projekt leitenden Forschungsfragen beziehen sich auf methodische Aspekte der Datenrepräsentation, des maschinellen Lernens sowie der Inferenz und Visualisierung von Entwurfsheuristiken.

1. *Wie lassen sich multi-dimensionale Grundrissdaten für maschinelle Lernalgorithmen repräsentieren?*

Hier birgt der Datensatz zwei Herausforderungen: (1) sind die Daten über unterschiedliche Ebenen (städtebaulicher Kontext, Wohnung, Räume und Punktraster) verteilt, (2) existiert eine Vielzahl von Analysen, welche unterschieden werden können in lokale Analysen für jeden Raumpunkt (wie z.B. Menge an Tageslicht) und relationale Analysen (z.B. metrische/visuelle Distanz zwischen Räumen/Punkten/Kontext).

2. *Welche Modelle des maschinellen Lernens eignen sich für die automatisierte Extraktion von Entwurfsheuristiken?*

Es existieren zahlreiche Modelle, um Zusammenhänge zwischen Daten zu identifizieren. Da der vorhandene Datensatz sehr komplex ist, ist zu erwarten, dass unterschiedliche Modelle unterschiedlich gut geeignet sind, um bestimmte Zusammenhänge zu finden. Weiterhin stellt sich eine Herausforderung bei der Transferierbarkeit der gelernten Zusammenhänge auf neue Problemstellungen (z.B.: Lassen sich die Daten interpolieren um, z.B. eine Heuristik für eine nicht in der Datenbank vorhandene Geometrie zu erzeugen?) Schließlich ist zu prüfen, ob sich mittels eines rein datenbasierten Ansatzes tatsächlich sinnvolle Heuristiken ableiten lassen.

3. *Wie lassen Entwurfsheuristiken verständlich darstellen?*

Um die aus den Lernmodellen identifizierten Zusammenhänge für Planende zugänglich zu machen, sind Visualisierungen notwendig. Diese Visualisierungen müssen leicht verständlich und transparent sein. So sollte deutlich werden, warum welcher Zusammenhang existiert und welche Unsicherheiten es bei der Berechnung gibt.

2.4.2 Arbeitsablauf

Das Projekt gliederte sich ursprünglich in vier Arbeitspakete (AP 1 - 4). Mit Beginn der Arbeiten mit der Grundrissdatenbank wurde deutlich, dass der Aufbereitung der Daten große Aufmerksamkeit gewidmet werden muss (siehe 3). Da diese Datenaufbereitung einen großen zeitlichen Aufwand erforderte, haben wir sie im Bericht mit einem fünften Arbeitspaket (AP 0) aufgeführt.

- *AP 0: Datenaufbereitung*
Damit KI-Methoden effektiv arbeiten können, ist die Qualität der zugrundeliegenden Daten entscheidend. Daher wurde in diesem AP die Datenbank sorgfältig auf fehlerhafte Einträge geprüft und bereinigt.
- *AP 1: Datenrepräsentation*
In diesem AP wurden die Daten der Grundrissdatenbank für unterschiedliche Modelle des maschinellen Lernens aufbereitet. Hierbei mussten Ansätze für die Repräsentation der Verknüpfung der unterschiedlichen Ebenen (städtebaulicher Kontext, Wohnung, Räume, Punktraster) sowie der unterschiedlichen Analyseergebnisse (lokal, relational) entwickelt werden.
- *AP 2: Lernmodelle*
In diesem AP wurden verschiedene Methoden des maschinellen Lernens auf ihre Tauglichkeit zur Identifikation von planungsrelevanten Zusammenhängen im Datensatz geprüft. Hierzu erfolgte zunächst eine explorative Analyse mittels linearer Regressionsmodelle. Daraufhin werden die identifizierten Zusammenhänge klassifiziert und unterschiedliche Methoden ausgewählt und auf den Datensatz angewendet.
- *AP 3: Entwurfsheuristiken*
Dieses AP beschäftigte sich mit der Konzeption und Darstellung für die in AP 2 berechneten Zusammenhänge. Hierzu werden gängige Methoden, wie parallele Koordinatensysteme, Potenzialkarten und Graphen verwendet und für den konkrete Problemstellungen angepasst.
- *AP 4: Validierung*
Die entwickelten Methoden wurden in Workshops mit Planenden auf ihre Tauglichkeit in Entwurfsprozessen getestet. Hierzu wurde ein prototypischer Demonstrator entwickelt (webbasiertes Interface), mit Hilfe dessen sich Problemstellungen formulieren (Input) und Entwurfsheuristiken visualisieren (Output) lassen.

Im folgenden Ergebnisbericht werden die Arbeitspakete 1 – 3 aufgrund ihrer engen inhaltlichen Verknüpfung nicht in separaten Kapiteln beschrieben, sondern in Kapitel 4 jeweils zusammen für die jeweilige Entwurfsheuristik.

2.4.3 Projektteam

Das Projekt wurde am Lehrstuhl Informatik in der Architektur und Urbanistik (InfAU) durchgeführt. Der Lehrstuhl ist spezialisiert auf digitale Planung, nutzerzentrierte Gebäudebewertung und entwurfsspezifische Datenanalyse. Im Projekt haben folgende wissenschaftliche Mitarbeiter des Lehrstuhls mitgewirkt: Dr. Sven Schneider (Projektleitung), Dr. Martin Bielik, Iuliia Osintseva, Luyang Zhang, Dr. Milan Valášek und Ekaterina Fuchkina.

Unser Praxispartner Archilyse AG war ein in Zürich ansässiges Unternehmen, welches sich auf die Analyse von Wohnbauten spezialisiert hat. Für das Projekt hat Archilyse eine umfangreiche Datenbank mit Wohnungsgrundrissen, sowie Know-how und Personal für die Datenaufbereitung und Grundrissanalyse zur Verfügung gestellt.

3 Datenaufbereitung

3.1 Intro

Swiss Dwellings ist ein gross angelegter Open-Source-Datensatz von Schweizer Wohngebäuden, der von der Archilyse AG veröffentlicht wurde [Standfest et al., 2022]. Der Datensatz enthält detaillierte Informationen zu über 37.000 Wohnungen aus mehr als 3.100 Gebäuden. Es umfasst sowohl geometrische und semantische Daten zum Grundriss selbst als auch nutzungsrelevante Information zu Sichtbarkeit, natürliches Licht und Raumbeziehungen und bietet eine wertvolle Grundlage für die Forschung in Bereichen wie architektonischer Entwurf und räumliche Analyse.

Im Gegensatz zu anderen allgemein verfügbaren Datensätzen für architektonische Grundrisse hat Archilyse nicht nur eine größere Stichprobengröße, sondern deckt auch mehr Merkmale ab (>350) (Tabelle 1). Insbesondere speichert der Datensatz Vektorgeometrie im WKT-Format (Abbildung 2). Im Vergleich zu Rasterbildformaten bietet dieses Format Vorteile in Bezug auf Datengenauigkeit und Skalierbarkeit und unterstützt verschiedene räumliche Analysen und komplexe geometrische Berechnungen. Darüber hinaus bietet der Datensatz detaillierte Informationen zur Raumklassifizierung (z. B. Wohnzimmer, Küche, Bad) und Layoutmerkmale wie Raumfläche, Kompaktheit und Zentralität. Diese Informationen sind direkt auf die Analyse des architektonischen Layouts anwendbar und unterstützen Studien zur Nutzung und räumlichen Effizienz in Wohnräumen. Darüber hinaus enthält der Datensatz eine Fülle von Zusatzinformationen, die aus Simulationen und geografischen Analysen abgeleitet wurden. Dazu gehören Raumbeziehungen (wie weit entfernt liegen die verschiedenen Räume zueinander), Zentralität (welcher Raum ist am zugänglichsten bzw. entferntesten), Tageslichtsimulationen (Helligkeit der Räume zu verschiedenen Zeiten), sowie Analysen zum Ausblick (wieviel % Straße, Gebäude, Grün sieht man innerhalb der Wohnung) und Lärm (resultierend aus der Nähe der Zimmer zu unterschiedlich stark befahrenen Straßen). Diese Daten, die in anderen Grundrissdatenbanken selten verfügbar sind, bieten potentiell wertvolle Erkenntnisse für die Optimierung des Layoutentwurfs.

Tabelle 1: Übersicht über die Grundrisseigenschaften.

Layout	Room element	Connectivity	View	Noise	Sun light	
Shape	Layout connects to bathroom	Connectivity balcony	View buildings	View pedestrians	Window noise traffic	Spring equinox morning
Area basics / geometry	True if the area connects to a bathroom.	Shortest distance to the balcony. (m)	Visible buildings. (Steradian)	Visible pedestrians. (Steradian)	Car traffic noise received on the area's windows from daytime and night-time (dB(A))	Solar radiation received in the Spring Equinox morning [06:00-12:00]. (klx)
Door	Layout connects to private outdoor	Connectivity bathroom	View greenery	View primary streets	Window noise train	Spring equinox noon
Area doors	True if the area connects to an outside area that is private to the apartment.	Shortest distance to the bathroom. (m)	Visible greenery. (Steradian)	Visible primary_streets. (Steradian)	Noise received on the area's windows from daytime [06:00-22:00] and night-time [22:00-06:00] train traffic. (dB(A))	Solar radiation received in the Spring Equinox noon [12:00-16:00]. (klx)
Window	Layout has bathtub	Connectivity betweenness centrality	View ground	View railway tracks		Spring equinox evening
Area windows.	True if the area has a bathtub.	The Betweenness-Centrality value.	Visible ground. (Steradian)	The amount of visible railway_tracks. (Steradian)		Solar radiation received in the Spring Equinox evening [16:00-20:00]. (klx)
Room	Layout has entrance door	Connectivity closeness centrality	View highways	View secondary streets		Summer solstice morning
The area's share to the apartment's room count.	True if the area is directly leading to an exit of the apartment.	The Closeness-Centrality value.	Visible highways. (Steradian)	Visible secondary_streets. (Steradian)		Solar radiation received in the Summer Solstice morning [06:00-12:00]. (klx)
	Layout has shower	Connectivity eigen	View isovist	View site		Summer solstice noon
	True if the area has a shower.	The eigen centrality value.	Visible isovist. (Steradian)	Visible site. (Steradian)		Solar radiation received in the Summer Solstice noon [12:00-16:00]. (klx)
	Layout has sink	Connectivity entrance door	View mountains class_2	View sky		Summer solstice evening
	True if the area has a sink.	Shortest distance to the entrance door. (m)	Visible mountains of UN mountain class 2. (Steradian)	Visible sky. (Steradian)		Solar radiation received in the Summer Solstice evening [16:00-20:00]. (klx)
	Layout has stairs	Connectivity kitchen	View mountains class_3	View tertiary streets		Winter solstice morning
	True if the area has stairs.	Shortest distance to the kitchen. (m)	Visible mountains of UN mountain class 3. (Steradian)	Visible tertiary_streets. (Steradian)		Solar radiation received in the Winter Solstice morning [06:00-12:00]. (klx)
	Layout has toilet	Connectivity living dining	View mountains class_4	View water		Winter solstice noon
	True if the area has a toilet.	Shortest distance to the living-dining room. (m)	Visible mountains of UN mountain class 4. (Steradian)	Visible water. (Steradian)		Solar radiation received in the Winter Solstice noon [12:00-16:00]. (klx)
	Layout is navigable	Connectivity loggia	View mountains class_5			Winter solstice evening
	True if the area is navigable by a wheelchair.	Shortest distance to the loggia. (m)	Visible mountains of UN mountain class 5. (Steradian)			Solar radiation received in the Winter Solstice evening [16:00-20:00]. (klx)
		Connectivity room	View mountains class_6			
		Shortest distance to the bedroom. (m)	Visible mountains of mountain class 6. (Steradian)			

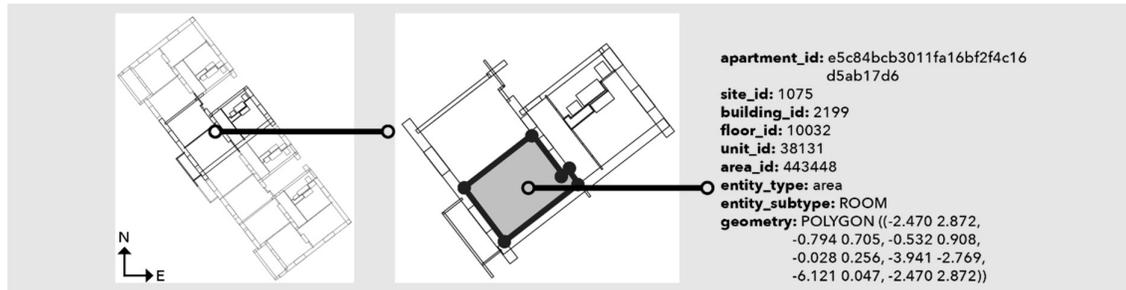


Abbildung 2: Grundriss-Vektorgeometrien.

Trotz seiner Vorteile in Bezug auf Datenskalierung und -vielfalt hat der Archilyse-Datensatz gewisse Einschränkungen. Erstens, da die ursprünglichen Grundrissdaten aus verschiedenen Quellen stammen, ist die Genauigkeit und Konsistenz der Daten beeinträchtigt. Bei einigen Gebäuden gab es fehlende oder fehlerhafte geometrische Daten, was potentiell zu Verzerrungen bei geometrischen Analysen oder Simulationen führen kann. Darüber hinaus enthält der Datensatz aus Datenschutzgründen keine Informationen zum genauen geografischen Standort der Gebäude. Infolgedessen können standortabhängige Merkmale (z. B. Aussicht und Lärm) fehlen. Schließlich gibt es eine regionale Einschränkung des Datensatzes. Der Archilyse-Datensatz umfasst ausschließlich Wohngebäude in bestimmten Regionen der Schweiz. Angesichts der Tatsache, dass sich Schweizer Architekturstile, Klima und Infrastruktur erheblich von denen anderer Regionen unterscheiden, ist mit Verzerrungen der KI-Modelle zu rechnen.

3.2 Bereinigung des Datensatzes

Zu Beginn des Projektes wurde eine Bereinigung durchgeführt, um die Qualität und Konsistenz des Datensatzes für maschinelles Lernen sicherzustellen. Insbesondere wurde darauf geachtet, extreme oder unvollständige Werte zu entfernen, die das Training der Modelle verfälschen oder deren Performance beeinträchtigen könnten. Durch diese Maßnahmen wurde sichergestellt, dass der Datensatz repräsentative und verlässliche Eingabedaten enthält, die für die Entwicklung robuster und generalisierbarer Modelle geeignet sind.

3.2.1 Filtern des Datensatzes

Der vollständige Datensatz umfasst Daten von insgesamt $N = 37.174$ Wohnungen. Im ersten Schritt schlossen wir Wohnungen aus, die entweder unterirdisch oder über dem 6. Obergeschoss lagen ($n = 2.271$), deren Gesamtfläche außerhalb des Bereichs von 25-200 m² lag ($n = 1.094$), für die Daten zum Lärm ($n = 4$) oder zur Sonneneinstrahlung im Raum ($n = 4$) fehlten oder die für eine dieser beiden Variablen einen Wert von Null hatten ($n = 810$). Da nur eine geringe Anzahl von Wohnungen ($n = 387$) über mehr als fünf Zimmer verfügte, wurden auch diese ausgeschlossen. Daraus ergab sich eine Stichprobengröße von $N = 32.990$ Wohnungen, deren Eigenschaften in Abbildung 3.

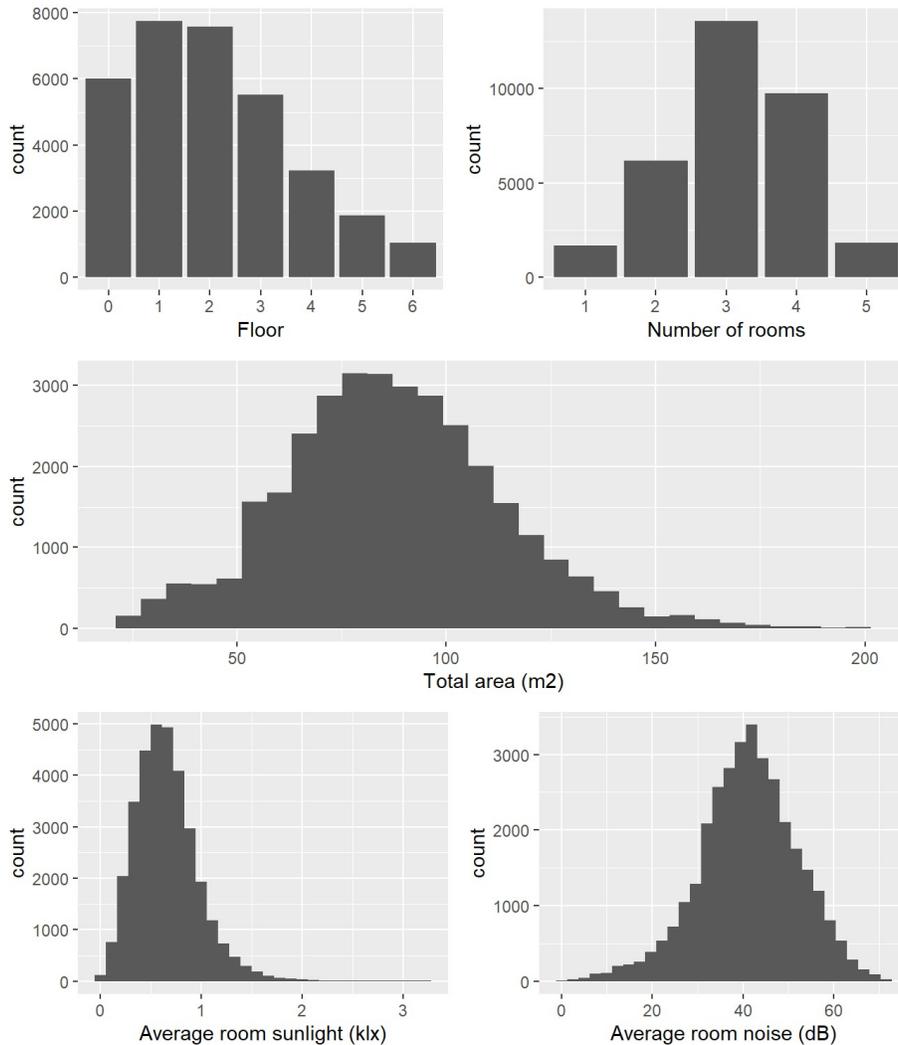


Abbildung 3: Verteilungen von Schlüsselvariablen nach der anfänglichen Datenbereinigung.

Um Wohnungen mit demselben Layout zu identifizieren, haben wir einen speziellen Algorithmus entwickelt:

Zunächst berücksichtigten wir mögliche Drehungen der Wohnungen, indem wir diese entlang der horizontalen (x-Achse) und der vertikalen (y-Achse) ausrichteten. Dabei wurde die längste Polygonkante innerhalb jeder Wohnung so gedreht, dass sie entlang der Horizontalen lag. Im nächsten Schritt konvertierten wir die Vektorgrafikdarstellung der Wohnungen in eine binäre Rasterdarstellung mit einer Auflösung von 224×224 Pixeln. Diese Rasterdarstellung zeigte ausschließlich die Flächengeometrien wie Räume, Flure, Schächte und Balkone, während Wände, Säulen, Türen und Fenster bewusst ausgeschlossen wurden. Jede dieser 224×224-Matrizen enthielt lediglich binäre Werte: 0 für Schwarz (Wände) und 1 für Weiß (Wohnungsflächen).

Diese Matrizen wurden dann verwendet, um ein Maß für den Abstand zwischen den Wohnungsgeometrien zu erhalten. Die Wohnungen wurden zunächst nach der Anzahl der Zimmer gruppiert. Innerhalb jeder Gruppe wählten wir dann eine zufällige Wohnung als

Referenzmatrix (A) aus und berechneten die Summe der quadrierten Differenz zwischen dieser Referenz und allen anderen Wohnungsmatrizen (B):

$$SS = \sum_{i=1}^n \sum_{j=1}^n (B_{ij} - A_{ij})^2,$$

wobei $n = 224$, die Anzahl der Pixel pro Dimension, ist.

Nach der anfänglichen Ausrichtung der Grundrisse entlang der x- und y-Achse blieben acht mögliche Orientierungen, die jeder Grundriss einnehmen konnte (siehe Abbildung 4). Um dies zu berücksichtigen, wurde jede Grundrissmatrix in acht verschiedene Matrizen transformiert, die diese Rotationen repräsentieren. Anschließend wurden diese Matrizen mit der Referenzgrundrissmatrix anhand des Maßes der Quadratsumme verglichen. Dieser Prozess führte zu acht Abstandswerten pro Grundriss, die einen achtdimensionalen Differenzraum definierten. In diesem Raum repräsentierte jeder Grundriss einen Punkt, wobei die Referenzwohnung am Ursprung positioniert war.

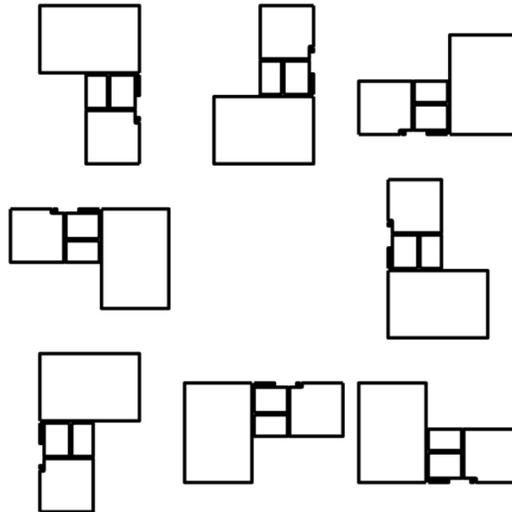


Abbildung 4: Die acht Ausrichtungen einer Wohnung, welche zur Ähnlichkeitsprüfung verwendet wurden.

Um den Differenzraum weiter zu erweitern, wählten wir einen weiteren Grundriss als Referenz und wiederholten den zuvor beschriebenen Prozess. In der ersten Iteration wurde der Referenzgrundriss aus der Mitte der Entfernungverteilung ausgewählt. Der resultierende 16-dimensionale Datensatz wurde anschließend dem Self-Organizing Map-Algorithmus (SOM, Kohonen, 1990) zugeführt, wobei die Rastergröße durch $\text{floor}(\sqrt{n})$ bestimmt wurde. Hierbei entspricht n der Anzahl der Grundrisse mit einer bestimmten Anzahl von Räumen. Dieses Verfahren ordnete jedem analysierten Grundriss eine Position im SOM-Raster zu, wodurch die Grundrisse nach ihrer Form gruppiert wurden.

Der oben beschriebene Algorithmus erzeugte anfänglich relativ breit gefasste Cluster, in denen gelegentlich unterschiedliche Grundrisse in einem einzigen Cluster zusammengefasst wurden. Daher wurde ein weiterer Schritt zur Verfeinerung des Clusterings implementiert. Innerhalb jedes SOM-Clusters wurde zunächst ein Grundriss willkürlich als Referenz festgelegt. Der

Abstand zwischen dieser Referenz und den acht möglichen Ausrichtungen aller anderen Grundrisse im selben SOM-Cluster wurde erneut berechnet. War das kleinste der acht Abstandsmaße kleiner als ein empirisch bestimmter Schwellenwert von 2.000, wurde der entsprechende Grundriss dem Cluster der Referenz hinzugefügt. Danach wurde der nächste Grundriss, der den Schwellenwert nicht überschreitet, als neue Referenz für einen weiteren Cluster definiert, und der Prozess wurde wiederholt. Dieses Verfahren wurde für jeden SOM-Cluster separat angewendet.

Obwohl der Verfeinerungsalgorithmus theoretisch direkt auf die rohen, ungeclusterten Daten hätte angewendet werden können, bot die initiale SOM-Clustering einen entscheidenden Vorteil: Sie reduzierte die Anzahl der notwendigen Paarvergleiche erheblich und sparte somit erhebliche Rechenressourcen.

Das gesamte Verfahren führte schließlich zu 11.173 rotations- und translationsinvarianten Clustern von geometrisch identischen Grundrissen. Die Anzahl der Grundrisse pro Cluster variierte zwischen 1 und 96 (siehe Abbildung 5).

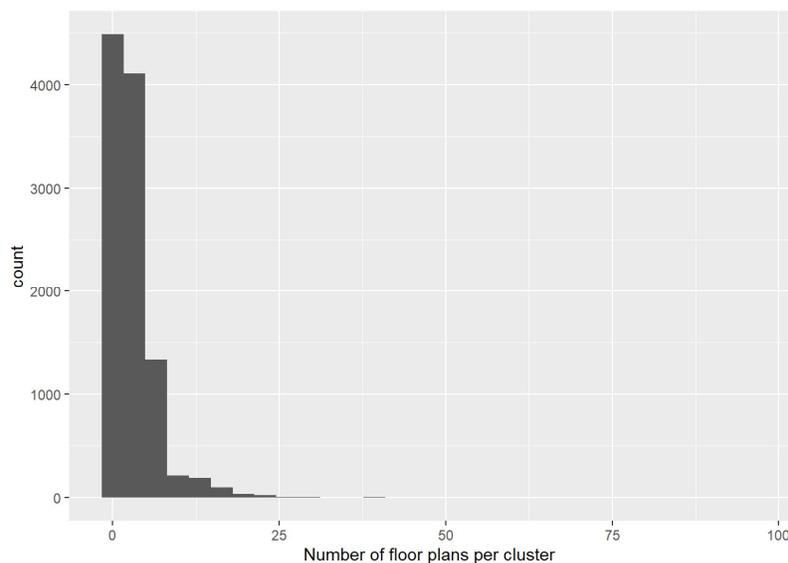


Abbildung 5: Histogramm der Verteilung der Anzahl der Grundrisse pro Cluster.

Nachdem die Daten entsprechend der Geometrie der Grundrisse in Cluster sortiert waren, entfernten wir Wohnungen, die neben der Grundrissgeometrie auch die gleichen Standortfaktoren aufweisen. Dazu nutzten wir die standortabhängigen Analysewerte Lärm und Tageslicht. Diese Duplikate wurden wie folgt identifiziert:

Zuerst haben wir die Variable Lärm in Schritten von 5 dB und die Variable Tageslicht in Schritten von 200 lx in Kategorien diskretisiert. Innerhalb jedes Clusters und für jeden Rauschpegel haben wir dann eine Instanz bei jedem gegebenen Pegel der diskretisierten Tageslichtvariablen beibehalten (falls verfügbar). Die beibehaltene Instanz war diejenige mit der niedrigsten Punktzahl in der ursprünglichen, kontinuierlichen durchschnittlichen Tageseinstrahlungsvariablen.

Dadurch wurde der Datensatz weiter auf die endgültige Größe von $n = 20.419$ im Wesentlichen einzigartigen Wohnungen reduziert.

3.2.2 Automatische Umrissgenerierung

Eine wesentliche Voraussetzung für die zu entwickelnden Heuristiken ist der Umriss der Wohnung, der als notwendiger Input für unsere Anwendung dient. Zwar stellt die Archilyse-Grundrissdatenbank vektorielle Geometriedaten für Entitäten wie Räume, Wände, Türen und Fenster bereit, jedoch fehlen dabei Umrisse von Stockwerken und Wohnungen. Daher mussten wir diese Umrisse automatisch extrahieren.

Die automatische Extraktion der Wohnungsumrisse aus den vorhandenen Geometriedaten ist aufgrund unvollständiger oder fehlerhafter Datensätze eine komplexe Aufgabe. Um diese zu bewältigen, nutzen wir einen mehrstufigen geometrischen Berechnungsprozess (siehe Abbildung 6). Zunächst wird ein Versatz (Offset) auf alle Raumpolygone angewendet, um Lücken zu schließen, die durch Ungenauigkeiten oder fehlende Geometriedaten entstehen. Anschließend werden die versetzten Polygone miteinander vereinigt, um einen zusammenhängenden Umriss zu erzeugen. Danach wird dieser Umriss auf seine ursprüngliche Größe zurückgesetzt.

Eine zusätzliche Herausforderung ergibt sich durch die in den ursprünglichen Geometriedaten enthaltenen erweiterten Wände, die zu einem unregelmäßigen Umriss führen können. Um dieses Problem zu lösen, führen wir einen umgekehrten Versatz durch. Dadurch werden verlängerte Wände bereinigt, sofern ihre Größe kleiner als der Versatzabstand ist. Abschließend wird der bereinigte Umriss erneut auf seine ursprüngliche Größe zurückgesetzt, wodurch der finale, präzise Wohnungsumriss entsteht.

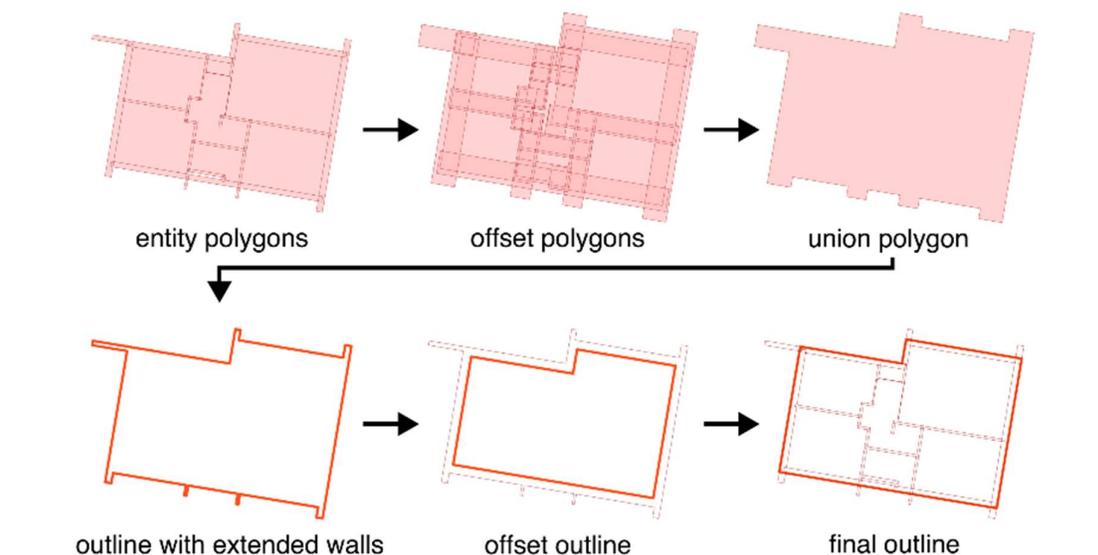


Abbildung 6: Algorithmus zur Erzeugung der Wohnungsumrisslinie.

Wie bereits erwähnt, sind die ursprünglichen geometrischen Daten sehr komplex und enthalten oft fehlende oder fehlerhafte Elemente, so dass die Methode der automatischen Extraktion von Umrissen nicht für alle Grundrisse funktioniert (Abbildung 7). Daher mussten die automatisch extrahierten Umrisslinien noch einmal manuell überprüft werden. Dazu wurde eine Webanwendung programmiert, welche im folgenden Abschnitt beschrieben wird.



Abbildung 7: Fehlerhaft berechnete Umrisslinien.

3.2.3 Manuelle Korrektur der Umrisslinie

Obwohl der Archilyse-Datensatz zweifellos qualitativ hochwertige und nützliche Daten liefert, traten in einigen Fällen suboptimale Ergebnisse bei der Extraktion von Grundrissgeometrien auf. Zu den beobachteten Anomalien zählten Wände, die über die Grenzen des Grundrisses hinaus ragten, sowie Geometrien, die als Eingänge oder Fenster klassifiziert waren, jedoch von der eigentlichen Raumgeometrie getrennt waren (siehe Abbildung 8).

Um diese Probleme zu beheben, entschieden wir uns, den Datensatz einer umfassenden Prüfung zu unterziehen. Hierfür wurden drei wissenschaftliche Hilfskräfte eingestellt, die die Daten manuell überprüften, fehlerhafte Geometrien markierten und Wohnungsumrisse eigenständig zeichneten. Dieser Ansatz gewährleistete eine höhere Präzision und Zuverlässigkeit der Daten für die weitere Verwendung.

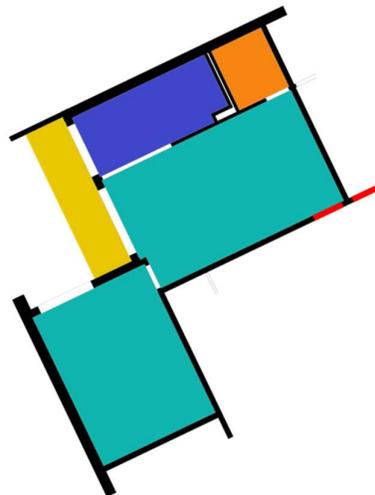


Abbildung 8: Beispiel für einen fehlerhaften Grundriss, hier: zwei Eingangstüren (rot), davon eine, welche nicht in die Wohnung führt.

Um die Datenüberprüfung zu optimieren, haben wir eine Webanwendung entwickelt, die auf dem Server der Bauhaus-Universität Weimar gehostet wurde. Diese Anwendung bot den Prüfern Werkzeuge zur Visualisierung, Überprüfung und Bearbeitung von Grundrissen, wodurch der Prozess effizienter und benutzerfreundlicher gestaltet wurde.

Der Prüfungsablauf verlief wie folgt: Beim Aufrufen der Webanwendung wurden den Prüfern die Geometrien der Wohnungen im Kontext ihres jeweiligen Stockwerks angezeigt (Abbildung 9 A). Die Reihenfolge der Darstellung war so organisiert, dass alle Grundrisse eines Stockwerks innerhalb desselben Gebäudes nacheinander geprüft wurden. Grundrisse, die aufgrund der vorherigen Datenbereinigung ausgeschlossen wurden, wurden automatisch übersprungen.

Die Prüfer begannen ihre Arbeit, indem sie die angezeigten Grundrisse visuell inspizierten. Fiel dabei eine Unregelmäßigkeit auf, markierten sie den Grundriss als problematisch (Abbildung 9 B). Anschließend wurde der automatisch generierte Grundrissumriss als geschlossene Polylinie angezeigt. Die Prüfer hatten die Möglichkeit, den Umriss zu genehmigen oder ihn durch Ziehen, Hinzufügen oder Entfernen von Eckpunkten anzupassen (Abbildung 9 C). Danach identifizierten sie die Innenwände, also jene Wände, die nicht zur Fassade des Gebäudes gehören, durch Anklicken der entsprechenden Liniensegmente (Abbildung 9 D).

Nach Abschluss der Überprüfung wurden die Daten gespeichert, und der nächste Grundriss wurde präsentiert. Dank der benutzerfreundlichen Oberfläche und einer kurzen Einarbeitungszeit konnte der gesamte Prüfprozess in weniger als einer Minute pro Grundriss durchgeführt werden.



Abbildung 9: Überblick über den Prozess der Grundrissprüfung mit dem eigens entwickelten Reviewing-Tool.

Am Ende der Überprüfung wurden die Umrisse aller 20.419 Grundrisse entweder genehmigt oder geändert. Von diesen Grundrissen wurden 268 als problematisch gekennzeichnet, wobei 559 geometrische Elemente (z. B. Wandsegment, Tür, Raum) als "ungewöhnlich" (seltsame Grundrissgeometrie) und vier Grundrisse als "fehlerhaft" gekennzeichnet wurden (Abbildung 10). In sieben Fällen fehlten geometrische Elemente in der Geometrie des gesamten Geschosses (z. B. Wohnungen, die nicht im Archilyse-Datensatz enthalten waren).

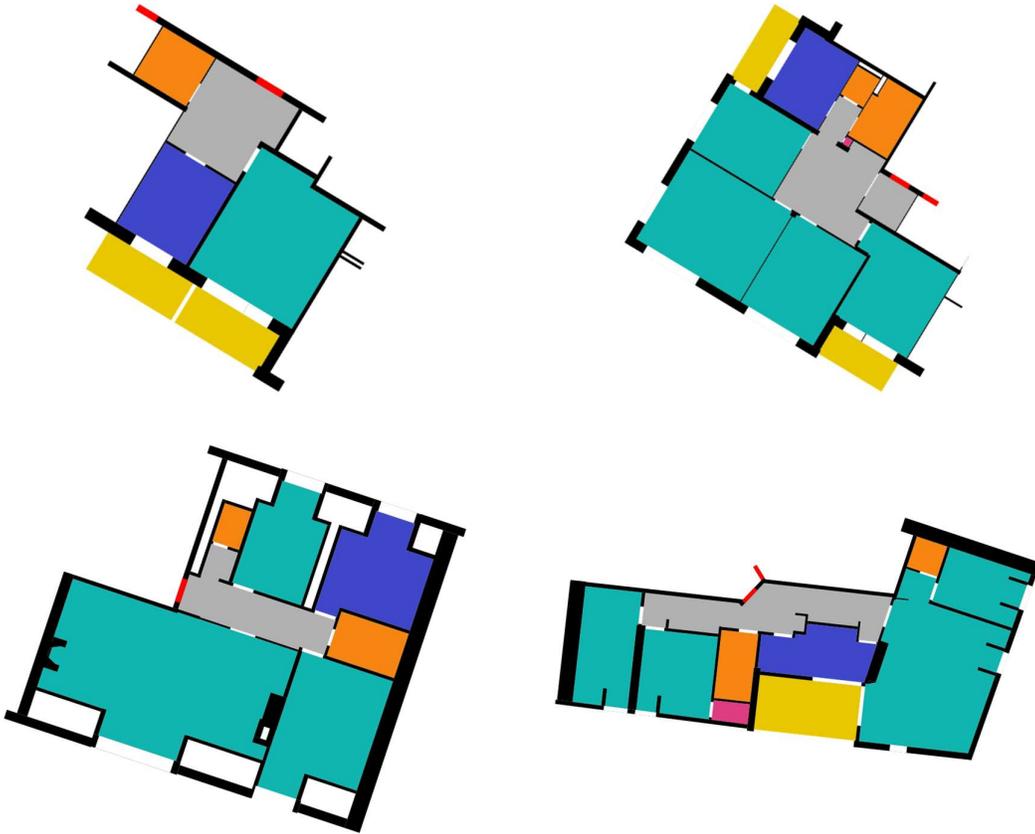


Abbildung 10: Grundrisse, die als fehlerhaft gekennzeichnet wurden.

3.3 Geometrische Features der Umrisslinie

Die im Projekt entwickelten KI-basierten Entwurfsheuristiken werden auf Basis des Wohnungsumrisses trainiert. Dafür muss der Umriss durch eine Vielzahl von Merkmalen beschrieben werden, die sowohl seine geometrischen als auch architektonischen Eigenschaften widerspiegeln. Zur Beschreibung der Wohnungsumrisse extrahierten wir insgesamt 48 globale und 64 lokale Merkmale. Die globalen Merkmale [Basaraner et al., 2017] sind numerische Werte, die die grundlegenden geometrischen Eigenschaften des Umrisses zusammenfassen (siehe Tabelle 2). Diese Merkmale bieten eine umfassende Übersicht über die gesamte Struktur des Grundrisses und bilden eine zentrale Grundlage für die weiteren Analysen.

Tabelle 2: Beispiele für globale Eigenschaften.

Perimeter (m)	Area (m ²)	Facade length (m) & ratio	Max diameter (m)
49.610	104.720	35.601 & 0.718	17.544
POE - Floor plan outline perimeter.	AOE - Floor plan outline area.	FaL - Exterior wall length. FaR=FaL/POE	Md - Maximal distance between two outline points.
Outer radius (m)	Circularity	Inner radius (m)	Compactness
8.772	0.408	3.160	0.535
MECr - Minimum enclosing circle radius.	Cir=AOE/AMEC (AMEC - Area of minimum enclosing circle)	LICr - Largest inner circle radius.	Com=4π×AOE/POE ²
Fractality	Squareness	Roundness	Convexity
0.404	0.825	0.676	0.810
Fra= 1-logAOE/(2×logPOE)	Squ=4×√AOE/(POE)	Rou - The relation between mean and std of the distance between the outline and the center.	Con=AOE/AConvexHull (AConvexHull - Area of Convex Hull)
Straight bounding rectangle width (m) & height (m) & ratio	Extent	Min bounding rectangle width (m) & height (m) & phi (rad)	Rectangularity
13.338 & 14.295 & 0.933	0.549	12.606 & 12.202 & 1.388	0.681
SBRw - Straight bounding rectangle width. SBRh - Straight bounding rectangle height. SBRr= SBRw/ SBRh	Ext=AOE/ASBR (ASBR- Area of straight bounding rectangle)	MBRw - Minimum bounding rectangle width. MBRh - Minimum bounding rectangle height. MBRp - The angle between rectangle and horizontal.	Rec=AOE/AMBR (AMBR - Area of minimum bounding rectangle)

Die lokalen Merkmale beschreiben die Lageeigenschaften einzelner Punkte und Segmente des Umrisses im Verhältnis zu dessen Gesamtstruktur. Für jeden Scheitelpunkt der Kontur leiten wir sieben Merkmale ab [Yan et al., 2021], darunter die lokale Fläche, die lokale Länge und weitere Eigenschaften (siehe Tabelle 3). Zusätzlich erfassten wir sechs Merkmale für jedes Segment der Kontur, darunter architektonische Eigenschaften (z. B. ob es sich um eine Außen- oder Innenwand handelt), und Länge und Himmelsrichtung (siehe Tabelle 4).

Da die Anzahl der Punkte und Segmente je nach Grundriss variiert, war die Anzahl der resultierenden lokalen Merkmale nicht einheitlich festgelegt. Die meisten ML-Modelle können jedoch keine Eingaben mit variabler Länge verarbeiten. Um sicherzustellen, dass

unterschiedliche Konturen in konstante Merkmalsvektoren umgewandelt werden, nutzen wir ein sog. Graph-Embedding der lokalen Merkmale. Konkret transformierten wir die Daten in zwei Graphen: Vertex-Graph und Segment-Graph:

- Der Vertex-Graph ist ein ungerichteter Graph, in dem die Knoten die geometrischen Eckpunkte der Kontur repräsentieren (jeder Knoten enthält sieben Merkmale). Die Kanten des Graphen werden durch die Verbindungen zwischen diesen Eckpunkten über geometrische Segmente definiert.
- Der Segment-Graph ist ebenfalls ein ungerichteter Graph. Hier stellen die Knoten die geometrischen Segmente der Kontur dar (jeder Knoten enthält sechs Merkmale), während die Kanten durch gemeinsam genutzte Punkte zwischen Segmenten definiert werden.

Anschließend trainierten wir unüberwachte (unsupervised) Modelle auf Basis des InfoGraph-Frameworks [Sun et al., 2019] für beide Graphen. Dies resultierte in jeweils 64 Embedding Features. Auf diese Weise generierten wir einen Eingabevektor mit konstanter Länge (insgesamt 176 Merkmale), der den Anforderungen der gewählten neuronalen Netzwerkarchitektur entspricht (siehe Abschnitt 4).

Table 3: Eigenschaften für einen Punkt der Umrisslinie.

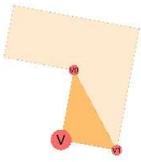
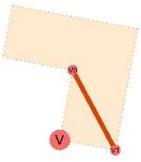
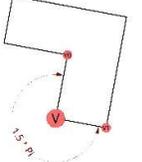
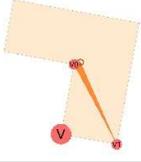
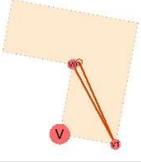
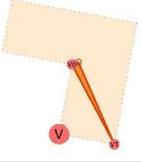
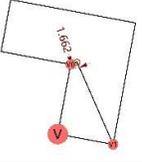
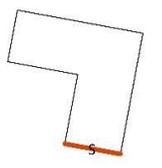
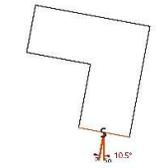
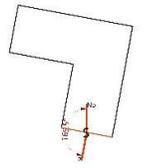
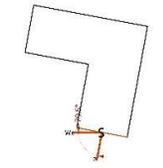
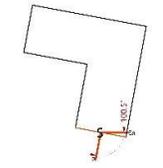
Local area	Local length	Local angle	
			
0.187	0.875	4.712	
$LA = ALT / AOE$ (ALT - Area of local triangle)	$LL = LV0V1 / \sqrt{AOE}$ (LV0V1 - Length of V0 · V1 line)	$LA = \angle V0 \cdot V \cdot V1$	
Regional area	Regional perimeter	Regional radius	Regional angle
			
0.029	0.904	0.032	1.662
$RA = ART / AOE$ (ART - Area of regional triangle)	$RP = (PRT / 2) / \sqrt{AOE}$ (PRT - Perimeter of regional triangle)	$RR = ART / (PRT / 2) / \sqrt{AOE}$	$RA = \angle V0 \cdot C \cdot V1$

Tabelle 4: Segmenteigenschaften.

Architectural property	Length		
			
exterior wall	5.590		
Exterior or interior wall	Length of the segment		
Direction south	Direction north	Direction west	Direction east
			
0.983	0	0.182	0
$DS = \cos(\angle P \cdot S \cdot So)$ If $DS < 0$, $DS = 0$	$DN = \cos(\angle P \cdot S \cdot No)$ If $DN < 0$, $DN = 0$	$DW = \cos(\angle P \cdot S \cdot We)$ If $DW < 0$, $DW = 0$	$DE = \cos(\angle P \cdot S \cdot Ea)$ If $DE < 0$, $DE = 0$

3.4 Merkmalsanalyse

Aktuelle Datensätze im Bereich architektonischer Gestaltung konzentrieren sich meist auf geometrische Merkmale. Kontextbezogene Eigenschaften wie Ausrichtung, räumliche Konfiguration, Lärm, Sonnenlicht und Aussicht werden aufgrund der schwierigen und ressourcenintensiven Datenerfassung oft vernachlässigt. Dabei beeinflussen genau diese Merkmale die wahrgenommene Qualität von Wohngrundrissen und deren Eignung zur Erfüllung der Bedürfnisse der Bewohner maßgeblich. Dieses Kapitel widmet sich daher der Analyse und Identifikation jener kritischen Merkmale, die einen signifikanten Einfluss auf das Training von ML-Modellen und deren Vorhersagegenauigkeit haben.

Eine der größten Herausforderungen besteht in den hohen Kosten für die Erhebung umfangreicher Merkmale, die über die reine Grundrissgeometrie hinausgehen. Beispielsweise erfordert die Erfassung von Umgebungsfaktoren wie Verkehrslärm, Sonneneinstrahlung oder Aussicht den Einsatz kontextbezogener Datensätze, komplexer Umweltsimulationen oder standortspezifischer Messungen. Der damit verbundene Zeit-, Kosten- und Fachwissensaufwand stellt erhebliche Hindernisse dar und führt zu wichtigen Überlegungen hinsichtlich der Effizienz des Datenerfassungsprozesses.

Die Analyse in diesem Kapitel wird von drei zentralen Fragestellungen geleitet:

- Welchen Informationswert haben einzelne Merkmale in einem Datensatz von Wohngrundrissen? Wie kann die Anzahl der Merkmale reduziert werden, ohne die Vorhersagegenauigkeit der Modelle zu beeinträchtigen?
- Welche Merkmale haben den größten Einfluss auf die Genauigkeit und Effizienz von ML-Modellen, die für architektonische Planungen verwendet werden?
- Sollten zukünftige Datensätze bestimmte hochwertige Merkmale priorisieren, um den Datenerfassungsprozess zu optimieren und den Ressourcenbedarf zu reduzieren?

Die Ergebnisse dieser Analyse sollen dazu beitragen, die Datenerhebung effizienter zu gestalten und maschinelles Lernen gezielt durch qualitativ hochwertige Daten zu unterstützen.

Stand der Technik

In den letzten Jahren hat die Integration datengesteuerter Ansätze in die Architekturplanung stark an Bedeutung gewonnen, vor allem durch die Anwendung von maschinellem Lernen (ML). Diese Ansätze ermöglichen es, durch die Analyse von räumlichen Konfigurationen, Umgebungsfaktoren und Benutzerpräferenzen systematisch optimierte Entwürfe zu generieren. Frühere Studien haben gezeigt, dass ML-Modelle in der Lage sind, aussagekräftige Muster in Grundrisslayouts zu erkennen, indem sie sowohl bildbasierte als auch kontextbezogene Daten nutzen. Dennoch bestehen weiterhin Herausforderungen, insbesondere bei der Balance zwischen der Komplexität der Merkmale und der Recheneffizienz.

Traditionell wurden ML-Modelle häufig mit bildbasierten Daten trainiert, um räumliche Konfigurationen von Wohnungen zu analysieren. Diese Ansätze bieten wertvolle Einblicke, indem sie geometrische Eigenschaften wie Raumgröße, -form und -positionierung einbeziehen. Allerdings ignorieren sie oft räumliche Beziehungen und topologische Informationen, was ihre Fähigkeit einschränkt, die funktionale Qualität eines Entwurfs präzise vorherzusagen. Um diese Einschränkungen zu überwinden, wurde in jüngerer Zeit vermehrt auf graphenbasierte Techniken zurückgegriffen, die Konnektivitäts- und Nachbarschaftsinformationen zwischen Räumen innerhalb eines Grundrisses effektiver abbilden können.

Ein zentraler Fortschritt ist die Nutzung topologischer Graphen, um die räumlichen Beziehungen zwischen Räumen darzustellen. Diese Graphdarstellungen eröffnen ein tieferes Verständnis der räumlichen Konfigurationen, indem sie Metriken wie Nähe, Zentralität und Konnektivität analysieren.

Neben den geometrischen und konfigurationsbezogenen Merkmalen spielen auch Umweltfaktoren wie Sonneneinstrahlung, Lärm und Aussicht eine entscheidende Rolle bei der Bewertung der Grundrissqualität. Die Sonneneinstrahlung beeinflusst beispielsweise Komfort, Energieeffizienz und Lebensqualität erheblich, während Lärm, insbesondere Verkehrslärm, nachweislich die Lebensqualität der Bewohner beeinträchtigen kann. Obwohl diese Umweltfaktoren für die architektonische Planung von zentraler Bedeutung sind, gestaltet sich ihre Erfassung aufgrund des hohen Aufwands für Simulationen, standortspezifische Messungen und die Nutzung externer Datensätze als äußerst ressourcenintensiv.

Ein wesentlicher Mangel der bisherigen Forschung liegt in der unzureichenden Untersuchung der relativen Bedeutung dieser unterschiedlichen Merkmale für ML-Modelle im Grundrissentwurf. Während viele Studien die Komplexität durch die Einführung zusätzlicher Merkmale erhöht haben, wurde bislang nur begrenzt darauf geachtet, wie sich der Datenerfassungsprozess durch gezielte Auswahl relevanter Merkmale optimieren lässt. Ziel dieses Kapitels ist es daher, diese Forschungslücke zu schließen, indem die Merkmale identifiziert werden, die den höchsten Informationswert bieten. Auf diese Weise soll das Training von ML-Modellen optimiert und die Effizienz bei der Datenerhebung gesteigert werden.

Methode

Um die relative Bedeutung verschiedener Merkmale von Wohngrundrissen zu bewerten, wurde ein Datensatz mit 52 Merkmalen für jeden Grundriss analysiert. Der Datensatz umfasste geometrische Eigenschaften der Grundrisse sowie Merkmale, die räumliche Beziehungen (z. B. Konnektivität und Closeness-Zentralität), Umweltaspekte und kontextuelle Faktoren (z. B. Lärm, Sonnenlicht und Ausblick) erfassten. Jeder Grundriss wurde sowohl als geometrische Entität als auch als Merkmalsvektor dargestellt. Der Prozess der Merkmalsauswahl wurde unter Verwendung einer Kombination aus Techniken zur Dimensionsreduktion und ML-basierten Methoden durchgeführt. Ziel war es, diejenigen Merkmale zu identifizieren, die am stärksten zur Vorhersagegenauigkeit der ML-Modelle beitragen.

Um die aussagekräftigsten Merkmale von Grundrissen zu bestimmen, wurden zwei Methoden verwendet. Die erste Methode, Tabula rasa, geht davon aus, dass vor der Auswahl keine Merkmale vorliegen. Sie wird verwendet, um den Merkmalsumfang *a priori* vor der Datenerhebung zu definieren. Die zweite Methode, Context-aware selection, dient dazu, zusätzlich zu bereits bestehenden Daten Merkmale auszuwählen, um deren Informationsgehalt zu erhöhen. Beide Methoden verwenden dasselbe hybride Verfahren zur Merkmalsauswahl und unterscheiden sich nur in der Initialisierungsphase. Der zentrale Teil der Auswahl basiert auf einem schrittweisen Vorwärtsauswahlverfahren (stepwise forward selection), das darauf abzielt, die besten N Merkmale zu identifizieren. Dies bedeutet, dass wir entweder a) mit einem leeren Merkmalsatz im Fall der Tabula rasa-Methode oder b) mit einem Satz bestehender Merkmale in der Context-aware selection starteten. In jedem Schritt wurde das Merkmal hinzugefügt, das den größten Beitrag zur gemeinsamen Informationsentropie (IE) der aktuellen Merkmalsauswahl leistet.

Zu Beginn wurde im ersten Schritt das Merkmal mit der höchsten Informationsentropie ausgewählt (siehe Abbildung 11). In den darauffolgenden Schritten wurde nach dem Merkmal gesucht, das in Kombination mit den bereits ausgewählten Merkmalen die maximale gemeinsame Entropie des Datensatzes erreicht. Dabei wurde jedoch nicht einfach das Merkmal mit der höchsten individuellen Informationsentropie ausgewählt (dargestellt durch den Durchmesser des Kreises in Abbildung 11), sondern das Merkmal, das den größten zusätzlichen Beitrag zur gemeinsamen Informationsentropie der Merkmalsauswahl lieferte (dargestellt durch die rote Umrandung in Abbildung 11).

Um das nächste beste Merkmal auszuwählen, berechneten wir die gemeinsame Entropie jedes verfügbaren Merkmals mit der aktuellen Merkmalsauswahl. Anschließend verglichen wir, wie viel zusätzliche Informationsentropie jedes Merkmal zur aktuellen Auswahl hinzufügt, und wählten dasjenige mit dem höchsten Beitrag aus (siehe Abbildung 11, Schritt 2).

Dieser Ansatz stellte sicher, dass die Informationsentropie der Merkmalsauswahl maximiert und gleichzeitig Redundanz minimiert wird. Merkmale, die keine neuen Informationen liefern, sondern nur bereits vorhandene Informationen in der Auswahl wiederholen, wurden nicht ausgewählt.

Um den rechenintensiven Auswahlprozess zu beschleunigen, wurden potenzielle Merkmalskandidaten anhand ihrer individuellen Shannon-Entropie vorab eingestuft. Diese wurden im ersten Schritt der Vorwärtsauswahl berechnet. Die Kandidaten wurden in der Rangfolge getestet, beginnend mit dem Merkmal mit der höchsten Informationsentropie. Der

Test wurde abgebrochen, sobald ein Merkmal gefunden wurde, dessen Informationsgewinn höher war als die Entropie des nächsten Kandidaten in der Rangliste. Durch dieses Vorgehen wurde nicht nur die Informationsqualität der ausgewählten Merkmale maximiert, sondern auch die Effizienz der Merkmalsauswahl erheblich gesteigert.

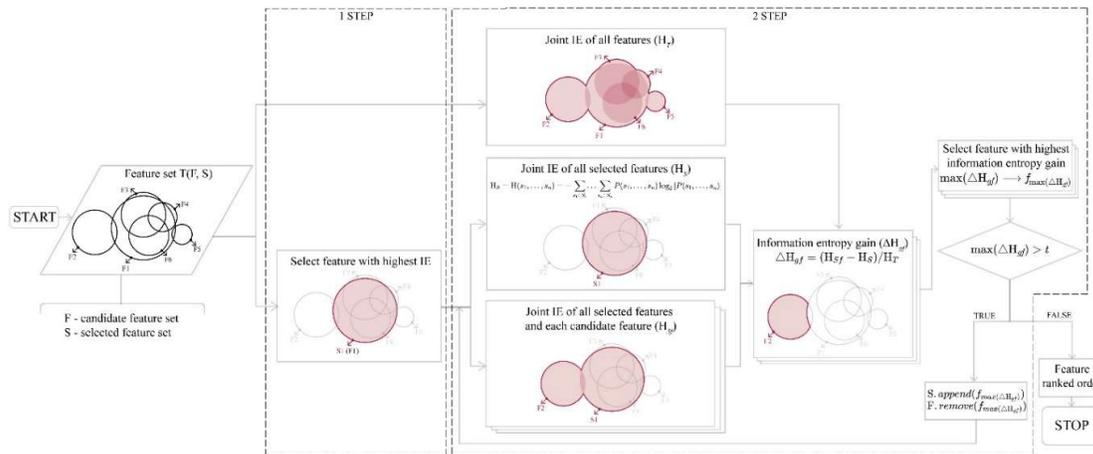


Abbildung 11: Diagramm zum vorgeschlagenen Prozess der Merkmalsauswahl.

Das Merkmalsauswahlverfahren erstellt eine Rangfolge, die den Gewinn an Informationsentropie (im Folgenden auch als Informationsgewinn bezeichnet) darstellt, der durch das schrittweise Hinzufügen jedes Merkmals zum Datensatz erzielt wird. Zum Beispiel: Wenn der Informationsgewinn der ersten beiden Merkmale in der Rangfolge 40 % und 10 % beträgt, erfassen diese beiden Merkmale zusammen 50 % der gesamten gemeinsamen Informationsentropie (IE) des Feature-Sets. Diese geordnete Rangfolge der Merkmale kann als Leitlinie genutzt werden, um a) das beste Set von N Merkmalen zu identifizieren, das den Informationswert maximiert und Redundanz minimiert, und b) die Anzahl und die spezifischen Merkmale zu bestimmen, die erforderlich sind, um einen bestimmten kritischen Anteil des IE abzudecken. Beispielsweise könnte festgelegt werden, dass das Feature-Set mindestens 95 % des IE abdecken soll; in diesem Fall würde man die ersten N Merkmale auswählen, die diesen Schwellenwert erreichen.

Um die Stabilität des ausgewählten Merkmalsatzes zu erhöhen, verwenden wir zusätzlich ein Ensemble von Feature-Auswahlmodellen anstelle eines einzelnen Modells. Dieses Ensemble wurde mit „bootstrapped“ Daten trainiert – einer Technik, bei der Teilmengen der Daten mit Zurücklegen ausgewählt werden. Diese Methode ist in der maschinellen Lernforschung etabliert (z. B. in Entscheidungsbaumverfahren) und wird genutzt, um die Robustheit und Genauigkeit von Algorithmen zu verbessern [Efron 1979]. Durch den Einsatz eines Ensembles wird die Auswahl der Merkmale widerstandsfähiger gegenüber Schwankungen im Datensatz und liefert stabilere Ergebnisse.

Datenvorbereitung

Die Datenvorbereitung umfasste die Bereinigung und Standardisierung des Datensatzes, um Konsistenz und Qualität über alle Merkmale hinweg sicherzustellen. Fehlende Werte wurden mithilfe von Imputationstechniken behandelt, wobei je nach Datentyp entweder die Mittelwert- oder Medianimputation angewendet wurde. Um sicherzustellen, dass die Merkmale auf einer

ähnlichen Skala liegen – was für viele ML-Algorithmen entscheidend ist –, wurden die Werte standardisiert.

Nach der Standardisierung folgte eine explorative Datenanalyse (EDA), um die Verteilungen der Merkmale sowie die Beziehungen zwischen ihnen besser zu verstehen. Im Rahmen dieser Analyse wurde auch eine Korrelationsanalyse durchgeführt, um stark korrelierte Merkmale zu identifizieren, die potenziell Redundanz in das Modell einbringen könnten. Durch das gezielte Entfernen solcher Merkmale konnte die Gesamtdimensionalität des Datensatzes reduziert werden, ohne dabei wesentliche Informationen zu verlieren. Dieser Schritt trug wesentlich zur Effizienz und Genauigkeit des Modells bei.

Dimensionsreduktion

Zur Reduktion der Dimensionalität des Datensatzes wurden zwei zentrale Techniken eingesetzt: Principal Component Analysis (PCA) und Recursive Feature Elimination (RFE).

- PCA wurde angewendet, um den ursprünglichen Satz von Merkmalen in einen kleineren Satz unkorrelierter Hauptkomponenten zu transformieren, die den größten Teil der Varianz in den Daten erfassen. Der Hauptvorteil dieser Methode liegt darin, die Dimensionalität des Datensatzes zu reduzieren, ohne dabei wesentliche Informationen zu verlieren. Durch die Analyse des erklärten Varianzverhältnisses konnten wir ermitteln, wie viele Hauptkomponenten erforderlich sind, um ein bestimmtes Informationsniveau, beispielsweise 90 % oder mehr, beizubehalten.
- RFE wurde eingesetzt, um iterativ die am wenigsten wichtigen Merkmale aus dem Datensatz zu entfernen, basierend auf ihrem Beitrag zur Modellperformance. Dabei wurde ein maschinelles Lernmodell, wie etwa ein Random Forest oder eine Support Vector Machine (SVM), trainiert, um die Merkmale nach ihrer Wichtigkeit zu bewerten. Merkmale mit niedriger Bedeutung wurden schrittweise eliminiert, und das Modell wurde nach jedem Schritt neu trainiert, bis ein optimaler Satz von Merkmalen identifiziert wurde.

Die Kombination von PCA und RFE ermöglichte es, die Dimensionalität des Datensatzes systematisch zu reduzieren, während die wertvollsten Informationen erhalten blieben. PCA diente dazu, übergeordnete Muster in den Daten zu identifizieren und die Reduktion auf Basis der Datenstruktur vorzunehmen. RFE hingegen erlaubte eine detailliertere Analyse der Merkmalsbedeutung und optimierte die Merkmalsauswahl auf Grundlage der Modellperformance. Diese kombinierte Herangehensweise gewährleistete eine effiziente und fundierte Reduktion des Merkmalsumfangs.

Validierung und Tests

Eine der größten Herausforderungen beim unüberwachten maschinellen Lernen, insbesondere bei der unüberwachten Merkmalsauswahl, war die Bewertung der Ergebnisse. Da die unüberwachte Merkmalsauswahl definitionsgemäß lediglich das Problem definiert, jedoch keine eindeutige "richtige" Antwort liefert, besteht ein üblicher Ansatz zur Performancebewertung darin, überwachte Klassifikatoren wie kNN [Fix & Hodges 1989], Naive Bayes [Maron 1961] oder andere Algorithmen einzusetzen.

In ähnlicher Weise evaluierten wir die Effektivität der vorgeschlagenen Methode zur unüberwachten Merkmalsauswahl sowie der damit identifizierten Grundrissmerkmale anhand von Aufgaben des überwachten Lernens. Dazu trainierten wir drei überwachte Klassifikatoren –

Naive Bayes, kNN und Decision Tree – mit dem Ziel, die Raumbeschriftungen (z. B. Küche, Bad) basierend auf der unüberwachten Merkmalsauswahl vorherzusagen. Die Performance dieser Klassifikatoren wurde unter drei Bedingungen verglichen:

1. mit allen verfügbaren Merkmalen,
2. mit der Merkmalsteilmenge, die durch die vorgeschlagene unüberwachte Merkmalsauswahlmethode identifiziert wurde, und
3. mit der Merkmalsteilmenge, die durch die hochmoderne überwachte Merkmalsauswahlmethode mRMR (Minimum Redundancy Maximum Relevance) ermittelt wurde.

Zusätzlich zur Bewertung der Leistungsfähigkeit der vorgeschlagenen Methode untersuchten wir ihre Sensitivität gegenüber der Stichprobengröße. Konkret analysierten wir, wie viele Daten erforderlich sind, damit die vorgeschlagene Methode einen zuverlässigen Satz von Grundrissmerkmalen identifizieren kann. Diese Sensitivitätsanalyse bot wichtige Einblicke in die Datenanforderungen der Methode und deren Robustheit bei begrenzten Datenmengen.

Ergebnisse

Die Analyse zeigte, dass das ursprüngliche Merkmalsset mit 52 Features signifikant reduziert werden konnte, ohne dabei einen Großteil des Informationswerts einzubüßen (siehe Abbildung 12). Konkret wurde das Merkmalsset auf lediglich fünf hochrelevante Merkmale reduziert, wobei dennoch 87 % des ursprünglichen Informationswerts erhalten blieben. Diese fünf entscheidenden Merkmale sind:

- Closeness-Zentralität: Dieses Merkmal misst, wie leicht zugänglich die Räume innerhalb des Grundrisses sind.
- Konnektivität zum Wohn-/Schlafzimmer: Dieses Merkmal beschreibt, wie gut die verschiedenen Räume mit den primären Wohnbereichen verbunden sind.
- Anbindung an den Balkon: Dieses Merkmal zeigt die Optimierung des Zugangs zu Außenbereichen.
- Verkehrslärm: Dieses Merkmal erwies sich als überraschend wichtig. Obwohl die Erfassung von Verkehrslärmdaten ressourcenintensiv ist, hat sich gezeigt, dass dieses Merkmal sehr aussagekräftig ist.
- Layout-Form: Die Gesamtform des Layouts stellte sich ebenfalls als Schlüsselmerkmal heraus. Sie liefert wertvolle Informationen über die räumlichen Eigenschaften und die Effizienz des Designs.

Diese Ergebnisse unterstreichen, dass eine gezielte Auswahl weniger, aber informativer Merkmale ausreicht, um die wesentlichen Eigenschaften eines Grundrisses abzubilden und gleichzeitig die Effizienz des Datenverarbeitungsprozesses zu maximieren.

Raumbeschriftungen in 92 % bis 99 % der Fälle korrekt zu klassifizieren, abhängig vom verwendeten ML-Algorithmus. Dies wird als Beweis dafür angesehen, dass der Prozess der Datentransformation und Dimensionsreduktion, der zur Ableitung der 52 Merkmale höherer Ordnung verwendet wurde, seine Ziele erreicht hat und den ursprünglichen Informationswert beibehält.

Tabelle 5: Die Klassifikationsgenauigkeit basierend auf der a) vollständigen Merkmalsmenge, b) der überwachten mRMR-Merkmalsauswahl und c) der unüberwachten Tabula Rasa-Merkmalsauswahl.

<i>Feature selection method</i>	<i>Number of higher-order features</i>	<i>Selected higher-order feature</i>	<i>NaiveBias accuracy</i>	<i>kNN (k=9) accuracy</i>	<i>DecisionTree accuracy</i>
Full data set	52	-	0.918	0.985	0.997
mRMR	5	Layout has toilet Layout is navigable Layout has stairs Layout has sink Layout has shower	0.183	0.556	0.556
Tabula rasa	5	Connectivity closeness Noise traffic Shape Connectivity room Connectivity balcony	0.606	0.856	0.881

Wenn es um die Performance des reduzierten Merkmalsatzes geht, der durch die mRMR-Methode ausgewählt wurde, stellten wir einen signifikanten Rückgang der Klassifizierungsgenauigkeit fest, der je nach verwendeten Klassifikator zwischen 18 % und 56 % lag. Die mRMR-Methode identifizierte die fünf wichtigsten Merkmale, die Folgendes erfassten: 1) die Konnektivität zum Balkon, 2) die barrierefrei Zugänglichkeit der Räume, 3) das Vorhandensein einer Toilette in einem bestimmten Raum, 4) das Vorhandensein einer Treppe und 5) das Vorhandensein eines Waschbeckens in einem bestimmten Raum.

Im Gegensatz dazu lieferte die vorgeschlagene unüberwachte Merkmalsauswahlmethode Tabula Rasa fünf Merkmale, die sich als deutlich leistungsstärker erwiesen: 1) Closeness-Zentralität, 2) Verkehrslärm, 3) Form der einzelnen Räume, 4) Verbindung zum Wohn-/Schlafzimmer und 5) Verbindung zu einem Balkon. Dieser Merkmalsatz bot ausreichend Informationen, um eine Klassifizierungsgenauigkeit von bis zu 88 % zu erreichen.

Es ist zu erwähnen, dass die überwachte Merkmalsauswahlmethode (mRMR), obwohl sie speziell für überwachte ML-Aufgaben entwickelt wurde, bei der Evaluierung schlechter abschnitt als die unüberwachte Methode. Wie von Brown et al. [2012] diskutiert, basiert der mRMR-Algorithmus auf einer Reihe von Näherungen, die Verzerrungen verursachen können. Ursprünglich wurde mRMR entwickelt, um die relevantesten Gene aus einer Vielzahl von Optionen auszuwählen [Ding & Peng 2005], wobei der Fokus auf Rechengeschwindigkeit lag. Diese Priorisierung der Effizienz führt dazu, dass der Algorithmus nicht immer die optimalen Merkmale für kleinere Datensätze identifiziert.

Im Gegensatz dazu ist die vorgeschlagene Merkmalsauswahlmethode speziell für kleinere Merkmalsmengen optimiert. Sie verwendet keine Näherungen, sondern durchsucht stattdessen die komplette Sammlung aller möglichen Merkmalskombinationen. Das Hauptziel unseres Algorithmus war die Maximierung des Informationswerts, während mRMR seinen Schwerpunkt auf die Effizienz der Berechnungen legt.

Zusammenfassend bestätigen diese Ergebnisse die Performance der vorgeschlagenen unüberwachten Merkmalsauswahlmethode. Sie ermöglicht eine erhebliche Reduktion der Komplexität des Grundrissdatensatzes, während der Informationswert weitgehend erhalten bleibt. Mit nur 10 % der wertvollsten Merkmale konnten wir eine Klassifizierungsgenauigkeit erreichen, die nahezu mit der Genauigkeit des vollständigen Datensatzes vergleichbar ist.

Fazit

Die Ergebnisse dieser Analyse haben Implikationen für die zukünftige Datenerfassung und das Training von ML-Modellen im Bereich des Grundrissentwurfs. Durch die Identifikation der relevantesten Merkmale wird es möglich, den Prozess der Datenerhebung für zukünftige Datensätze zu optimieren, die Kosten zu senken und gleichzeitig einen hohen Informationswert zu gewährleisten. Die fünf Schlüsselmerkmale – Closeness-Zentralität, Konnektivität zum Wohn-/Schlafzimmer, Konnektivität zum Balkon, Verkehrslärm und Layoutform – ermöglichen ein effizienteres und präziseres Training von ML-Modellen.

Die Reduktion auf diesen Merkmalsatz unterstreicht die Bedeutung von Konfigurationseigenschaften (Raumbeziehungen). Der hohe Informationswert des Merkmals Verkehrslärm zeigt, dass kontextuelle externe Merkmale, obwohl sie schwierig zu erfassen sind, einen erheblichen Einfluss auf die Grundrissgestaltung haben und daher nicht vernachlässigt werden sollten.

Aus praktischer Sicht bieten diese Ergebnisse wertvolle Unterstützung für Architekten, Stadtplaner und Datenwissenschaftler. Sie ermöglichen es, den Fokus bei der Datenerfassung auf eine kleinere, aber wirkungsvollere Merkmalsmenge zu legen. Dies kann zu skalierbaren Ansätzen führen, wenn ML-Techniken auf Grundrissdatensätze in unterschiedlichen Kontexten oder Ländern angewendet werden. Die vergleichsweise geringe Bedeutung von Merkmalen, die mit Ausblicken und Sonnenlicht zusammenhängen, sollte nicht als Ablehnung ihrer Relevanz interpretiert werden. Vielmehr deutet dies darauf hin, dass Ressourcen gezielt anderweitig eingesetzt werden können, insbesondere wenn gesetzliche Regelungen bereits sicherstellen, dass Mindeststandards in diesen Bereichen erfüllt werden.

4 Entwurfsheuristiken

In den folgenden vier Kapiteln wird untersucht, wie maschinelles Lernen und datengetriebene Ansätze den Entwurfsprozess von Wohnungsgrundrissen unterstützen können. Zunächst wird die **Suche nach ähnlichen Grundrissen** betrachtet, wobei der Fokus darauf liegt, bestehende Lösungen effizient zu identifizieren. Anschließend beleuchtet die Entwurfsheuristik **Umrisspotential**, wie sich aus der Außenkontur eines Grundrisses zentrale Merkmale und Einschränkungen ableiten lassen. Mit der dritten Entwurfsheuristik, **Raumdiagramme**, wird die Anwendung von Graph Neural Networks (GNNs) für die Vorhersage und Optimierung von Raumlayouts untersucht, wobei der Fokus auf topologischen Beziehungen und räumlichen Eigenschaften liegt. Abschließend widmet sich der Abschnitt **Grundrissgeometrie** generativen Ansätzen zur automatisierten Erstellung von Grundrissen unter Anwendung von GANs und Stable Diffusion.

4.1 Suche nach ähnlichen Grundrissen

4.1.1 Einführung

Im architektonischen Entwerfen stellt sich häufig die Frage: Warum eine neue Lösung entwickeln, wenn bereits passende Beispiele existieren? Dieser pragmatische Ansatz betont die Bedeutung, bestehende Grundrissbeispiele als Grundlage für den Entwurfsprozess zu nutzen. Statt die zeitintensive Aufgabe auf sich zu nehmen, neue Entwürfe von Grund auf zu erstellen, können Architekten auf kuratierte Sammlungen von Grundrissen in Büchern oder digitalen Datenbanken zurückgreifen. Solche Repositorien bieten eine Fülle von Beispielen, die wertvolle Einblicke und Inspiration für neue Projekte liefern können.

Allerdings sind die aktuellen Methoden für den Zugriff auf diese Grundrisse stark limitiert. Die Suchfunktionen in den meisten Datenbanken sind rudimentär oder fehlen gänzlich, sodass Benutzer gezwungen sind, zahlreiche Einträge manuell zu durchforsten, um eine geeignete Übereinstimmung zu finden. Dieser Prozess ist nicht nur zeitaufwendig, sondern auch ineffizient, da keine Möglichkeit besteht, die Datenbank nach spezifischen geometrischen Merkmalen oder Designqualitäten zu durchsuchen. Dadurch laufen Architekten Gefahr, optimale Lösungen zu übersehen, weil der Suchprozess nicht auf ihre individuellen Kriterien abgestimmt ist. Dies verdeutlicht den dringenden Bedarf an fortschrittlichen Such- und Filteralgorithmen, die die Effizienz und Benutzerfreundlichkeit dieser wertvollen Ressourcen erheblich verbessern könnten.

4.1.2 Datenrepräsentation und KI-Modell

Die Aufgabe, Grundrisse nach ihrer Passung zu einer gewünschten Gliederung zu ordnen, birgt mehrere Herausforderungen, deren Lösung maßgeblich von der gewählten Herangehensweise abhängt.

Zunächst war es entscheidend, das Konzept der "Passung" klar zu definieren und operationalisierbar zu machen. Spielen bspw. Rotation und Translation eine Rolle? Oder sollte die Passung auf strukturellen Elementen wie Innen- und Außenwänden oder Eingängen basieren? Es gibt keine universell richtige Antwort auf diese Fragen. Stattdessen muss die

Definition der Passung die spezifischen Eigenschaften widerspiegeln, die durch eine konzeptionelle Analyse dieser Fragen identifiziert wurden.

Sobald das Konzept der Passung festgelegt war, entsteht die nächste Herausforderung: die Reduktion eines komplexen Grundrisses auf eine handhabbare Menge algorithmisch nutzbarer quantitativer Deskriptoren. Diese müssen die konzeptionelle Definition der Passung angemessen abbilden. Beispielsweise könnten, wenn die geometrische Form des umschließenden Polygons eines Grundrisses und seine Ähnlichkeit mit einem Zielpolygon das einzige Maß der Passung darstellen sollen, Bildverarbeitungsmethoden wie Bildmomente eingesetzt werden, um die entsprechenden Deskriptoren abzuleiten. Es gibt zahlreiche Metriken, von denen einige sensitiv gegenüber Transformationen sind, während andere invariant bleiben.

Um schließlich eine Datenbank mit Grundrissen nach den am besten passenden Einträgen abfragen zu können, muss die Passung in einer einzigen Größe ausgedrückt werden, die als Grundlage für die Sortierung der Datenbank dient. Die aus den Daten abgeleiteten quantitativen Deskriptoren können dabei als Positionen in einem n -dimensionalen Raum interpretiert werden. Die finale Passungsmetrik entspricht in diesem Kontext dem Abstand zwischen dem Zielumriss und dem Grundriss in diesem Raum. Je nach Anforderung können unterschiedliche Distanzmetriken, wie die euklidische oder Manhattan-Distanz, sowie Gewichtungsmechanismen verwendet werden, um die Performance des Anpassungsalgorithmus zu optimieren.

In unserem Ansatz haben wir zunächst verschiedene geometrische Eigenschaften berücksichtigt, darunter die Gesamtfläche des Grundrisses, die Position des Eingangs und die Klassifikation der Wände als Innen- oder Außenwände. Diese Informationen wurden durch 176 Merkmale dargestellt, die mit Hilfe eines grapheneinbettenden maschinellen Lernmodells abgeleitet wurden. Zur Berechnung der Ähnlichkeit zwischen einem Grundriss und einem Zielumriss wurde die euklidische Distanz in einem 64-dimensionalen Raum verwendet. Obwohl dieser Ansatz gute Ergebnisse hinsichtlich der Eingangsposition und der Wandklassifikation lieferte, zeigte er Schwächen in der präzisen Formanpassung.

Um diese Defizite zu beheben, haben wir unsere Methodik angepasst. Anstelle von Grapheneinbettungen berechneten wir die Momenteninvarianten von Hu für jedes Grundrisspolygon [Hu, 1962]. Diese sieben reellen Zahlen, die aus Bildmomenten abgeleitet werden, sind in der Bildverarbeitung ein gängiges Mittel zur Mustererkennung. Sie sind invariant gegenüber Translation, Skalierung und, bis auf das Vorzeichen der letzten Invariante, auch gegenüber Reflexion. Durch eine einfache Log-Transformation

$$H_i = -\text{sign}(h_i) * \log_{10}|h_i|,$$

wobei h_i die i -te Momenteninvariante ist und verwendet werden kann, um diese Momenteninvarianten auf einer ähnlichen Skala zu platzieren, was es ermöglicht, eine ungewichtete Distanz (normalerweise Manhattan-Entfernung) im resultierenden 7-dimensionalen Raum zur Berechnung der Formähnlichkeit zu verwenden.

4.1.3 Ergebnisse

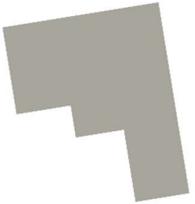
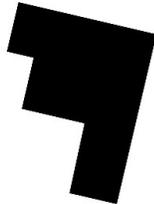
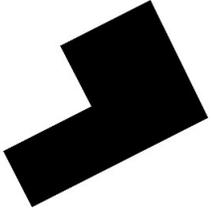
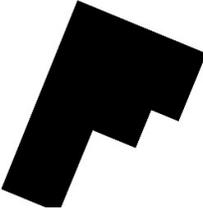
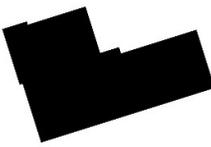
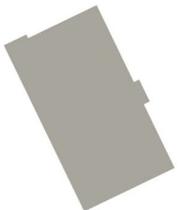
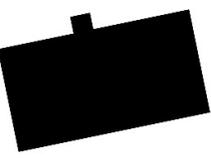
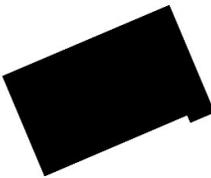
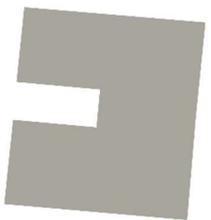
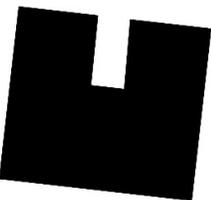
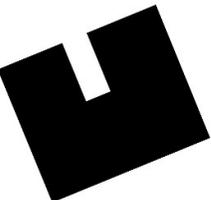
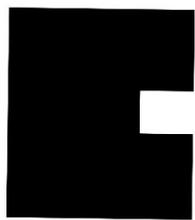
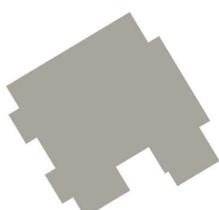
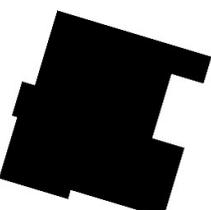
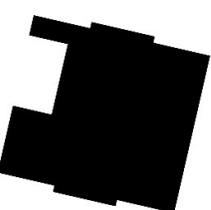
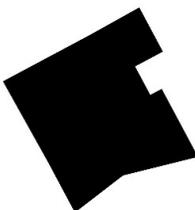
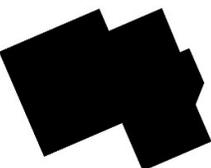
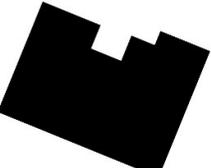
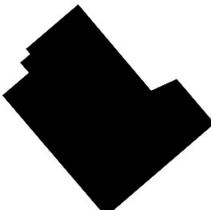
Um die Performance dieser Methode zu evaluieren, führten wir folgendes Experiment durch: Zunächst wurde jede Grundrisskontur des Datensatzes in eine Schwarz-Weiß-Rasterdarstellung mit einer Auflösung von 200×200 Pixeln umgewandelt, wobei die schwarzen Pixel die Grundrissfläche und der weiße Hintergrund die Umgebung repräsentierten. Anschließend berechneten wir die log-transformierten Momenteninvarianten von Hu für jedes dieser Rasterbilder. Daraufhin wählten wir zehn Grundrisskonturen aus, die als Zielvorlagen mit unterschiedlichen Formen dienten. Von diesen Zielvorlagen erstellten wir gedrehte, gespiegelte sowie gleichzeitig gedrehte und gespiegelte Versionen und berechneten die sieben Momenteninvarianten für jede Transformation. Wie erwartet, lieferten alle Varianten einer Zielvorlage identische Wertearrays, was die Transformationsinvarianz dieser Indizes bestätigte.

Im nächsten Schritt berechneten wir die Manhattan-Distanzen im „Hu-Raum“ zwischen jedem Grundriss im Datensatz und den Zielvorlagen, um die zehn ähnlichsten Grundrisse zu identifizieren. Dieser Ansatz bewährte sich und ordnete die Wohnungsgrundrisse erfolgreich nach ihrer Ähnlichkeit mit der unveränderten Zielvorlage (siehe Tabelle 6 für eine vereinfachte Darstellung).

Die Invarianz gegenüber Translation und Spiegelung sehen wir als eine nützliche Eigenschaft des Matching-Algorithmus, da solche Transformationen leicht auf jede Geometrie angewendet werden können, sobald ein gut passender Grundriss für eine Zielkontur gefunden wurde. Die Skalierungsinvarianz ist hingegen weniger wünschenswert, da Grundrisse in der Praxis nicht beliebig skaliert werden können: Zwei Wohnungen mit sehr ähnlichen Konturen, aber stark unterschiedlicher Gesamtfläche, könnten grundlegend unterschiedliche Layoutlösungen erfordern. Daher sollte der Datensatz vor der Ähnlichkeitsberechnung nach Gesamtfläche gefiltert werden, um die Analyse auf eine passende und reduzierte Datenmenge zu beschränken.

Ein Nachteil dieser Methode ist, dass weder die Position des Eingangs noch die Konfiguration der Wände (z. B. Innen- oder Außenwände) berücksichtigt werden. Dennoch bevorzugen wir diesen Ansatz aufgrund seiner überlegenen Performance bei der Formähnlichkeitsbewertung. Grundsätzlich kann dieser Ansatz auch mit anderen Verfahren kombiniert werden, um eine „Best-of-Both-Worlds“-Lösung zu schaffen. Dazu wäre jedoch ein Gewichtungssystem erforderlich, das die verschiedenen Dimensionen des kombinierten Raums – bestehend aus den Hu-Momenteninvarianten sowie Deskriptoren für Wandkonfiguration und Eingangsposition – angemessen priorisiert. Eine solche Gewichtung rein konzeptionell festzulegen, erscheint schwierig. Alternativ könnten diese Gewichte durch ein zusätzliches maschinelles Lernmodell erlernt werden, bei dem die Dimensionen des kombinierten Raums als Prädiktorvariablen und ein Passungsindex als Zielvariable dienen. Da derzeit jedoch kein Datensatz existiert, der alle benötigten Informationen enthält, fiel das Training eines solchen Modells außerhalb des Rahmens dieses Projekts.

Tabelle 6: Performance des Form-Ähnlichkeitesalgorithmus basierend auf den Momentinvarianten von Hu im Datensatz.

Target shape	Match #1	Match #2	Match #3
			
			
			
			
			
			

4.2 Umrisspotential

4.2.1 Einführung

Der architektonische Entwurfsprozess ist oft iterativ, komplex und zeitaufwändig, insbesondere wenn es darum geht, ein vorgegebenes Raumprogramm in eine bestimmte Grundrissgliederung einzupassen. In diesem Kapitel stellen wir einen Ansatz vor, der mithilfe von maschinellem Lernen die zentralen Merkmale von Wohngrundrissen auf Basis ihrer Umrisse vorhersagen kann. Ziel ist es, Architekten dabei zu unterstützen, gestalterische Einschränkungen frühzeitig zu erkennen und unnötigen Aufwand in unpassende oder ineffiziente Wohnungsaufteilungen zu vermeiden.

Die Heuristik „Umrisspotential“ zielte darauf ab, das Potenzial eines Wohnungsumrisses zu bewerten, um spezifische Qualitäten zu erreichen. Beispielsweise könnte die Frage beantwortet werden, ob sich innerhalb eines gegebenen Umrisses drei Schlafzimmer platzieren lassen und ob das Badezimmer dabei noch über ein Fenster verfügt. Solche Analysen ermöglichen es, bereits in einer frühen Planungsphase zu klären, ob ein Grundriss den Anforderungen eines Raumprogramms entspricht, bevor zeit- und arbeitsintensive Planungsarbeiten beginnen.

4.2.2 Datenrepräsentation

Für die Repräsentation der Wohnungen wurden globale und lokale Merkmale aus den Grundrissen extrahiert. Globale Merkmale liefern Aussagen über die geometrische Struktur jedes Grundrisses. Insgesamt wurden 48 globale Merkmale extrahiert, darunter Metriken wie Umfang, Fläche, maximaler Durchmesser, Rundheit, Kompaktheit und Fraktalität.

Lokale Merkmale hingegen erfassten detaillierte kontextuelle Eigenschaften, die sich auf interne Merkmale des Grundrisses auswirken können. Dazu zählen Merkmale, wie beispielsweise die Orientierung der Wände, das Vorhandensein von Fenstern oder die Nähe zu potenziellen Lärmquellen (z. B. Autobahnen, Straßen oder Schienen). Um die Variabilität der Merkmalsanzahl zu berücksichtigen, wurden diese lokalen Merkmale mithilfe von Graph-Embedding Techniken auf eine Standardanzahl normiert. Diese Technik transformierte die Eigenschaften von Kanten und Knoten in einen Vektor mit fester Länge, der für neuronale Netzwerke geeignet ist. Dadurch blieb die Länge des Eingabevektors konsistent, unabhängig von der Anzahl der Segmente in einem Grundriss.

Die finale Datenrepräsentation jedes Grundrisses kombinierte die 48 globalen Merkmale mit den 64 eingebetteten lokalen Merkmalen, was zu einem umfassenden Merkmalsvektor führte.

4.2.3 KI-Modell

Um die wichtigsten Merkmale eines Grundrisses basierend auf seiner Gliederung vorherzusagen, haben wir eine Deep Neural Network (DNN)-Architektur implementiert. Aufgrund der nichtlinearen Beziehung zwischen der äußeren Umrissgestaltung und der internen Konfiguration von Wohneinheiten bot sich ein DNN an, da es in der Lage ist, komplexe Muster in Daten zu erkennen und zu lernen. Das Modell wurde mit dem gefilterten Datensatz mit über 20.000 Wohngrundrissen trainiert (siehe 3.2.1), um insgesamt 11 verschiedene Merkmale vorherzusagen (siehe Tabelle 7). Diese umfassten unter anderem die Anzahl der Räume, das

Vorhandensein von Loggien oder Balkonen sowie konfigurationsbezogene Eigenschaften wie die Zirkulationseffizienz und die Raumbeziehungen.

Zur Feinabstimmung des Modells führten wir eine Rastersuche im Hyperparameterraum durch. Die untersuchten Parameter umfassten:

- Dropout-Raten: [0,3; 0,4; 0,5],
- L2-Regularisierungsparameter: [0,0001; 0,001; 0,01],
- Anzahl der Schichten: 1–7,
- Anzahl der Einheiten pro Schicht: [64; 128; 256].

Die Modellperformance wurde anhand des Verlusts auf dem Validierungssatz bewertet. Hierbei berechneten wir einen kombinierten Verlust als ungewichtete Summe der Verluste für jede Ausgangsvariable. Für binäre Variablen (z. B. das Vorhandensein eines Balkons) verwendeten wir die gewichtete binäre Kreuzentropie, während für kontinuierliche Variablen (z. B. die Sonneneinstrahlung in Räumen) der mittlere quadratische Fehler (Mean Squared Error, MSE) zum Einsatz kam.

Das Modell wurde mithilfe des Adam-Optimierers mit einer Lernrate von 0,0001 trainiert. Das Training umfasste maximal 500 Epochen. Eine frühzeitige Stoppregel wurde implementiert, wobei das Training abgebrochen wurde, wenn der Validierungsverlust über 20 aufeinanderfolgende Epochen keine Verbesserung von mindestens 0,001 zeigte. In diesem Fall wurden die Modellgewichte zurückgesetzt, die den geringsten Verlust erzielt hatten.

Für die Studie wurde der Datensatz in einem Verhältnis von 60:20:20 aufgeteilt, was 11.106 Grundrissen für das Training, 3.702 für die Validierung und 3.702 für den Testsatz entspricht. Je nach Art der zu prognostizierenden Variablen kamen unterschiedliche Verlustfunktionen zum Einsatz: Für kategoriale Variablen wie das Vorhandensein von Balkonen oder offenen Küchen wurde die gewichtete binäre Kreuzentropie genutzt, um Klassenungleichgewichte zu berücksichtigen. Für kontinuierliche Variablen wie die Sonneneinstrahlung in Wohnräumen wurde der mittlere quadratische Fehler verwendet. Die kombinierte Verlustfunktion, bestehend aus der Summe der individuellen Verluste, sorgte für ein ausgewogenes Lernziel zwischen kategorialen und kontinuierlichen Ausgaben.

Die DNN-Architektur erwies sich als äußerst effektiv, um die komplexen Beziehungen zwischen den Grundrissumrissen und ihren internen Konfigurationen zu erfassen. Dies umfasste sowohl geometrische als auch räumliche Merkmale. Durch den Einsatz von Deep Learning konnte das Modell abstrakte Muster in den Daten erkennen und auf zuvor unbekannte Grundrisse verallgemeinern.

4.2.4 Ergebnisse

Das Modell zeigte eine gute Vorhersagegenauigkeit für kategoriale Merkmale. Insbesondere war es in der Lage, binäre Variablen wie das Vorhandensein von Balkonen, Loggien oder offenen Küchen mit einer durchschnittlichen Genauigkeit von 83 % und Sensitivitäts- und Spezifitätswerten zwischen 76 % und 92 % vorherzusagen. Dieser Genauigkeitsgrad deutet darauf hin, dass das Modell die wesentlichen Beziehungen zwischen dem Umriss und den

Layout-Elementen effektiv erfasst hat, was Architekten in den frühen Entwurfsphasen ein nützliches Werkzeug darstellt.

Bei der Vorhersage der Anzahl der Räume erreichte das Modell eine Genauigkeit von 74,2 %, und in den meisten Fällen, in denen die Vorhersage falsch war, lag sie nur um einen Raum daneben (siehe Abbildung 13). Dies deutet darauf hin, dass das Modell gut kalibriert wurde, um die strukturellen Einschränkungen zu identifizieren, die durch den Entwurf auferlegt werden, und wie sie sich in der Anzahl der Räume im endgültigen Layout niederschlagen.

Prediction \ Truth	1	2	3	4	5
1	99	6	0	0	0
2	99	566	58	0	0
3	1	175	1160	217	2
4	0	5	226	900	164
5	0	0	1	0	23

Abbildung 13: Klassifizierungsgenauigkeit des Modells in Bezug auf die Variable Anzahl der Zimmer.

Bei den kontinuierlichen Variablen, wie der Erschließungseffizienz, der Sonneneinstrahlung im Wohnzimmer und dem Geräuschpegel, erzielte das Modell eine eher moderate Performance (siehe Tabelle 7 und Abbildung 14). Es konnte bis zu 40 % der Varianz für die Erschließungseffizienz und den Geräuschpegel im Wohnzimmer erklären, während die erklärte Varianz für andere Merkmale, wie die Sonneneinstrahlung, mit etwa 18–26 % geringer ausfiel. Die mittleren absoluten Fehler (MAE) lagen für die Erschließungseffizienz bei 0,03 und für die Zentralität (Mean Depth) bei 0,14.

Die Ergebnisse zeigten, dass das Modell bei kontinuierlichen Merkmalen zwar eine geringere Präzision aufweist, aber dennoch hilfreiche Informationen für die Bewertung von Grundrissen in der frühen Planungsphase liefern kann. Trotz der begrenzten Genauigkeit unterstützen diese Metriken die Einschätzung der Eignung eines Grundrisses und können Architekten wertvolle Orientierungspunkte für die weitere Gestaltung bieten.

Tabelle 7: Zusammenfassung der Modellperformance.

Continuous Variable	MAE	R2
Circulation efficiency	0.03	.40
Living room sunlight (klx)	0.29	.18
Living room noise (db)	7.11	.40
Kitchen sunlight (klx)	0.80	.26
Mean depth (step)	0.14	.29
Binary Variables	Sensitivity	Specificity
Loggia	.83	.85
Balcony	.84	.74
Natural bathroom ventilation	.76	.78
2nd bathroom	.89	.92
Open plan kitchen	.82	.83

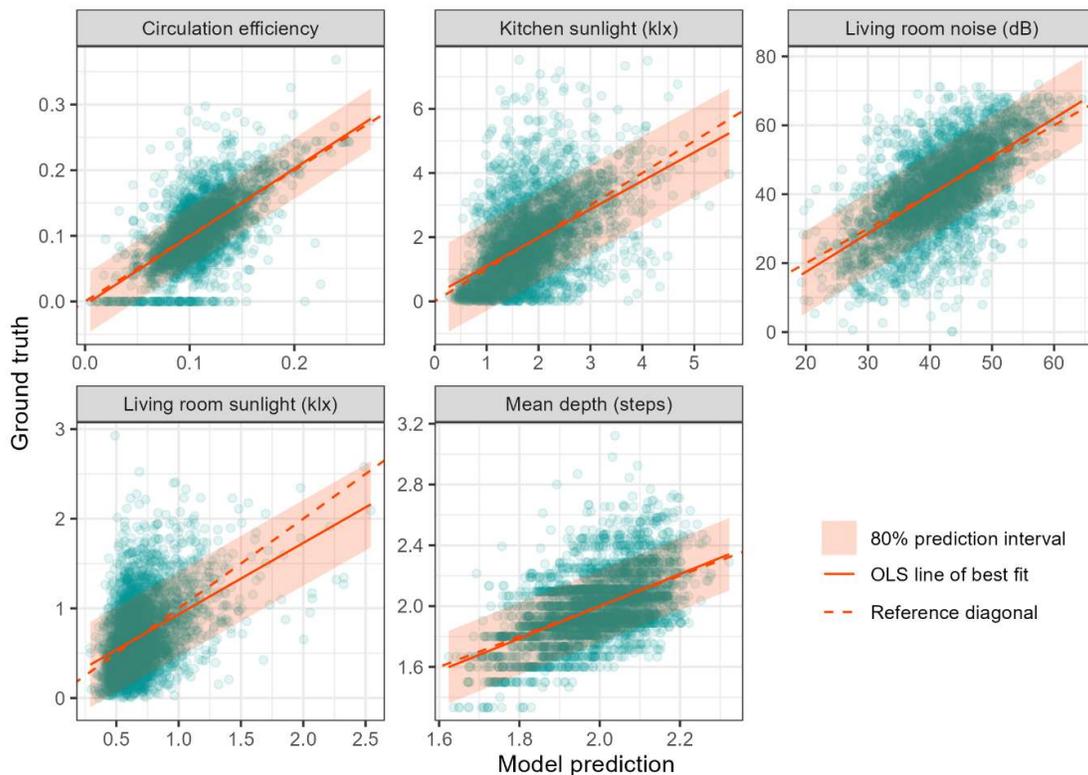


Abbildung 14: Streudiagramme der Modellvorhersage vs. Ground Truth für jede der fünf kontinuierlichen Variablen mit überlagerten Regressionsgeraden und 80 % Vorhersageintervallen.

Die hohe Genauigkeit bei der Vorhersage kategorialer Merkmale deutet darauf hin, dass der Umriss eines Grundrisses erhebliche Einschränkungen für die Raumkonfiguration vorgibt. Dies impliziert, dass maschinelles Lernen als Vorhersagewerkzeug Architekten dabei unterstützen kann, schnell zu beurteilen, ob eine bestimmte Raumaufteilung grundlegende Anforderungen (wie die Anzahl der Zimmer oder das Vorhandensein von Balkonen, offener Küchen oder eines zweiten Badezimmers) erfüllt.

Bei Merkmalen wie der Erschließungseffizienz und der Zentralität erzielte das Modell eine solide Genauigkeit. Die akzeptablen Fehlermargen zeigen, dass es allein anhand der Kontur wertvolle Einblicke in die räumliche Konfiguration liefert. So konnte die Erschließungseffizienz – das Verhältnis der Korridorfläche zur Gesamtfläche – präzise vorhergesagt werden, ebenso wie die Zentralität, welche topologische Abstände zwischen Räumen beschreibt.

Wir schließen, dass ein Wohnungssumriss genügend Informationen enthält, um wesentliche Grundrissmerkmale präzise vorherzusagen. Diese Merkmale können als emergente Eigenschaften der durch den Umriss vorgegebenen Einschränkungen betrachtet werden.

Kontextabhängige Merkmale, wie beispielsweise Lärm und Sonneneinstrahlung, konnten vom Modell weniger präzise vorhergesagt werden. Dies liegt vermutlich daran, dass diese Merkmale weniger vom Umriss selbst, sondern vielmehr von externen Faktoren wie Verkehrsaufkommen oder der umliegenden, verschattenden Bebauung beeinflusst werden.

Mit den stetig wachsenden Möglichkeiten der Technologie des maschinellen Lernens wird die zukünftige Forschung in der Lage sein, den Umfang und die Genauigkeit von Modellen zur Vorhersage architektonischer Qualitäten weiter zu verbessern. Dies wird Architekten nicht nur von unnötigen Entscheidungen entlasten, sondern ihnen auch ermöglichen, ihre Zeit und Energie auf die kreativsten und innovativsten Aspekte ihres Handwerks zu konzentrieren.

4.3 Raumdiagramme

4.3.1 Einführung

In diesem Abschnitt stellen wir eine Methode zur Erstellung von Raumdiagrammen vor. Diese Diagramme verdeutlichen die räumliche Anordnung und Beziehungen der einzelnen Räume, um die Anforderungen eines Wohnungsgrundrisses bestmöglich zu erfüllen. Ziel ist es, Planern aufzuzeigen, welche Raumbeziehungen sinnvoll sind und wo Optimierungen erforderlich sein könnten, um eine optimale Raumaufteilung zu erreichen. Zur Umsetzung dieser Methode verwenden wir Graph Neural Networks (GNNs).

GNNs sind eine Deep-Learning-Technik, die neue Möglichkeiten für die Vorhersage und Generierung von Grundrissen eröffnet. GNNs können Graphendaten verarbeiten, die in der Bild- und Sprachverarbeitung eher selten, aber in Bereichen wie sozialen Netzwerken, chemischen Molekülen und Verkehrsnetzwerken weit verbreitet sind. Die Knoten und Kanten eines Graphs können mit umfangreichen Informationen versehen werden [Wu et al., 2022]. GNNs sind in der Lage, Abhängigkeiten zwischen Knoten durch einen sogenannten "Message-Passing-Mechanismus" zu erfassen, Informationen aus benachbarten Knoten zu aggregieren und die Repräsentationsvektoren der Knoten so lange zu aktualisieren, bis ein stabiles Gleichgewicht erreicht ist. Obwohl GNNs noch eine relativ neue Technologie darstellen, beginnen immer mehr Forscher, ihre Anwendung im architektonischen Entwurf zu erkunden. Graphen eignen sich besonders gut für die vektorbasierten geometrischen Repräsentationen, die häufig in der Architektur verwendet werden, da sie umfangreiche geometrische und attributive Informationen enthalten. Darüber hinaus können GNNs die topologischen und attributiven Beziehungen zwischen vektorbasierten geometrischen Entitäten effektiv lernen, was sie zu einer vielversprechenden Methode für die Generierung oder Vorhersage von Grundrissen macht.

Mit der Heuristik „Raumdiagramme“ zielten wir darauf ab, ein GNN-Modell für die Vorhersage von im Grundriss verorteten topologischen Diagrammen zu entwickeln (Abbildung 15).

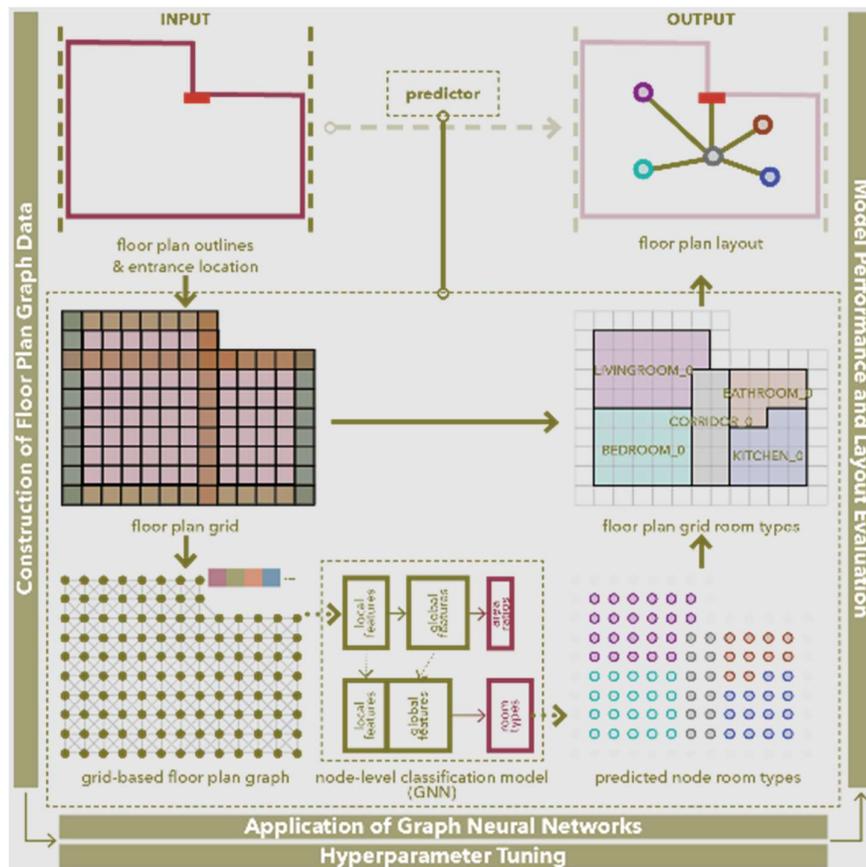


Abbildung 15: Ablaufdiagramm.

4.3.2 KI-Modell

Zur Vorhersage von Raumdiagrammen nutzen wir ein rasterbasiertes Modell. Die Aufgabe bestand darin, den Raumtyp jeder Rasterzelle innerhalb eines Grundrisses vorherzusagen – ähnlich der semantischen Segmentierung von Punktwolken. Um diese Aufgabe zu bewältigen, haben wir ein Modell entwickelt, das auf der PointNet-Architektur [Charles et al., 2017] und einem Graph Convolutional Neural Network (GCN) basiert. Dieses Modell nutzt rasterbasierte Grundrissdiagramme als Eingabedaten, um die Raumtypen der Rasterknoten zu klassifizieren.

Das Modell besteht aus vier zentralen Modulen: einem Modul zur lokalen Merkmalsanalyse (Local Feature Learning Module), einem Modul zur globalen Merkmalsanalyse (Global Feature Learning Module), einem Knotenklassifizierungsmodul (Node Classification Module) und einem Hilfsmodul zur Vorhersage des Raumflächenverhältnisses (Room Area Ratio Prediction Module) (siehe Abbildung 16):

- Das **Local Feature Learning Module** zielt darauf ab, die lokalen Merkmale jedes Knotens aus den rasterbasierten Grundrissdiagrammdaten zu extrahieren, um räumliche Informationen und kontextuelle Beziehungen zu benachbarten Knoten zu erfassen. Dieses Netzwerk besteht aus drei wesentlichen Teilen: Spatial Alignment Network (T-Net), Message Passing and Aggregation Network (GCN) und Feature Alignment Network (T-Net).

- Das **Global Feature Learning Module** zielt darauf ab, die globalen Merkmale des rasterbasierten Grundrissdiagramms zu erfassen, um umfassendere Kontextinformationen bereitzustellen. Dieses Modul besteht aus mehreren Graph-Convolutional Neural Network-Schichten und einer globalen Graph-Max-Pooling-Schicht für die weitere Informationsweitergabe und Feature-Aggregation. Durch die Vergrößerung des rezeptiven Feldes kann dieses Netzwerk Informationen in größerem Maßstab erfassen, um die Merkmale des gesamten Grundrissdiagramms umfassender zu beschreiben.
- Das **Node Classification Prediction Module** ist der letzte Schritt des Modells, der verwendet wurde, um gelernte lokale und globale Features auf die Knotenklassifizierungsaufgabe anzuwenden. Dieses Netzwerk verkettet lokale und globale Merkmale und führt eine Klassifizierungsvorhersage durch Multiple Perceptron (MLP) durch. Jeder Knoten gibt einen Wahrscheinlichkeitswert für jede Zimmerkategorie aus, um den Zimmertyp des Knotens vorherzusagen.
- Um das Erlernen von Merkmalen weiter zu optimieren, führten wir ein Zusatzmodul ein, das **Room Area Ratio Prediction Module**. Dieses Modul zielt darauf ab, dem Modell zu helfen, Merkmale besser zu verstehen, indem es die Flächenverhältnisse verschiedener Raumtypen vorhersagt. Dieses Zusatzmodul verwendet globale Merkmale als Eingabe und führt eine Regressionsvorhersage durch multiple Perzeptrons (MLP) durch, um die Flächenverhältnisse verschiedener Raumtypen auszugeben. Das Modell kann die Bedeutung und Verteilung verschiedener Raumtypen in der Wohnaufteilung besser erfassen, indem es diese Flächenverhältnisse vorhersagt.

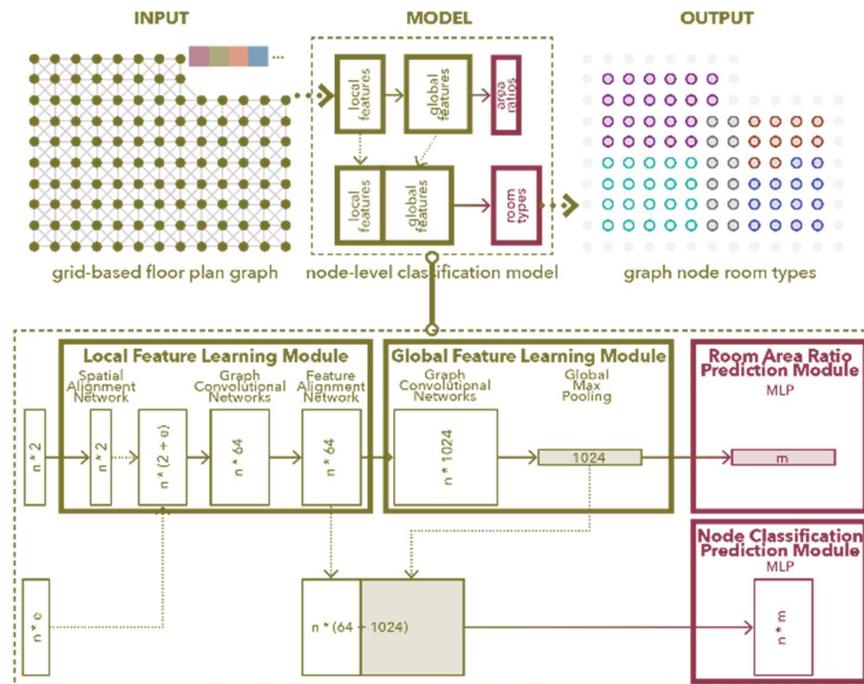


Abbildung 16: Architektur des Modells zur Vorhersage des Grundrisslayouts.

Um sicherzustellen, dass das Modell robust gegenüber starren Transformationen wie Verschiebung, Rotation oder Skalierung bleibt, haben wir das Konzept des T-Net (Transformationsnetzwerk) aus PointNet übernommen. Zusätzlich wurde GCN integriert, um flexible Eingabedaten zu verarbeiten und unabhängig von deren Reihenfolge zu bleiben. Dies

erleichtert die Weitergabe und Aggregation von Informationen zwischen den Knoten und verbessert die Modellperformance.

Evaluation

Das Modell wurde hinsichtlich zwei Kriterien getestet: Bewertung der Knotenklassifizierung und Bewertung des generierten Grundrisslayouts auf der Grundlage der Ergebnisse der Knotenklassifizierung.

Für die Aufgabe der Knotenklassifizierung verwendeten wir die Genauigkeit als Bewertungsmetrik. Die Genauigkeit ist eine häufig verwendete Metrik, um den Anteil korrekt klassifizierter Stichproben in Vorhersagen zu messen. Für jede Raumkategorie berechneten wir das Verhältnis der korrekt vorhergesagten Knoten zur Gesamtzahl der Knoten in dieser Kategorie, um die Genauigkeit für diese Kategorie zu erhalten. Anschließend berechneten wir die durchschnittliche Genauigkeit über alle Kategorien hinweg als Gesamtklassifizierungsgenauigkeit des Modells (Abbildung 17).

$$ACC = \frac{\text{num. of correct predictions}}{\text{total num. of predictions}}$$

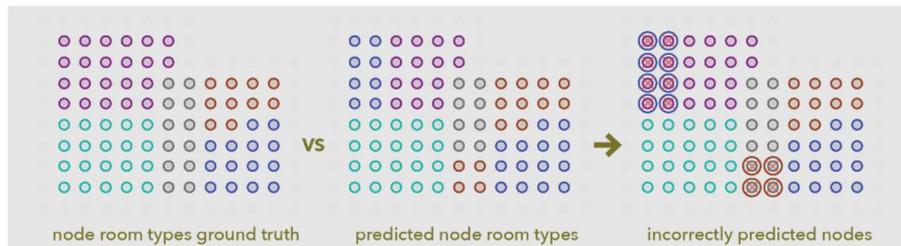


Abbildung 17: Berechnung der Genauigkeit der Knotenklassifizierung.

Da sich unsere Studie auf die Klassifizierung von Raumtypen auf Knotenebene und nicht auf Generierungsaufgaben konzentrierte, kann es einige Unterschiede zwischen den vorhergesagten und den tatsächlichen Grundrissen geben (Abbildung 18). Selbst wenn die Genauigkeit der Knotenklassifizierung relativ gering ist, kann der prognostizierte Grundriss dennoch sinnvoll sein. Aus diesem Grund führen wir Metriken zur Bewertung des Grundrisslayouts ein, einschließlich der Kombinationsmetrik für die Raumanzahl, der Metrik für die Raumtopologie und der geometrischen Metriken für den Raum.

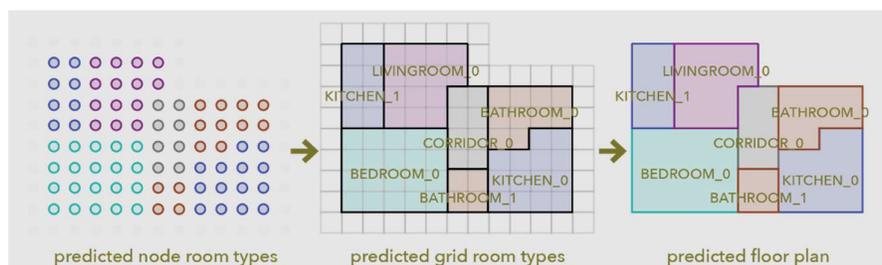


Abbildung 18: Vorhergesagte Knotenraumklasse für vorhergesagtes Grundrisslayout.

Die Metrik Raumanzahl bewertet, ob die Anzahl und Kombination der verschiedenen Raumtypen im vorhergesagten Layout mit denen im tatsächlichen Layout übereinstimmt

(Abbildung 19). Wir bewerteten dies, indem wir die vorhergesagten Zimmertypkombinationen mit Wohnungen mit ähnlichen Umrissen im Trainingsdatensatz verglichen.



Abbildung 19: Bewertungsmetrik für die Zimmeranzahl.

Mit der Metrik Raumtopologie wird bewertet, ob die Verbindungen zwischen Räumen im vorhergesagten Layout angemessen sind. Dazu vereinfachen wir die Raumverbindungen, indem wir einen Minimum Spanning Tree [MST; Hagberg et al., 2008] und vergleichen sie mit der MST für alle Layouts im Trainingsdatensatz (Abbildung 20).

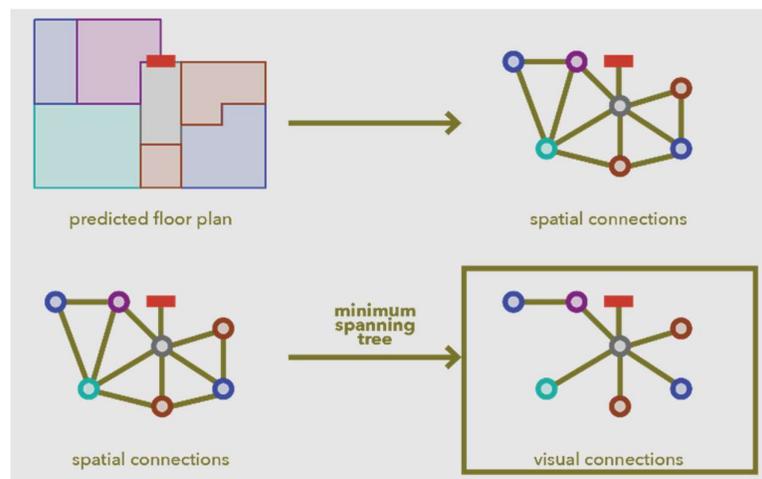


Abbildung 20: Metrik für die Raumtopologie.

Die Metrik zur Bewertung der Raumgeometrie besteht aus sechs Untermetriken. Zusammen bilden diese geometrischen Metriken einen mehrdimensionalen Bewertungsrahmen, der eine umfassende Bewertung der geometrischen Eigenschaften von Räumen mit Vorhersage ermöglicht (siehe Abbildung 21)

- Die Raumfläche misst die Flächengröße einzelner Räume im vorhergesagten Layout und stellt sicher, dass die Raumgrößen den Wohn- und Funktionsanforderungen entsprechen.
- Die kürzeste Kante misst die Länge der kürzesten Kante eines Raums.
- Die längste Kante misst die Länge der längsten Kante eines Raums.
- Die Fraktalität des Raumes [Wentz, 2000] charakterisiert die Komplexität und Unregelmäßigkeit von Raumgrenzen.

$$FR = 1 - \frac{\log(area)}{\log(perimeter)}$$

- Die geometrische Rundheit [Haralick et al., 1992] misst die Nähe einer Raumform zu einem idealen Kreis und charakterisiert Glätte und Winkligkeit der Raumform.

$$DI = \frac{1}{N} \sum_{i \in N} |p - p_i| \quad \sigma^2 = \frac{1}{N} \sum_{i \in N} (|p - p_i| - DI)^2 \quad RO = 1 - \frac{\sigma}{DI}$$

- Die Rechteckigkeit [Basaraner et al., 2017] bewertet die Ähnlichkeit zwischen einem Raum und seinem minimalen umgebenden Rechteck und quantifiziert die Regelmäßigkeit der Raumform.

$$RE = \frac{area}{area_{MBR}}$$

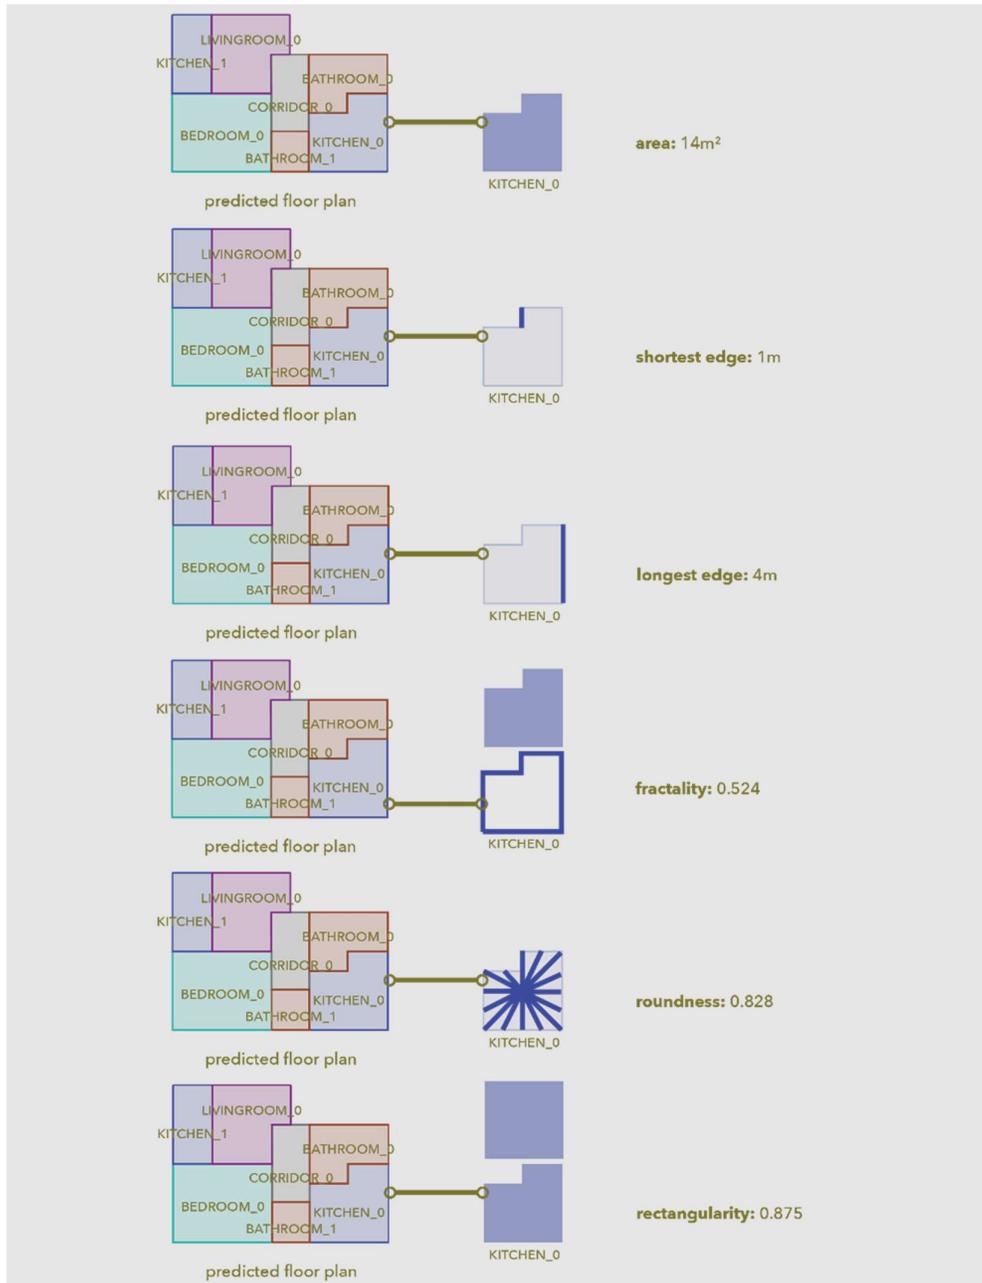


Abbildung 21: Maße zur Charakterisierung der Raumgeometrie.

4.3.3 Datenaufbereitung

Ziel des Modells war es, die räumlichen Standorte und topologischen Beziehungen verschiedener Raumtypen auf der Grundlage vektorbasierter Wohnungsumrisse und Eingangspositionen als Eingaben vorherzusagen. Zu diesem Zweck führten wir eine Datenaufbereitung durch und erstellten separate Grundrissdarstellungen sowohl für die Modellinputs und -outputs.

Datenaufbereitung

Der gefilterte Datensatz (3.2.1) enthält auch Wohnungen, die zwar denselben Grundriss, jedoch unterschiedliche Merkmale (z. B. Tageslicht) aufweisen, da sie sich auf verschiedenen Etagen desselben Gebäudes befinden. Um den Einfluss redundanter Daten zu minimieren, wählten wir für jedes Gebäude die Wohnungen im ersten Stock als Erststichprobe aus. Durch diesen Auswahlprozess identifizierten wir etwa 8.000 Wohnungen. Zur weiteren Verbesserung der Genauigkeit der Wohnungsgeometriedaten führten wir eine gründliche Überprüfung und manuelle Korrektur der geometrischen Entitäten für 1.000 Wohnungen durch. Diese dienten als experimentelle Stichprobe.

Um die Darstellung der Grundrissdiagramme und das Modelltraining zu erleichtern, vermieden wir eine übermäßige Diversität in den Wohnungsausrichtungen. Deshalb standardisierten wir die Ausrichtung der korrigierten 1.000 Wohnungen (siehe Abbildung 22). Dazu erzeugten wir ein sog. straight skeleton [Aichholzer et al., 1996] jeder Wohnung basierend auf ihrem Umriss und bestimmten die längste innere Winkelhalbierende als Hauptachse. Durch eine entsprechende Drehung richteten wir diese Hauptachse entweder entlang der x- oder y-Achse aus.

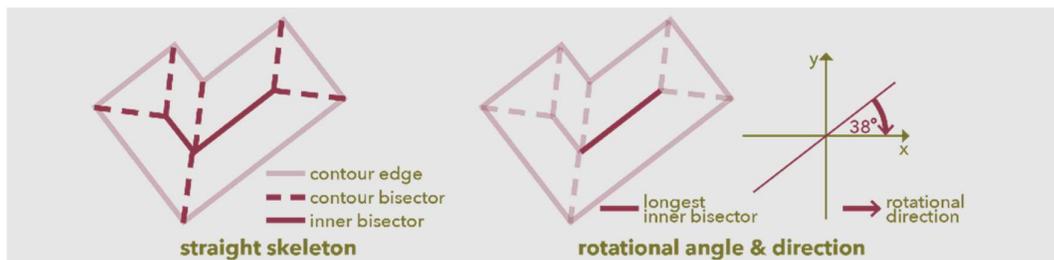


Abbildung 22: Standardisierung der Grundrissorientierung.

Nach den oben genannten Schritten erhalten wir die endgültigen Grundrissdaten (Abbildung 23) die Raumtypen, geometrische Daten für Räume, Türen und Fenster sowie den Wohnungsumriss und den Grundriss enthalten. Diese Daten bieten eine genaue und konsistente Grundlage für die anschließende Darstellung des Grundrissdiagramms.

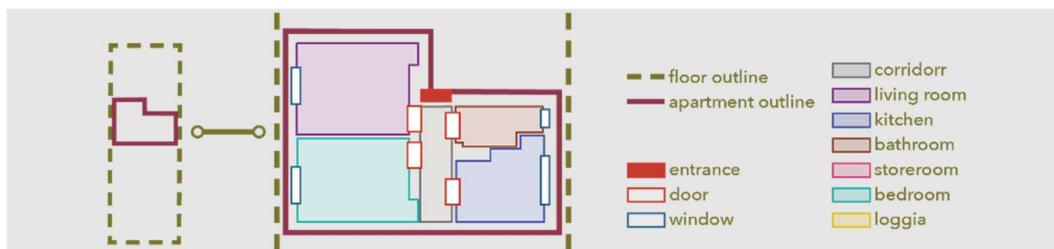


Abbildung 23: Grundrissdaten nach vollständiger Aufbereitung.

Darstellung eines rasterbasierten Grundrissdiagramms

Die Umwandlung von verarbeiteten, vektorbasierten Grundrissen in eine graphische Darstellung bildet eine zentrale Grundlage für die automatische Vorhersage des Grundrisslayouts. Die Diagrammdarstellung erfasst umfassende geometrische, semantische und topologische Informationen aus dem Grundriss und stellt die notwendigen Ein- und Ausgabedaten für das Training des GNN-Modells bereit.

Aufgrund der Komplexität, Raumpositionen direkt aus der Polylinien-Darstellung des Wohnungsumrisses vorherzusagen, führen wir einen Zwischenschritt ein. Dabei vereinfachen wir den vektorbasierten Grundriss in ein strukturiertes, regelmäßiges Raster mit einer Auflösung von 1 m x 1 m (siehe Abbildung 24). Dieses Raster dient als Grundlage für die Erstellung des Grundrissdiagramms. Die rasterbasierten Diagramme bestehen ebenfalls aus Knoten und Kanten ($G = (V, E)$).

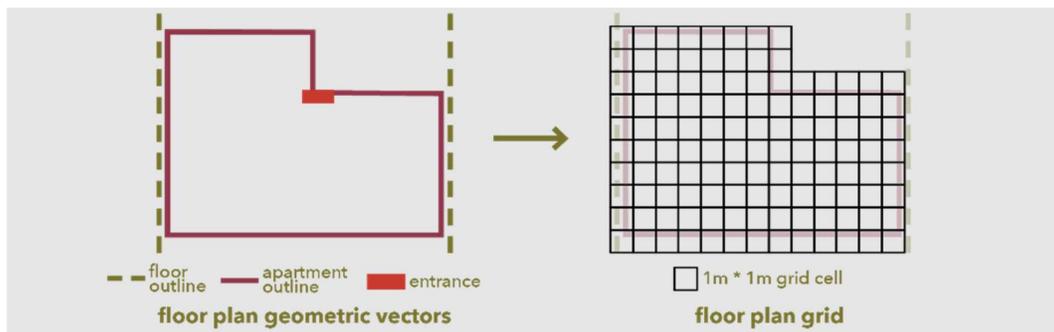


Abbildung 24: Grundrissraster.

Knoten

In unserem Modell wird jede Rasterzelle als Knoten betrachtet. Jeder Knoten kann mehrere Features als Eingabedaten des Modells enthalten, einschließlich der räumlichen Koordinate, des Entitätstyps, der relativen Position und der räumlichen Merkmale (Tabelle 8). Diese Funktionen bieten umfangreiche Kontextinformationen für Knotenklassifizierungsaufgaben:

- **Räumliche Koordinaten:** Die räumliche Position der einzelnen Knoten wird durch ihre X- und Y-Koordinaten definiert, die sich auf die untere linke Ecke des Rasters beziehen (siehe Abbildung 25).
- **Entitätstyp:** Diese beschreiben die architektonischen Attribute der Knoten, wie z. B. "Wand", "Außen", "Innen", "Ecke", "Eingang" und "Boden". Die Zuordnung der Merkmale erfolgt anhand der Überlappung zwischen dem Raster und dem Wohnungsumriss (siehe Abbildung 26).
- **Relative Position:** Diese unterstützen das Verständnis der relativen Position und Ausrichtung der Knoten. Dazu berechnen wir den direkten Abstand jedes Knotens sowohl zum zentralen Knoten als auch zum Eingangsknoten ('c_length' und 'e_length'). Außerdem bestimmen wir die Winkel relativ zu den x- und y-Achsen ('c_xangle', 'c_yangle', 'e_xangle' und 'e_yangle') (siehe Abbildung 27).
- **Raumachsen:** Diese erweitern die Beschreibung der Standortattribute der Knoten. Hierbei werden den Knoten Merkmale basierend auf ihrer Position relativ zum Eingang, zu den Eckknoten und zur Hauptachse der Wohnung zugewiesen (siehe Abbildung 27).

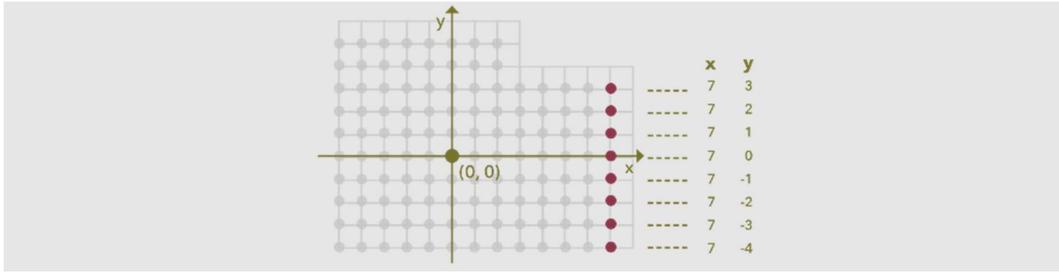


Abbildung 25: Raumkoordinaten.

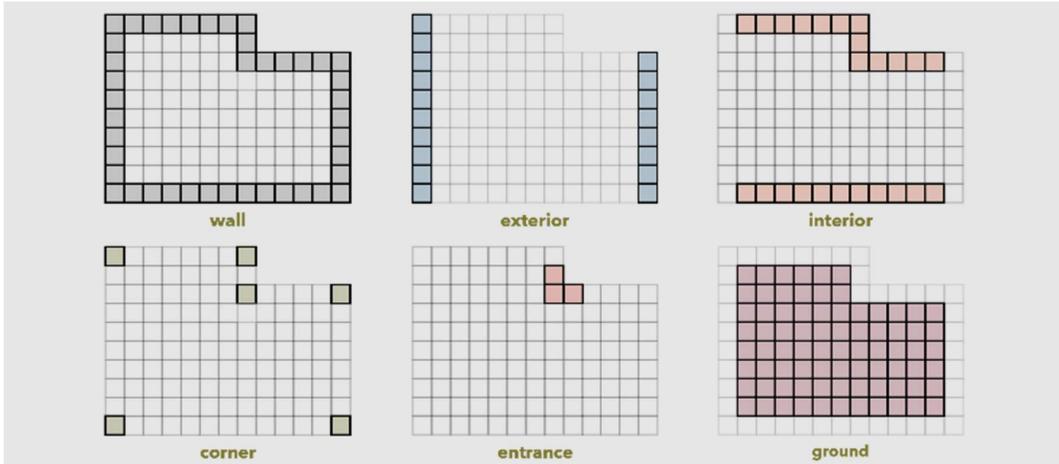


Abbildung 26: Entitätstyp.

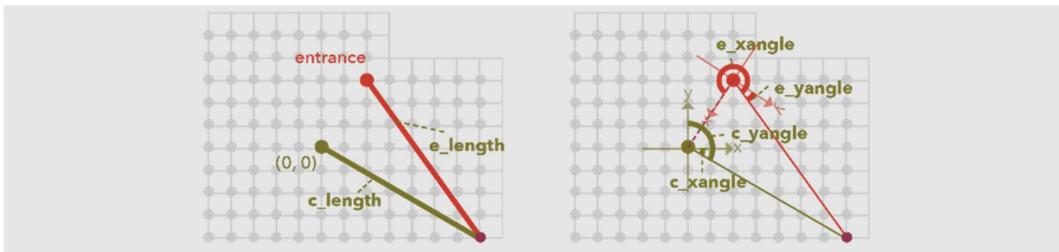


Figure 27: Relative Position.

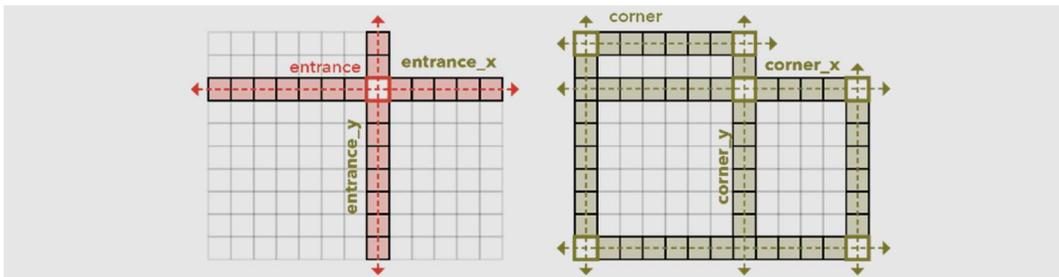


Figure 28: Raumachsen.

Tabelle 8: Knoteneigenschaften.

FEATURE TYPE	FEATURE					
Spatial Coordinate Features	x	y				
Entity Type Features	wall	exterior	interior	corner	entrance	ground
Relative Position Features	c_length	c_xangle	c_yangle	e_length	e_xangle	e_yangle
Spatial Identifier Features	corner_x	corner_y	entrance_x	entrance_y		

Neben den räumlich-geometrischen Eigenschaften, wurden die Nutzungen der Räume in den Knoten gespeichert:

- Raumtyp: Es gibt 7 Haupttypen: "FLUR", "WOHNZIMMER", "KÜCHE", "BAD", "ABSTELLRAUM", "SCHLAFZIMMER" und "LOGGIA" (Abbildung 29).
- Unterkategorien für Räume: Die Unterzimmertypen verfeinern die Zimmertypen weiter. Es gibt 21 Unterraumtypen: 'CORRIDOR_0', 'CORRIDOR_1', 'CORRIDOR_2', 'LIVINGROOM_0', 'LIVINGROOM_1', 'KITCHEN_0', 'BATHROOM_0', 'BATHROOM_1', 'BATHROOM_2', 'STOREROOM_0', 'STOREROOM_1', 'STOREROOM_2', 'STOREROOM_3', 'ROOM_0', 'ROOM_1', 'ROOM_2', 'ROOM_3', 'ROOM_4', 'LOGGIA_0', 'LOGGIA_1', 'LOGGIA_2'. Die Codierungswerte von Unterraumtypen werden durch den Abstand vom geometrischen Mittelpunkt der Raumeinheit zum Eingang bestimmt. Je näher sich ein Objekt am Eingang befindet, desto kleiner ist der entsprechende Codierungswert für den Unterraumtyp.

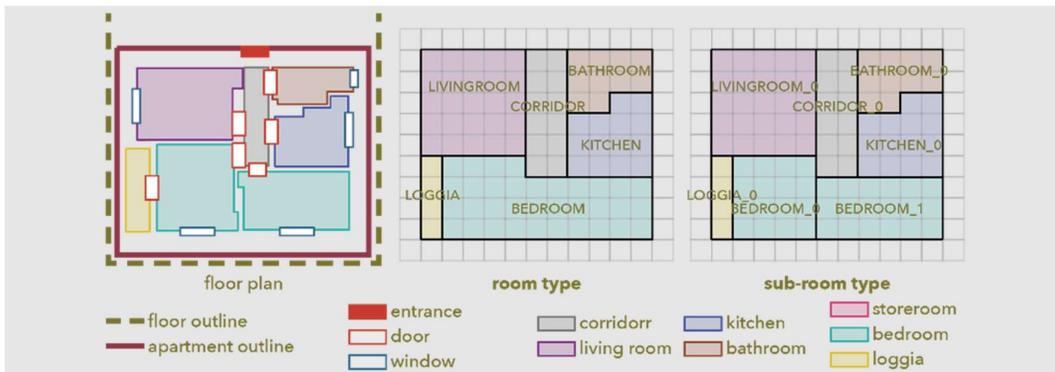


Abbildung 29: Labels für Raumfunktionen.

Tabelle 9: Knotenbeschriftungen.

FEATURE TYPE	FEATURE						
Room Type	CORRIDOR	LIVINGROOM	KITCHEN	BATHROOM	STOREROOM	BEDROOM	LOGGIA
Sub-Room Type	CORRIDOR_0	LIVINGROOM_0	KITCHEN_0	BATHROOM_0	STOREROOM_0	BEDROOM_0	LOGGIA_0
	CORRIDOR_1	LIVINGROOM_1		BATHROOM_1	STOREROOM_1	BEDROOM_1	LOGGIA_1
	CORRIDOR_2			BATHROOM_2	STOREROOM_2	BEDROOM_2	LOGGIA_2
					STOREROOM_3	BEDROOM_3	
						BEDROOM_4	

Kanten

Die Kanten zwischen den Knoten werden basierend auf der relativen Position der Raster bestimmt. Jeder Knoten ist mit seinen benachbarten Knoten verbunden. Um architektonische Einschränkungen zu berücksichtigen, fügen wir zusätzlich zusätzliche Kanten zwischen allen Knoten und Knoten mit speziellen Attributen hinzu (z. B. mittlerer Knoten, Eingangsknoten; Abbildung 30). Das Vorhandensein von Kanten wird durch eine Adjazenzmatrix (A) dargestellt.

$$A[i][j] \begin{cases} = 1, \text{if } ((v_i, v_j) \in E), (v_i, v_j \in V) \\ = 0, \text{if } ((v_i, v_j) \notin E), (v_i, v_j \in V) \end{cases}$$

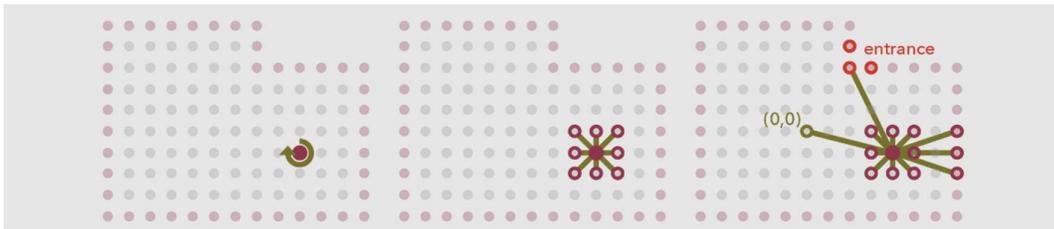


Abbildung 30: Kanten im Grundrissgraph.

Mit dieser Methode wandelten wir die 1.000 verarbeiteten Muster von Wohngrundrissen in Graphen um. Die rasterbasierten Grundrissdiagramme bildeten die Grundlage, um Knotenklassifizierungsmodelle für die automatisierte Vorhersage von Raumdiagrammen zu trainieren. Von den 1.000 Datensätzen nutzten wir 800 Stichproben als Trainingssatz, während die verbleibenden 200 Stichproben als Testsatz dienten.

4.3.4 Ergebnisse

Wir führten das Training des Modells über 50 Epochen durch. Dabei beobachteten wir während des Trainingsverlaufs ein typisches Verhalten, das auf ein Überanpassungsproblem hinweist. Zu Beginn der Ausbildung nahm sowohl der Trainingsverlust als auch der Testverlust stetig ab, was auf eine verbesserte Modellanpassung an die Daten hindeutete. Mit zunehmender Anzahl an Epochen zeigte sich jedoch, dass der Testverlust nach einem bestimmten Punkt wieder anstieg, während der Trainingsverlust weiter abnahm. Dieses Verhalten deutet darauf hin, dass das Modell die Trainingsdaten übermäßig gut auswendig lernte (Overfitting), anstatt generalisierbare Muster zu erfassen, die auf neue, ungesehene Daten angewendet werden könnten.

Die Auswertung der Modellperformance bestätigte diese Beobachtungen (Abbildung 31). Die Genauigkeit der Unterraumklassifizierung und der Raumklassifizierung für den Trainingssatz erreichte hohe Werte von 0,97 bzw. 0,98. Für den Testsatz lagen die entsprechenden Genauigkeiten jedoch deutlich niedriger bei 0,36 und 0,45. Diese Diskrepanz verdeutlichte, dass das Modell auf die Trainingsdaten optimiert war, sich jedoch nicht gut auf den Testsatz übertragen ließ.

Dieses Ergebnis legte nahe, dass die gewählte Modellarchitektur oder der Ansatz zur Knotenklassifizierung suboptimal war. Insbesondere könnte die geringe Testgenauigkeit darauf hindeuten, dass das Modell Schwierigkeiten hatte, die komplexen Beziehungen zwischen den

Knoten im Grundrissdiagramm zu verallgemeinern. Alternativ könnten auch Probleme wie eine unzureichende Regularisierung oder eine unbalancierte Verteilung der Klassen im Trainings- und Testsatz zu diesem Verhalten beigetragen haben.

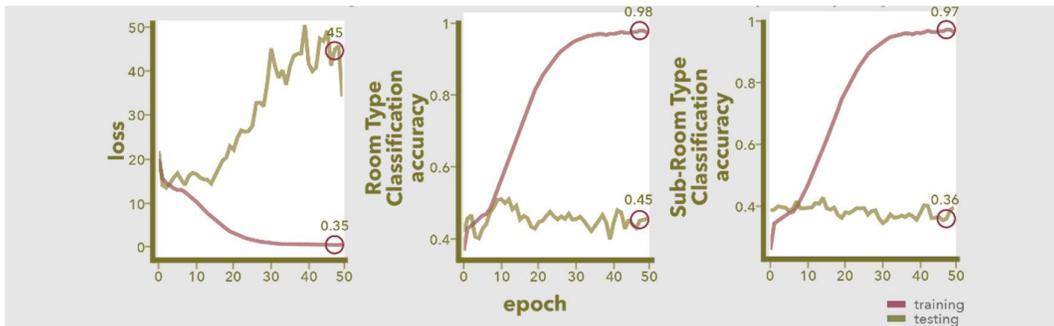


Abbildung 31: Loss und Accuracy der Knotenklassifizierung.

Obwohl die Genauigkeit der Knotenklassifizierung ein wichtiges Maß für die Modellperformance darstellte, erfasste sie nicht vollständig die Angemessenheit und Praktikabilität des vorhergesagten Grundrisslayouts. Aus diesem Grund führten wir eine ergänzende Bewertung des Grundrisslayouts hinsichtlich der Raumanordnung ein (siehe Abbildung 32). Die Ergebnisse zeigten Einschränkungen im vorhergesagten Layout, insbesondere in Bezug auf die Kombination der Raumanzahl und die Raumtopologie, wobei nur etwa 15 % korrekt vorhergesagt wurden.

In Bezug auf raumgeometrische Metriken erzielte das Modell gute Ergebnisse bei der Vorhersage von Räumen wie Fluren und Badezimmern (etwa 70 % wurden korrekt vorhergesagt), war jedoch bei anderen Raumtypen, wie z. B. Schlafzimmern, weniger genau. Dies deutete darauf hin, dass das Modell Schwierigkeiten hatte, das Lernen effektiv auszubalancieren, da die Vorhersage bestimmter Raumtypen unterschiedlich schwierig war.

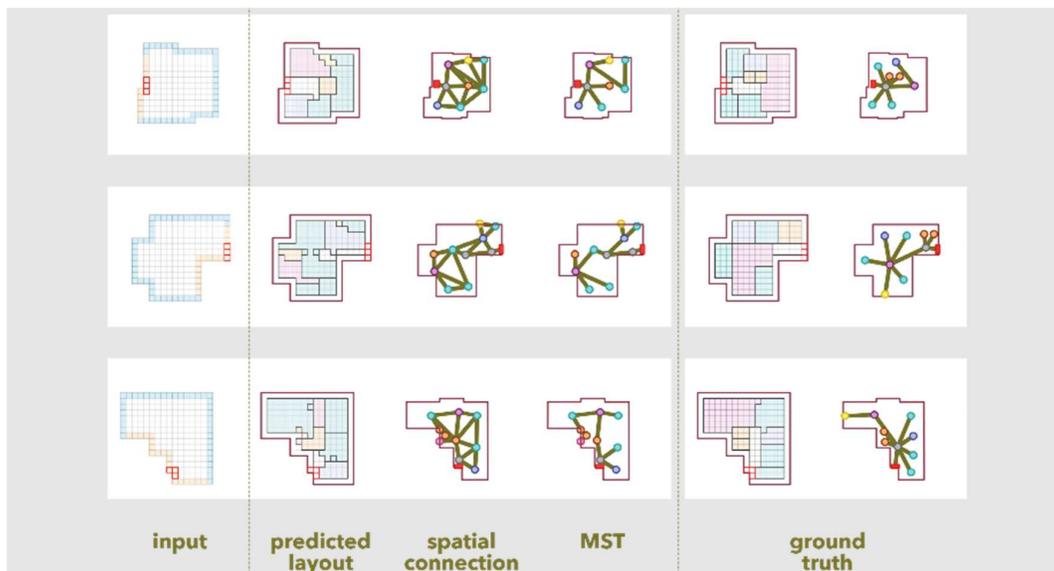


Abbildung 32: Eingabe - vorhergesagtes Grundrisslayout - Ground Truth.

Durch Experimente, die den gesamten Prozess von der Grundrissdarstellung über die Konstruktion des Layout-Vorhersagemodells bis hin zur Bewertung des Modells und des

vorhergesagten Layouts umfassten, stellten wir fest, dass die Vereinfachung der Grundriss-Layout-Vorhersage in eine Knotenklassifizierungsaufgabe die Komplexität des Layout-Designs möglicherweise nicht vollständig erfasste. Wir empfehlen für die Zukunft, Ansätze zu untersuchen, die Diagrammgenerierungsmodelle kombinieren, um Grundrisslayouts direkt zu generieren.

4.4 Grundrissgeometrie

4.4.1 Einführung

In diesem Kapitel wird die vierte und letzte Entwurfsheuristik unseres Projekts vorgestellt - die Erzeugung der konkreten Grundrissgeometrie. Diese Methode baut inhaltlich auf den Erkenntnissen der vorherigen Ansätze auf und konzentriert sich auf die genaue Positionierung von Wänden, Türen und Fenstern innerhalb des Gebäudeumrisses.

Für die Erzeugung der Grundrissgeometrie wurden zwei Ansätze untersucht: Der erste Ansatz basierte auf einem Generative Adversarial Network (GAN) und wurde im Rahmen einer vom Projektteam co-betreuten Masterthesis [Khamam, 2023] entwickelt. Der zweite Ansatz nutzte ein sog. Stable Diffusion Model. Das Kapitel beschreibt die genutzten Datenformate, die angewandten Modelle und die Ergebnisse der beiden Ansätze. Abschließend wurden die Herausforderungen und Vorteile dieser Methoden sowie ihre Eignung für die automatisierte Grundrissgenerierung diskutiert.

4.4.2 Datenrepräsentation

Um Machine-Learning-Modelle für die Generierung von architektonischen Grundrissen effektiv zu trainieren, war eine angemessene und detaillierte Darstellung der architektonischen Daten erforderlich. Dazu haben wir zwei Datensätze für die beiden Generierungsmethoden entwickelt:

GAN-basierter Ansatz

In der Anfangsphase des Projekts wurde ein kleiner Datensatz von 224 Wohngrundrissen kuratiert, vorverarbeitet und mit Anmerkungen versehen. Die Vorbereitung des Datensatzes umfasste das Parsen von ursprünglichen CAD-basierten Grundrissen in beschriftete Bilder, die von Modellen des maschinellen Lernens verarbeitet werden konnten. Der Datensatz enthielt gerasterte, beschriftete Grundrisse (256 x 256 Pixel) mit verschiedenen Farben, die wichtige Funktionsbereiche wie Wohnzimmer, Küchen, Bäder und Verkehrszonen darstellten. Diese Farbcodierung ermöglichte es dem Modell, zwischen verschiedenen Raumfunktionen zu unterscheiden und ihre räumlichen Beziehungen zu verstehen.

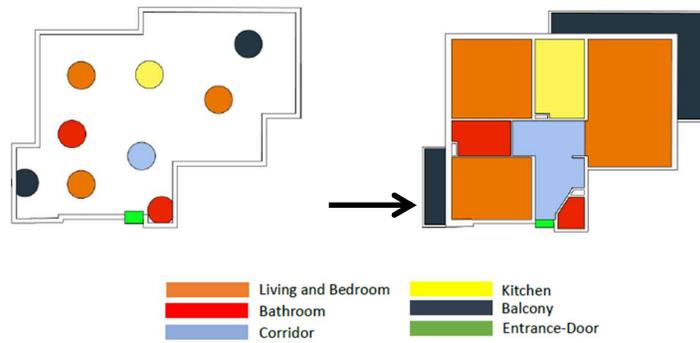


Abbildung 33: Eingabe- und Ausgabedaten beim GAN-basierten Ansatz [Khamam, 2023].

Stable Diffusion-Based Approach

Der zweite Datensatz umfasste die gesamte bereinigte Archlyse-Datenbank mit über 20.000 Wohngrundrissen (siehe 3.2.1). Der Input besteht aus einer vereinfachten Darstellung des Gebäudeumrisses mit farbcodierten Elementen wie Außenwänden (blau), Innenwänden (grün) und dem Eingang (rot). Zusätzlich wird ein textbasiertes Prompt (z. B. „floor plan, 3 rooms“) verwendet, das die Anforderungen an den Grundriss beschreibt. Der Output ist ein detaillierter Grundriss mit farbcodierten Raumtypen (z. B. Flur, Wohnraum, Küche) sowie Positionen von Türen und Fenstern. Diese Datenaufbereitung stellt sicher, dass das Stable-Diffusion-Modell sowohl geometrische als auch semantische Informationen über den Grundriss erhält.

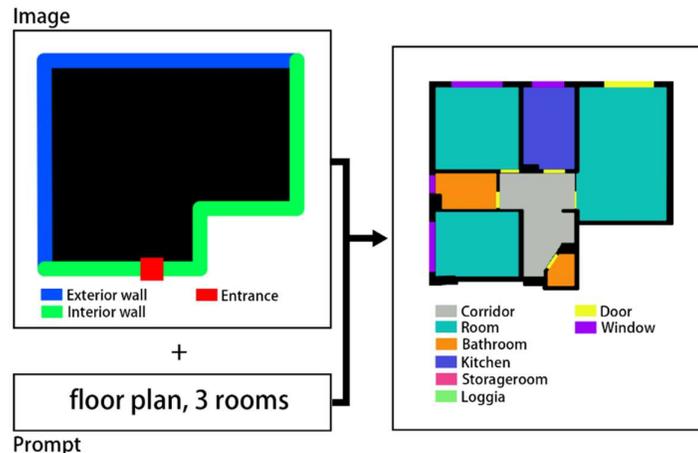


Abbildung 34: Eingabe- und Ausgabedaten beim Stable Diffusion basierten Ansatz.

4.4.3 KI-Modell

Generative Adversarial Network (GAN) – Pix2Pix

Der erste generative Ansatz basierte auf einem Conditional Generative Adversarial Network (cGAN) namens pix2pix [Isola et al., 2017]. Ziel dieses Modells war es, Eingabeskizzen – einfache Blasendiagramme oder Grundrisskonturen, die räumliche Zonen darstellen – in vollständige Wohnlayouts mit unterschiedlichen Funktionsbereichen umzuwandeln. Wie in Abbildung 35 dargestellt, wurde das Modell kontradiktorisch trainiert, wobei ein

Generatornetzwerk Layouts erstellt und ein Diskriminatornetzwerk deren Qualität bewertete, um den Lernprozess iterativ zu verbessern.

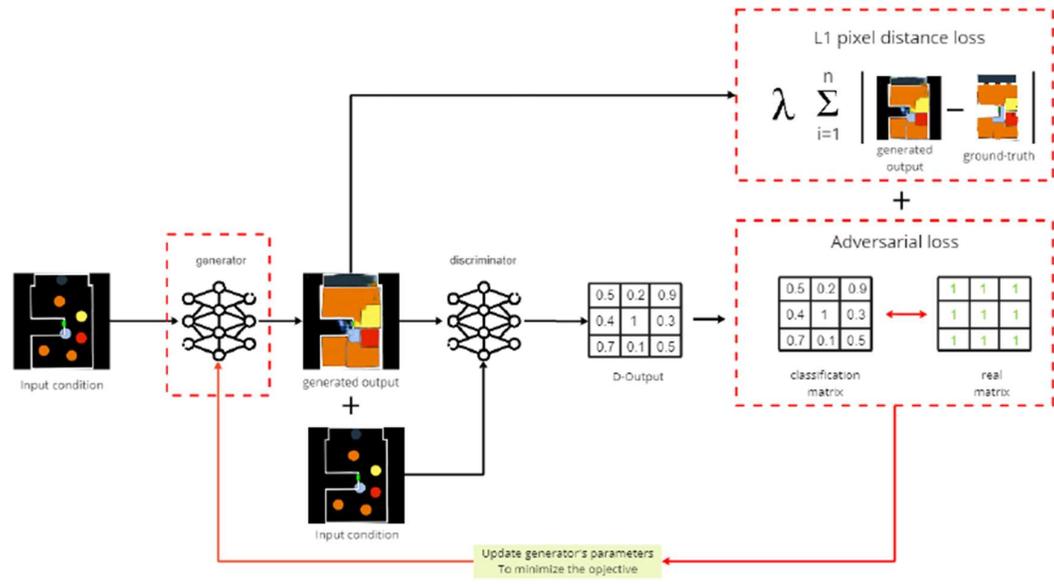


Abbildung 35: Training des pix2pix-Algorithmus [Khamam, 2023].

Das Generatornetzwerk verwendete eine Encoder-Decoder-Struktur: Zunächst wurden durch den Encoder räumliche Merkmale aus der Eingabeskizze extrahiert, bevor der Decoder daraus ein realistisches Grundrisslayout generierte. Der Diskriminator erhielt sowohl echte Grundrisse als auch vom Generator erzeugte Layouts und lernte, zwischen ihnen zu unterscheiden. Diese Rückkopplung verbesserte die Generationsfähigkeit des Generators im Laufe der Zeit [Goodfellow et al., 2014].

Das Training wurde durch zwei kombinierte Verlustfunktionen optimiert: den L1-Pixelabstandsverlust, der die Ähnlichkeit zwischen den erzeugten und den echten Grundrissen maß, und den adversarial loss, der die Diskriminatorleistung berücksichtigte, wie in der Abbildung rechts dargestellt. Die Kombination dieser Verluste trieb die Erzeugung realistischer Grundrisse voran, die sowohl geometrische als auch semantische Anforderungen erfüllten.

Ein Hauptproblem beim Training des Modells war der begrenzte Datensatz, der die Generalisierbarkeit der Ergebnisse einschränkte. Dies führte zu einer Überanpassung an spezifische Layoutmerkmale wie Raumnachbarschaften und Rechtwinkligkeit und verringerte die Variabilität der generierten Pläne. Zusätzlich erschwerte der Mangel an flexibler Konditionierung die Kontrolle über spezifische Anforderungen, was den Nutzen für praktische Anwendungen einschränkte, in denen Anpassungsfähigkeit entscheidend ist.

Stable Diffusion Model

Der zweite Ansatz nutzte ein stabiles Diffusionsmodell, [Rombach et al., 2022], um detaillierte und vom Benutzer steuerbare Grundrisse zu erstellen. Anders als GAN-basierte Modelle durchliefen Diffusionsmodelle einen Rauschunterdrückungsprozess, bei dem eine verrauschte Eingabe schrittweise in ein kohärentes und qualitativ hochwertiges Bild umgewandelt wurde. Dieser iterative Prozess, bei dem das Rauschen in mehreren Schritten reduziert wurde, ist in der Abbildung dargestellt.

Das Modell wurde mit einem großen Datensatz trainiert, was eine verbesserte Generalisierungsfähigkeit und die Erzeugung vielfältiger, realistischer Entwürfe ermöglichte. Ein entscheidender Vorteil dieses Ansatzes war die Integration von Benutzereingaben, die eine präzisere Kontrolle über bestimmte Designmerkmale erlaubte. Benutzer konnten beispielsweise die Anzahl der Schlafzimmer oder die Einbeziehung spezifischer Funktionen wie Balkone oder Heimbüros angeben, woraufhin das Modell Layouts generierte, die diesen Anforderungen entsprachen. Diese bedingte Kontrolle stellte eine signifikante Verbesserung gegenüber dem GAN-basierten Ansatz dar und machte das Modell vielseitiger für reale Entwurfsanwendungen.

Darüber hinaus unterstützte das Modell nicht nur numerische Eingaben (z. B. Raumanzahl oder -größen), sondern auch textbasierte Beschreibungen [Ramesh et al., 2022], die verwendet werden können um Grundrisscharakteristika, wie „offenes Layout“ oder „helles Badezimmer“ zu integrieren. Diese Flexibilität war besonders wichtig, um Grundrisse zu erstellen, die spezifische Nutzeranforderungen erfüllen. In unserer prototypischen Implementation haben wir uns bei der Textbeschreibung allerdings auf die Anzahl der Räume eingeschränkt.

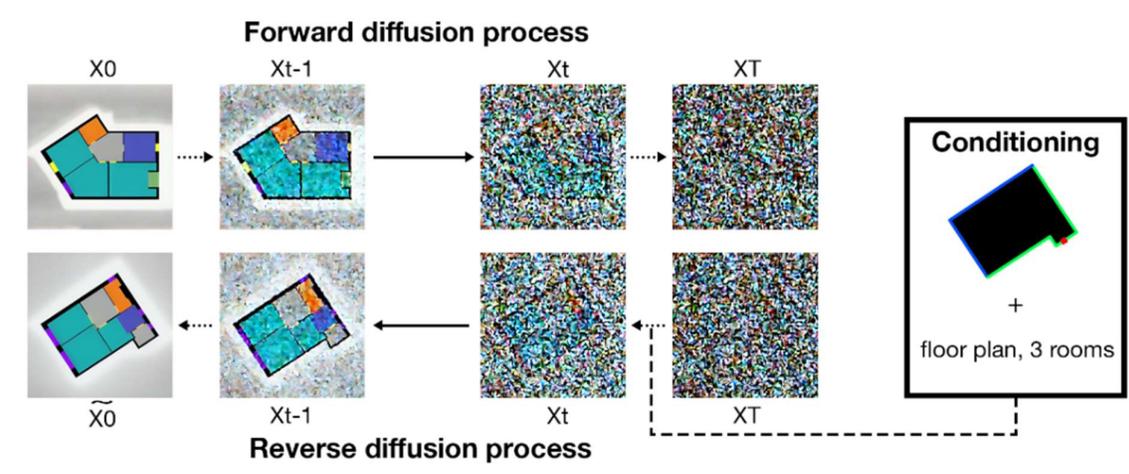


Abbildung 36: Training des Stable Diffusion Modells.

4.4.4 Ergebnisse

Die Performance beider Modelle wurde anhand verschiedener architektonischer Metriken bewertet, darunter die Genauigkeit der Raumanzahl, die Raumbeziehungen, die Raumgrößen und -form und die visuelle Qualität der generierten Layouts.

Pix2Pix

Das GAN-basierte pix2pix-Modell lieferte trotz des sehr kleinen Datensatzes (N=224) überraschend brauchbare Ergebnisse in Bezug auf die grundlegende räumliche Anordnung. Es zeigten sich aber Grenzen in einigen Aspekten:

Raumanzahl: Das Modell zeigte eine hohe Genauigkeit bei der Erzeugung der Raumanzahl entsprechend den Eingabeanforderungen. Es konnte zuverlässig zwischen verschiedenen Raumtypen wie Schlafzimmern, Bädern und Fluren differenzieren. Dennoch traten in einigen

Fällen leichte Diskrepanzen auf, insbesondere bei komplexeren Layouts, bei denen Räume zusammengelegt oder aufgeteilt wurden, was auf eine begrenzte Generalisierbarkeit des Modells hinweist.

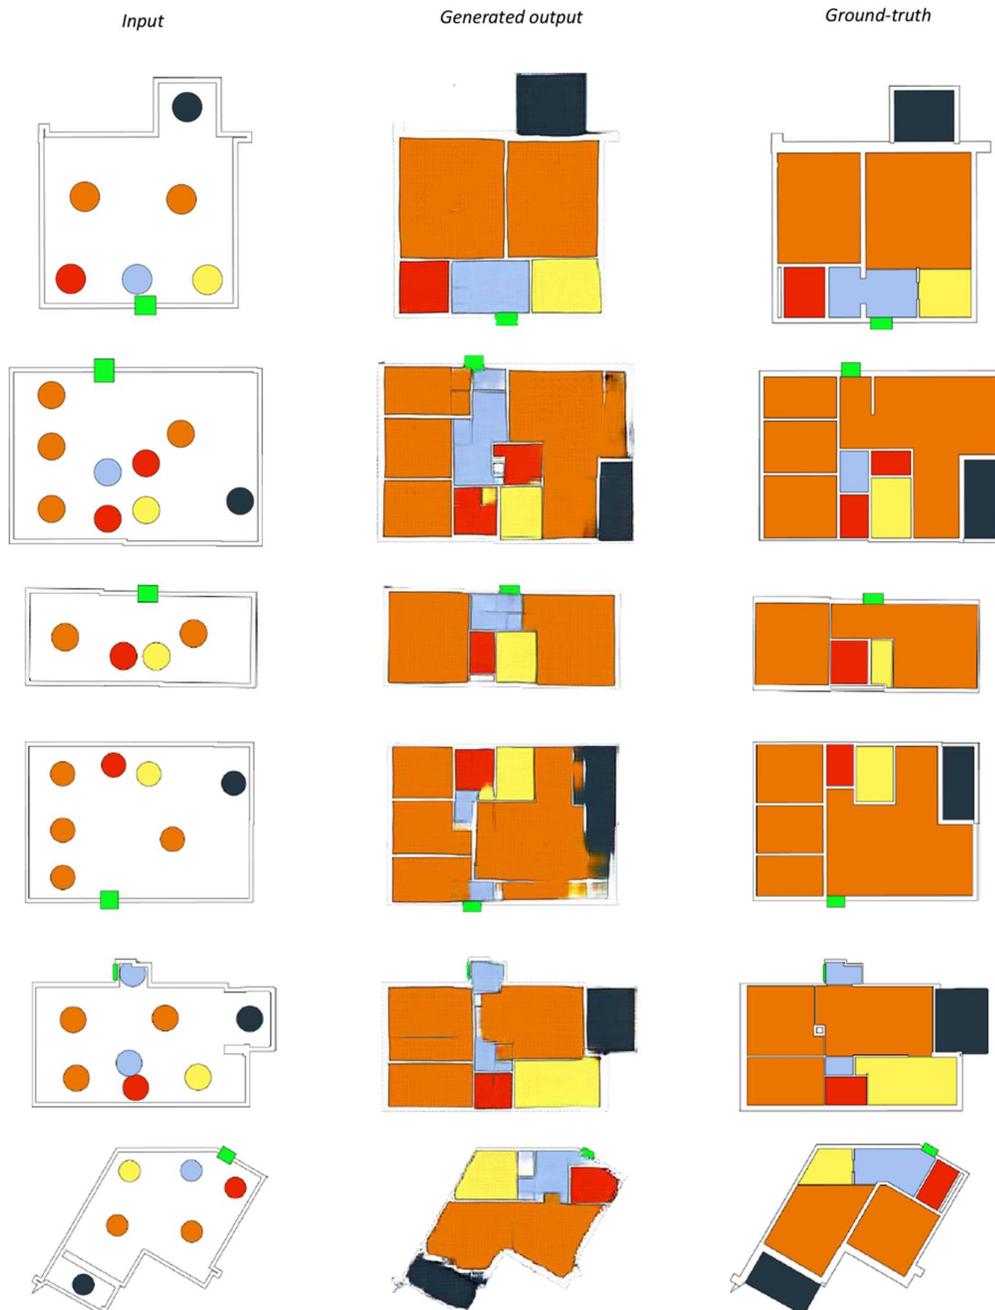


Figure 37: Generierte Grundrisse (Mitte) auf Basis einer Punktanordnung (links) und der Vergleich zum tatsächlichen Grundriss (rechts) [Khamam, 2023].

Die **räumliche Verbindungen** wurde anhand der logischen und funktionalen Verbindungen zwischen den generierten Räumen bewertet. Das Modell konnte überzeugende Verbindungen schaffen, wie z. B. Korridore zwischen Eingängen und Wohnbereichen oder direkte Zugänge von Schlafzimmern zu Badezimmern. Diese Verknüpfungen entsprachen oft den gängigen

architektonischen Konventionen, auch wenn sie nicht explizit in den Eingabedaten definiert waren (siehe beispielsweise die blau markierten Flure in Abbildung 37 (Zeile 3 und 4), die nicht im Input-Bild existieren).

Die Bewertung der **Raumgrößen und -formen** in den generierten Layouts zeigte, dass das Modell überwiegend sinnvolle und funktionale Raumdimensionen erzeugte. Es konnte die relativen Größen der Räume an die Anforderungen der Eingaben und die typische Nutzung anpassen, wie z. B. größere Wohnräume und kleinere Badezimmer. Allerdings waren die erzeugten Raumgrößen nicht immer vollständig konsistent mit architektonischen Standards. In einigen Fällen wurden Räume entweder zu klein oder zu groß generiert, insbesondere bei Layouts mit vielen unterschiedlichen Raumtypen. Die Raumformen waren in den meisten Fällen einfach und rechteckig, was auf die starke Ausrichtung des Trainingsdatensatzes auf orthogonale Grundrisse zurückzuführen ist. Das Modell zeigte Schwierigkeiten, komplexere oder diagonale Raumformen zu erzeugen, was zu einer gewissen Monotonie in den Layouts führte. Die Integration von Trainingsdaten mit mehr Variationen in Form und Geometrie könnte die Fähigkeit des Modells verbessern, vielseitigere und realistischere Raumgrößen und -formen zu erzeugen.

Hinsichtlich der **visuellen Qualität** der generierten Grundrisse produzierte das Modell Ergebnisse, die in ihrer Darstellung weitgehend erkennbare Grundrisse waren. Dennoch traten häufig Artefakte wie unsaubere Kanten oder Überlagerungen auf, insbesondere bei komplizierten Raumaufteilungen. Verbesserungen in der visuellen Darstellung könnten durch den Einsatz umfangreicherer und vielfältigerer Trainingsdaten erreicht werden.

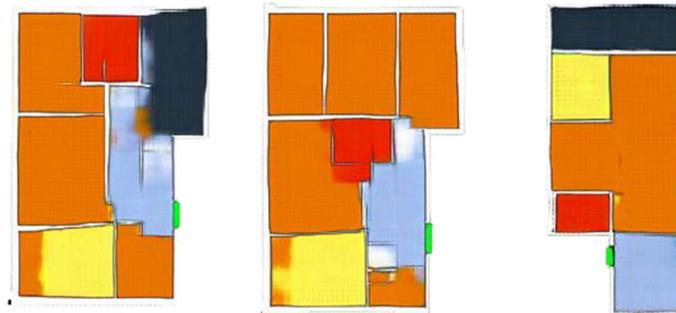


Figure 38: Artefakte in der Darstellung [Khamam & Schneider, 2023].

Ergebnisse des Stable Diffusion Modells

Das mit mehr als 20.000 Grundrissen trainierte Stable Diffusion Modell zeigte bemerkenswerte Verbesserungen in allen Bereichen:

Raumanzahl: Die Ergebnisse des Modells in Bezug auf die Raumanzahl zeigen eine hohe Übereinstimmung zwischen den Eingaben und den generierten Grundrissen. Das Modell konnte erfolgreich Layouts mit einer vorgegebenen Anzahl von Räumen erzeugen, wie in den Beispielen in Tabelle 10 ersichtlich.

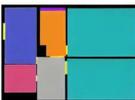
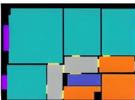
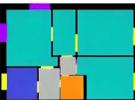
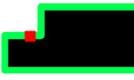
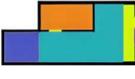
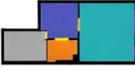
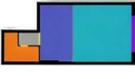
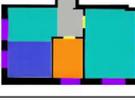
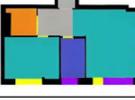
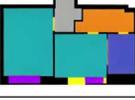
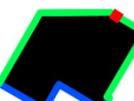
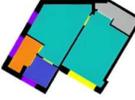
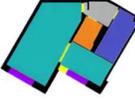
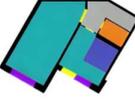
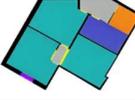
Räumliche Beziehungen: Das Diffusionsmodell zeigte eine solide Fähigkeit, kohärente räumliche Beziehungen auch bei komplexeren Layouts zu wahren. Es ordnete funktionale Zonen sinnvoll an und bewahrte wesentliche Nachbarschaften, wie beispielsweise die Platzierung von Badezimmern in der Nähe von Küchen. Auch die Verkehrswege wurden effizient

gestaltet, indem Korridore logisch positioniert und unterschiedliche Bereiche sinnvoll miteinander verbunden wurden. Diese Ergebnisse belegen, dass das Modell in der Lage war, eine funktionale und praktikable Raumstruktur zu erzeugen, wie in Tabelle 11 dargestellt. Allerdings traten auch hier gelegentlich Abweichungen auf, die auf eine eingeschränkte Generalisierbarkeit hinweisen und durch erweiterte Daten oder gezielte Anpassungen des Modells verbessert werden könnten.

Hinsichtlich der **Raumgrößen** zeigte das zweite Modell eine vergleichbare Leistung zum ersten Modell. Die generierten Räume wiesen in den meisten Fällen funktionale und realistische Größen auf, die den Anforderungen des jeweiligen Grundrisses entsprachen. Es gab jedoch ähnliche Herausforderungen bei der exakten Proportionierung in komplexeren Layouts, insbesondere wenn mehrere Räume eng miteinander verbunden waren. Bei den **Raumformen** übertraf das zweite Modell jedoch deutlich das erste. Während das erste Modell überwiegend rechteckige und orthogonale Räume erzeugte, zeigte das Diffusionsmodell eine wesentlich größere Flexibilität. Es war in der Lage, auch bei nicht-orthogonalen Umrissen sinnvolle und kohärente Raumaufteilungen zu erzeugen. Dies führte zu einer größeren Vielfalt in den generierten Grundrissen und spiegelte besser die realen architektonischen Gegebenheiten wider. Diese Stärke macht das zweite Modell besser geeignet für Layouts mit ungewöhnlichen oder asymmetrischen Umrissen.

Visuelle Qualität: Die Qualität der erzeugten Bilder war im Vergleich zu pix2pix deutlich höher. Der Diffusionsprozess ermöglichte besser definierte Wände, klare Raumgrenzen und eine Reduzierung visueller Artefakte. Wichtig ist, dass das Modell auch in der Lage war, komplexe Geometrien zu verarbeiten, wie z. B. die diagonale Partitionierung, mit der das GAN-Modell aufgrund von Datensatzbeschränkungen Schwierigkeiten hatte.

Table 10: Examples of inputs and generated outputs.

Input		Generated output		
	floor plan, 1 rooms			
	floor plan, 2 rooms			
	floor plan, 2 rooms			
	floor plan, 4 rooms			
	floor plan, 1 rooms			
	floor plan, 2 rooms			
	floor plan, 1 rooms			
	floor plan, 2 rooms			
	floor plan, 2 rooms			
	floor plan, 3 rooms			
	floor plan, 2 rooms			
	floor plan, 3 rooms			

Trotz der signifikanten Verbesserungen gegenüber dem ersten Experiment gibt es auch hier noch einige Herausforderungen. Verzerrungen im Datensatz führten zu Überrepräsentationen bestimmter Arten der Partitionierung (z. B. Flure, orthogonale Divisionen), was in einigen Fällen die Vielfalt der generierten Ausgaben einschränken könnte. Zukünftige Verbesserungen könnten sich auf die Diversifizierung der Trainingsdaten konzentrieren, um diese Verzerrungen zu beseitigen und die Robustheit des Modells zu verbessern.

Fazit

Die beiden generativen Ansätze stellen einen deutlichen Fortschritt bei der Integration von maschinellem Lernen in den Grundrissentwurf dar. Das pix2pix-Modell bot einen nützlichen Ausgangspunkt für die Erforschung der automatisierten Grundrisserstellung, war aber durch seinen kleinen Datensatz und den Mangel an Anpassungsmöglichkeiten eingeschränkt. Im Gegensatz dazu zeigte wurden im zweiten Ansatz die Vorteile größerer Datensätze und der bedingten Generierung deutlich (hochwertigen, kontrollierbaren und vielfältigen Grundrisse).

Beide Modelle sind vielversprechende Werkzeuge für Architekten, die es ihnen ermöglichen, schnell und effizient mit verschiedenen Konfigurationen zu experimentieren und gleichzeitig die Kontrolle über wichtige Aspekte des Entwurfs zu behalten. Zukünftige Forschungen sollten sich auf die weitere Verbesserung der Modellfunktionen konzentrieren, einschließlich der Erweiterung des Datensatzes, um vielfältigere Architekturstile abzudecken, und der Integration dieser Modelle in bestehende Architekturwerkzeuge, wie z. B. CAD-Software, um die Benutzerinteraktion zu erleichtern. Ein weiterer Weg zur Erkundung besteht darin, graphenbasierte generative Modelle mit dem aktuellen Diffusionsansatz zu kombinieren, um strukturiertere und anpassbarere Raumdiagramme zu erstellen, die den Layout-Generierungsprozess informieren können.

5 Validierung

In diesem Kapitel wird die Durchführung und Auswertung von Nutzertests beschrieben, die zur Validierung und Bewertung der entwickelten Methoden durchgeführt wurden. Dafür haben wir ein webbasiertes Nutzerinterface entwickelt, das speziell darauf ausgelegt wurde, die generierten Grundrisslayouts für Endnutzer zugänglich und interaktiv nutzbar zu machen. Dabei lag der Fokus auf einer benutzerfreundlichen Oberfläche, die es ermöglicht, Grundrisse anzupassen und die Ergebnisse in Echtzeit zu überprüfen.

Im Anschluss wird erläutert, wie das Tool in den Nutzertests eingesetzt wurde, um die praktische Anwendbarkeit und Akzeptanz der generierten Layouts zu evaluieren. Ziel der Tests war es, Feedback zur Funktionalität, Bedienbarkeit und Qualität der generierten Ergebnisse zu sammeln, um sowohl die technische als auch die nutzerseitige Perspektive in die weitere Optimierung des Tools einfließen zu lassen.

5.1 Webbasiertes User Interface „floorAI“

Dieses Kapitel beschreibt die Entwicklung und Funktionen einer webbasierten Plattform, die unabhängig von spezifischen CAD-Tools verschiedene Entwurfsheuristiken für Grundrisse erzeugt. Ziel der Anwendung ist es, Architekten und Planern eine benutzerfreundliche Lösung bereitzustellen, die Entwurfsprozesse vereinfacht, die Effizienz in der Planungsphase steigert und die praktische Anwendbarkeit dieser Heuristiken im Entwurfsprozess evaluiert.

Die Web-App ermöglicht es, Eingaben direkt aus CAD-Programmen zu empfangen, wobei die Grundrissgeometrie als zentrale Datengrundlage dient. Im Rahmen des Projektes haben wir folgende Entwurfsheuristiken in die App integriert:

- Suchen nach ähnlichen Grundrissen
- Umrisspotential
- Generieren der Grundrissgeometrie

Diese Heuristiken lassen sich einzeln oder in Kombination einsetzen, um spezifische Entwurfsziele zu erreichen. Die Ergebnisse können nahtlos in das CAD-Programm zurückexportiert werden, was eine iterative Vorgehensweise im Planungsprozess unterstützt.

Alle maschinellen Lernvorgänge werden serverseitig ausgeführt, während ein schlanker Konnektor die Integration mit CAD-Programmen wie Rhino3D, ArchiCAD, Revit und AutoCAD ermöglicht. Dieser Ansatz stellt sicher, dass die rechenintensiven Prozesse nicht auf der Hardware des Nutzers durchgeführt werden, wodurch die Plattform von jedem Gerät aus zugänglich bleibt. Gleichzeitig ist die Architektur der Lösung leicht erweiterbar, da die Konnektoren lediglich die Übertragung von Eingaben und Ergebnissen übernehmen und für zusätzliche CAD-Umgebungen angepasst werden können.

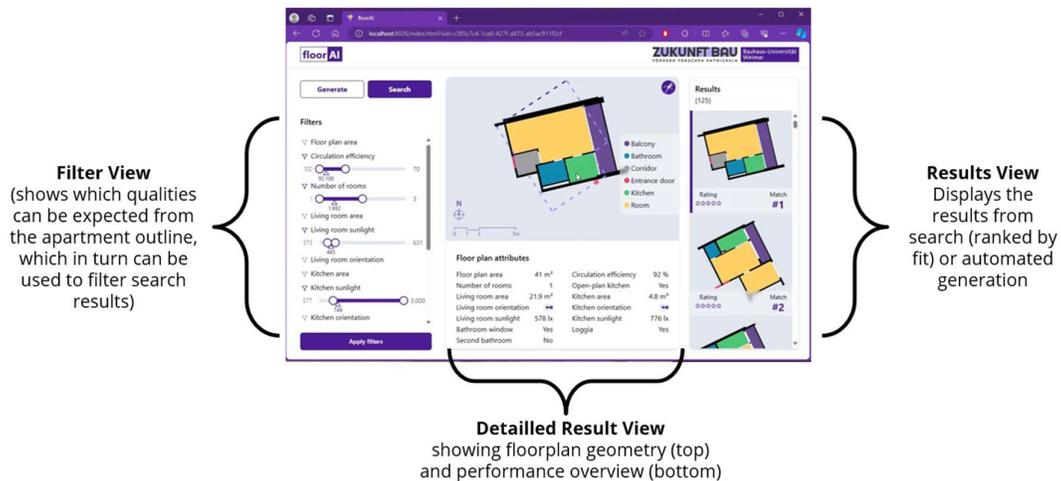


Figure 39: Screenshot des Webbasierten Interfaces.

Die technische Umsetzung des Systems besteht aus mehreren Schlüsselkomponenten: einem CAD-Plugin, das die Verbindung zwischen verschiedenen CAD-Umgebungen und der webbasierten Benutzeroberfläche herstellt, sowie einem Frontend, das eine intuitive Benutzeroberfläche für die Interaktion mit den Entwurfsheuristiken ermöglicht. Das Backend ist in zwei Hauptteile gegliedert: Ein zentraler Server übernimmt die Koordination der Kommunikation zwischen Frontend, CAD-Plugin und der Suche nach ähnlichen Grundrissen, während ein dedizierter Server für maschinelle Lernaufgaben wie die Datenverarbeitung, die Berechnung von Funktionen, die Erstellung von Einbettungen und die Ausführung generativer KI-Modelle abwickelt (siehe Abbildung 40).

Das CAD-Plugin ist eine .NET-basierte Anwendung, die dazu dient, eine WebSocket-Verbindung zwischen der CAD-Software und dem Frontend der Anwendung herzustellen. Sobald diese Verbindung aktiv ist, kann der Benutzer die Geometrie eines Grundrisses direkt aus der CAD-Software an die Anwendung senden.

Das Frontend der Software ist eine reaktive JavaScript-Anwendung, die mit dem Svelte-Framework entwickelt wurde. Es bietet dem Benutzer eine Reihe von Werkzeugen, darunter die Visualisierung der aus der CAD-Software übertragenen Umrissgeometrie, die Vorhersage des Umrisspotentials, die Suche nach ähnlichen Grundrissen in der Datenbank, die Filterung der Suchergebnisse nach Kriterien wie der Anzahl der Räume oder der Erschließungseffizienz sowie die Generierung neuer Grundrisse. Sobald ein passender Grundriss gefunden ist, kann dieser per Knopfdruck an die CAD-Software zurückgesendet werden, was einen nahtlosen Workflow ermöglicht.

Das Backend der Anwendung übernimmt den Großteil der Verarbeitungsaufgaben und basiert ebenfalls auf .NET. Es verwaltet den Datenfluss zwischen der CAD-Software und dem Frontend über WebSocket-Kanäle und stellt mehrere serverseitige API-Endpunkte zur Verfügung, die vom Frontend genutzt werden:

- Einbettungs-API-Endpunkt: Erstellt Vektoreinbettungen für die gegebene Umrisslinie (siehe 3.3).
- Hu-API-Endpunkt: Berechnet sieben logarithmisch transformierte Hu-Moment-Invarianten für die gegebene Umrisslinie (siehe 4.1.2).

- Such-API-Endpunkt: Führt eine Abfrage in der Grundrissdatenbank basierend auf benutzerdefinierten Filtern durch (z. B. Anzahl der Zimmer) und gibt Ergebnisse zurück, die nach ihrer Entfernung im Hu-Raum zur Zielkontur geordnet sind.
- Vorhersage-API-Endpunkt: Erstellt basierend auf der Vektoreinbettung Vorhersagen zum Umrisspotential (siehe 4.2).
- Generierungs-API-Endpunkt: Generiert auf Basis eines Umrisses und einer angegebenen Anzahl von Räumen bis zu vier neuartige Grundrisse mit einem vortrainierten ML-Modell (siehe 4.4, Stable Diffusion Modell).

Die Endpunkte für Einbettung, Vorhersage und Generierung leiten ihre Anfragen an einen dedizierten ML-Server weiter, auf dem die entsprechenden vortrainierten Machine-Learning-Modelle ausgeführt werden. Der Hu-Endpunkt berechnet die Momentinvarianten von Hu, während der Suchendpunkt die Grundrissdatenbank abfragt und Ergebnisse liefert, die nach der Distanz im Hu-Raum sortiert und gemäß den im Frontend festgelegten Filtern gefiltert werden.

Ein dedizierter ML-Server, gehostet auf der Plattform Hugging Face, wurde eingesetzt, um die vortrainierten Machine-Learning-Modelle für die beschriebenen Aufgaben zu hosten. Hugging Face bietet eine robuste Infrastruktur und ausreichend Rechenleistung, um die ressourcenintensiven Prozesse effizient durchzuführen. Dieser Ansatz ermöglicht eine skalierbare Lösung, die rechenintensive Aufgaben auslagert und den Nutzern eine performante, leicht zugängliche Plattform bereitstellt.

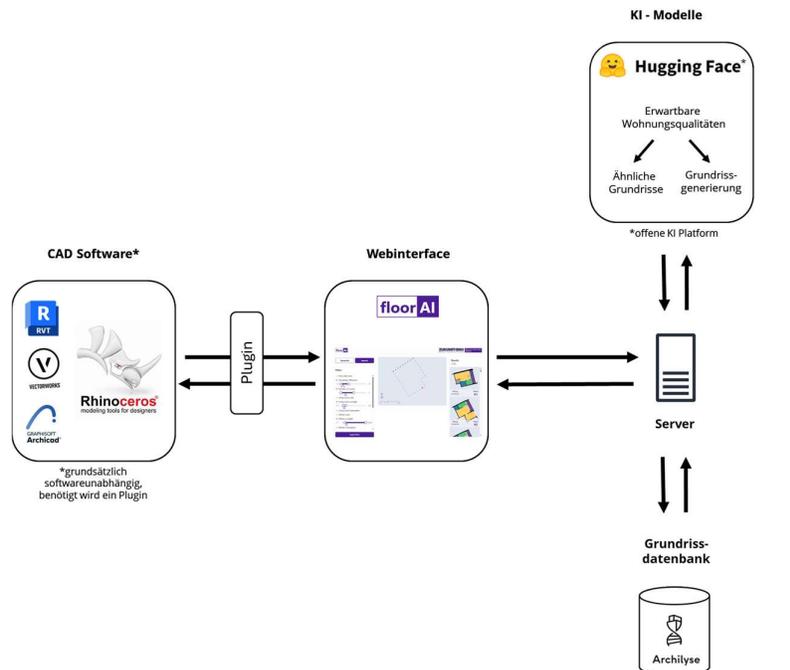


Abbildung 40: Datenfluss zwischen CAD-Software, Frontend und Backend der Anwendung.

5.2 Workshops

5.2.1 Expertenmeetings

Um die Entwicklung unserer Methoden möglichst praxistauglich zu gestalten, war ursprünglich geplant, mehrere Anwendertests durchzuführen. Solche Tests sind allerdings erst dann sinnvoll möglich, wenn sowohl die Methoden als auch das Interface ausreichend entwickelt sind – ein Zustand, der erst zu einem späten Zeitpunkt im Projekt erreicht wurde.

Um dennoch wertvolles Feedback zu gewinnen, haben wir während der Projektlaufzeit Expertenmeetings organisiert. In diesen Treffen wurden die Projektziele sowie die entwickelten Methoden präsentiert und diskutiert, teils auf konzeptioneller Ebene, teils in Form früher Demonstratoren. Diese Expertenrunden boten uns die Möglichkeit, frühzeitig Rückmeldungen und Anregungen einzuholen, die in die weitere Entwicklung einfließen konnten.

Insgesamt haben wir drei solcher Expertentreffen durchgeführt. An diesen Meetings nahmen Prof. Johannes Kühn sowie zwei seiner Mitarbeiterinnen teil. Dabei konnten wir wertvolle Erkenntnisse über die Perspektive von Architekten auf KI-basierte Assistenzsysteme und ihre Arbeitsweise gewinnen:

- **Positive Einstellung gegenüber KI-Systemen:** Grundsätzlich standen die Architekten der Integration von KI-basierten Assistenzsystemen in ihre Arbeitsprozesse positiv gegenüber. Sie erkannten das Potenzial solcher Systeme zur Unterstützung bei zeitaufwendigen und iterativen Aufgaben.
- **Integration menschlicher Kreativität:** Trotz der Offenheit gegenüber KI wurde die Bedeutung der menschlichen Kreativität betont. Architekten sehen diese als unerlässlich, um individuelle und ästhetische Lösungen zu entwickeln, die den Anforderungen spezifischer Projekte gerecht werden.
- **Aufwand des Grundrisszeichnens:** Insbesondere bei komplexeren Projekten wurde das Grundrisszeichnen als sehr zeitintensiv beschrieben. Es erfordert häufig viele Iterationen, um das geforderte Raumprogramm unter Berücksichtigung geometrischer Constraints und Bauvorschriften zu erfüllen.
- **Zusammenspiel zwischen Gebäudekubatur und Grundrissen:** Architekten wünschten sich ein stärkeres Zusammenspiel zwischen dem Gebäudevolumen und den Grundrissen. Beispielsweise könnte ein System vorschlagen, das Volumen eines Gebäudes anzupassen, wenn die geplanten Grundrisse nicht optimal passen.
- **Typologisches Vorgehen in der Planung:** Architekten gaben an, häufig typologisch vorzugehen, d. h. Grundmuster für Wohnungen oder Gebäudeaufteilungen zu entwickeln und diese in Projekten zu wiederholen. Dieses Vorgehen hat Vorteile für die Planung und den Bauablauf, da weniger Sonderfälle auftreten, was zu geringeren Kosten und einem reduzierten Kommunikationsaufwand auf der Baustelle führt.
- **Standardisierung der Sanitärräume:** Sanitärräume wurden als zentrales Element für die Typisierung genannt. Dabei muss ihre Platzierung im Zusammenhang mit dem gesamten Gebäude betrachtet werden, um Installationsschächte zu minimieren und die Effizienz der technischen Infrastruktur zu gewährleisten.
- **Erschließung einer Wohnung:** Die Gestaltung des Wohnungsflurs wurde als entscheidend für die Effizienz und Funktionalität einer Wohnung hervorgehoben. Architekten experimentieren zunehmend mit innovativen Lösungen, wie der Integration des Flurs in den Wohnraum oder einer Dimensionierung, die eine multifunktionale Nutzung des Flurs ermöglicht. Diese Ansätze tragen dazu bei, den Platzbedarf zu minimieren und gleichzeitig die Nutzbarkeit zu erhöhen.

- **Tageslicht und geometrische Aufteilung:** Obwohl Tageslicht als grundsätzlich wichtiges Kriterium betrachtet wird, spielt es bei der geometrischen Aufteilung von Wohnungen eine eher untergeordnete Rolle. Dies liegt daran, dass die maximale Gebäudetiefe und Vorschriften Fensterdimensionen in der Regel sicherstellen, dass die Räume ausreichend hell sind.
- **Relevanz von Raumbeziehungen:** Raumbeziehungen wurden als der wichtigste Faktor in der Grundrissgestaltung empfunden. Besonders die Verbindung zwischen Küche und Wohnzimmer wurde hervorgehoben. Diese Verbindung ist nicht nur aus funktionaler Sicht von Bedeutung, sondern stellt auch eine Maßnahme zur Minimierung der Wohnfläche dar.

Ein weiterer Punkt, der in den Expertentreffen thematisiert wurde, war die Einschränkung der Grundrissvielfalt durch die vorhandenen Fälle in der Datenbank. Die in der Datenbank enthaltenen Grundrisse basieren vor allem auf dem schweizerischen Wohnbau, der spezifischen Bauvorschriften unterliegt. Diese Vorschriften beeinflussen die geometrischen und funktionalen Möglichkeiten der Grundrissgestaltung. Ein Großteil der Grundrisse in der Archilyse-Datenbank zeigt vorwiegend traditionelle Grundrisse mit zentralem Flur, was die Bandbreite an innovativen Lösungen begrenzte.

Ein möglicher Ansatz, um diese Einschränkung zu überwinden, wäre die Erweiterung der Datenbank um Grundrisse aus anderen Ländern oder Regionen mit unterschiedlichen Bauvorschriften und architektonischen Stilen. Darüber hinaus könnte die Einführung von "Grundrissstilen" oder Wohnformen als Auswahlkriterium in der Datenbank hilfreich sein. Dies würde es Nutzern ermöglichen, gezielt nach traditionellen oder innovativen Lösungen zu suchen. Eine solche Erweiterung könnte nicht nur die Vielfalt der Lösungen erhöhen, sondern auch die Generierung von Grundrissen fördern, die auf spezifische architektonische Anforderungen oder Präferenzen ausgerichtet sind. Dies würde die Datenbank flexibler und vielseitiger machen und die Grundlage für experimentelle und kreative Planungsansätze stärken.

5.2.2 Anwendertest

Die Nutzerstudie wurde durchgeführt, um die Qualität und Nützlichkeit entwickelten Entwurfsheuristiken zu bewerten. Ziel war es, die Integration des Tools in bestehende Arbeitsabläufe der architektonischen Gestaltung zu analysieren, seinen Mehrwert in verschiedenen Phasen der Grundrissgestaltung zu untersuchen und mögliche Verbesserungen für zukünftige Versionen zu identifizieren. Die Studie fand am Ende der Projektlaufzeit statt, nachdem die Methoden ausgereift waren und das Web-Tool zur Verfügung stand.

Ein zentrales Anliegen der Studie war es, ein besseres Verständnis der spezifischen Herausforderungen und Bedürfnisse von Architekten während des Entwurfsprozesses zu gewinnen. Die Untersuchung umfasste die Bewertung der Qualität der generierten Grundrisse, die Effizienz der Suchfunktionalitäten und die Nützlichkeit des Umrisspotentials bei der Unterstützung von Entwurfsprozessen.

Ein weiterer Schwerpunkt lag darauf, zu bewerten, wie gut der Workflow des Tools mit traditionellen Designansätzen harmoniert. Hierbei wurde geprüft, ob die Funktionalitäten nahtlos in bestehende Praktiken integriert werden können und ob es Bereiche gibt, in denen Anpassungen oder Erweiterungen den Entwurfsprozess weiter optimieren könnten.

Letztlich zielte die Studie darauf ab, einen Beitrag zur Weiterentwicklung von KI-gestützten Entwurfswerkzeugen zu leisten, die nicht nur Inspiration bieten, sondern auch konkrete und praktikable Lösungen im Kontext der architektonischen Planung bereitstellen. Die gewonnenen

Erkenntnisse sollen sicherstellen, dass das Tool Architekten bei der kreativen und funktionalen Gestaltung von Grundrissen optimal unterstützt.

Studiendesign

Die Studie stützte sich auf Fokusinterviews, um gezielte Einblicke in die Erfahrungen und Perspektiven der Teilnehmer zu gewinnen. Diese Methode erlaubte eine detaillierte Erhebung von Feedback zur Nutzung des Tools und dessen Integration in den Entwurfsprozess.

Die Teilnehmergruppe bestand aus insgesamt vier Projektteams. Jedes Team setzte sich aus 2–3 Studierenden zusammen. Die Auswahl der Teilnehmer erfolgte im Rahmen eines studentischen Entwurfsprojekts, das im Wintersemester 2023/24 unter der Leitung von Prof. Johannes Kühn stattfand. Das Entwurfsprojekt beschäftigte sich mit der Entwicklung einer Bebauung für ein innerstädtisches Grundstück in Prag, das für eine Mischnutzung vorgesehen war, wobei der Schwerpunkt auf Wohnnutzung lag. Die Projektergebnisse umfassten Lösungen mit unterschiedlichen formalen Ausdrucksformen (z. B. runde vs. lineare Formen, symmetrische vs. organische Grundrisse), Entwurfsansätzen (z. B. bottom-up vs. top-down) und Konzepten (z. B. Modularität, visuelle Qualität, kontextuelle Beziehung). Durch diese konnten wir das Tool in verschiedenen architektonischen Kontexten evaluieren (siehe Abbildung 41).

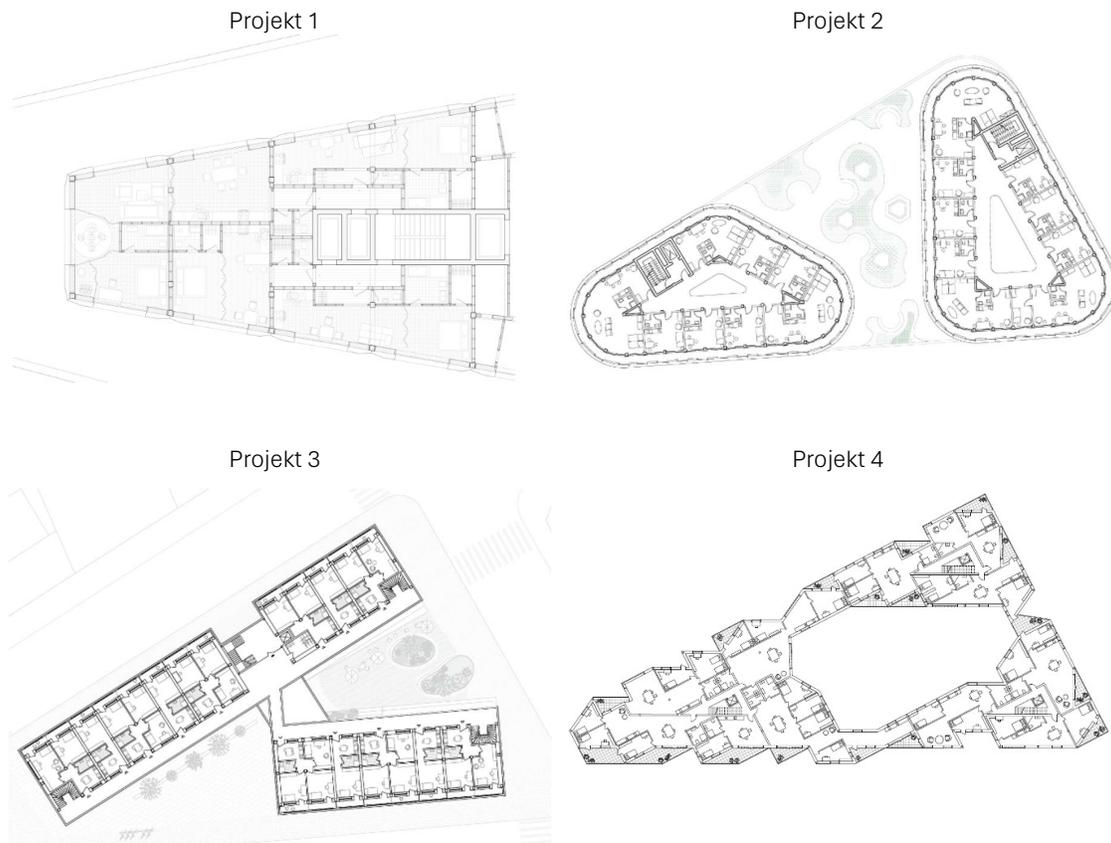


Abbildung 41: Vier studentische Projekte für den Anwendertest.

Die Nutzerstudie bestand aus vier aufeinander abgestimmten Teilen:

1. **Verständnis des Entwurfsprozesses:** Zu Beginn wurden die Teilnehmer gebeten, ihren allgemeinen Entwurfsablauf zu reflektieren. Dabei wurden ihre typischen Entwurfsphasen mithilfe von Karten dokumentiert, die die wesentlichen Schritte bei der Gestaltung von Wohngebäuden visualisierten.
2. **Anwendung des Tools:** Anschließend erfolgte eine Einführung in das Tool floorAI. Die Teilnehmer wurden aufgefordert, die Such- und Generierungsfunktionen nutzen, um Grundrisse für ihren Gebäudeentwurf zu entwickeln.
3. **Bewertung des Tools:** Im dritten Schritt verglichen die Teilnehmer die Grundrisse mit ihren ursprünglichen Entwürfen. Die Grundrisse wurden dabei nach Kriterien wie Plausibilität und Eignung für das eigene Entwurfskonzept bewertet.
4. **Offene Diskussion:** Der Workshop schloss mit einer offenen Reflexion, in der die Teilnehmer über die potenzielle Rolle des Tools im Designprozess diskutierten. Dabei wurden auch konkrete Verbesserungsvorschläge für die Weiterentwicklung des Tools erarbeitet.

Ergebnisse

Die Gespräche mit den Studierenden über ihren Entwurfsprozess bestätigten weitgehend bestehende Erkenntnisse aus der Literatur, insbesondere die Auffassung, dass architektonisches Entwerfen ein iterativer und oft unklar definierter Prozess ist. Flexibilität bei den Entwurfswerkzeugen wurde von den Teilnehmern als entscheidend angesehen. Hinsichtlich des Zeitaufwandes wurde geschätzt, dass die Grundrissgestaltung etwa 15–20 % der gesamten Gebäudeplanung ausmacht. Die Teilnehmer beschrieben vier zentrale Merkmale ihres Entwurfsprozesses:

- **Iterative Schleifen:** Die Grundrissgestaltung erfolgte selten linear, sondern wurde in wiederkehrenden Iterationen bearbeitet (z.B. Konstruktionsraster auf Grund).
- **Unvorhersehbarkeit:** Unerwartete Erkenntnisse während des Designprozesses führten häufig zu abrupten Veränderungen und Neuausrichtungen.
- **Gleichzeitigkeit:** Statt einem linearen Ablauf wurden verschiedene Probleme parallel angegangen, was eine hohe Komplexität und Flexibilität erfordert (z.B. verschiedene Geschosse aufeinander abstimmen sowie die Innenraumaufteilung mit der Fassade in Einklang bringen).
- **Gestalterischer Fokus:** Die Bedeutung der Grundrissgestaltung variierte stark. In einigen Fällen diente der Grundriss als Ausgangspunkt für das gesamte Gebäude, in anderen kristallisierte er sich erst später im Prozess heraus.

Umrisspotential

Die Studierenden haben für die von ihnen entworfene Grundrissaufteilung das Umrisspotential (siehe 4.2) ermittelt.

- Diese Funktion wurde von den Teilnehmenden als interessant, aber wenig nützlich empfunden. Sie begründeten dies damit, dass ihre Entscheidungen hinsichtlich der Wohnungsaufteilung auch von externen Faktoren (z.B. Konstruktionsraster, Erschließung) abhängen. Um diese verschiedenen Faktoren aufeinander abzustimmen spielen sie sehr schnell verschiedenste Varianten mental oder in Skizzen durch. Das Erstellen einer digitalen Repräsentation dieser Varianten würde dabei hinderlich sein.
- Ein weiterer Kritikpunkt war der Umgang mit numerischen Metriken. Die Teilnehmer zeigten wenig Interesse an quantitativen Werten wie z.B. Beleuchtungskennwerten (teilweise auch, weil das Wissen um deren Bedeutung nicht vorhanden war). Wünschenswert wären stattdessen qualitative oder visuelle Hinweise. Beispielsweise würde eine visuelle Bewertung wie „gut / schlecht beleuchtet“ als hilfreicher empfunden als eine reine Darstellung numerischer Daten.

Diese Ergebnisse verdeutlichen, dass die Entwurfsheuristik „Umrisspotential“ in ihrer aktuellen Form nicht optimal auf die Arbeitsweise von Architekten abgestimmt ist. Eine stärkere Ausrichtung auf visuelle und intuitive Unterstützung könnte die Akzeptanz und Nützlichkeit der Funktion erheblich verbessern.

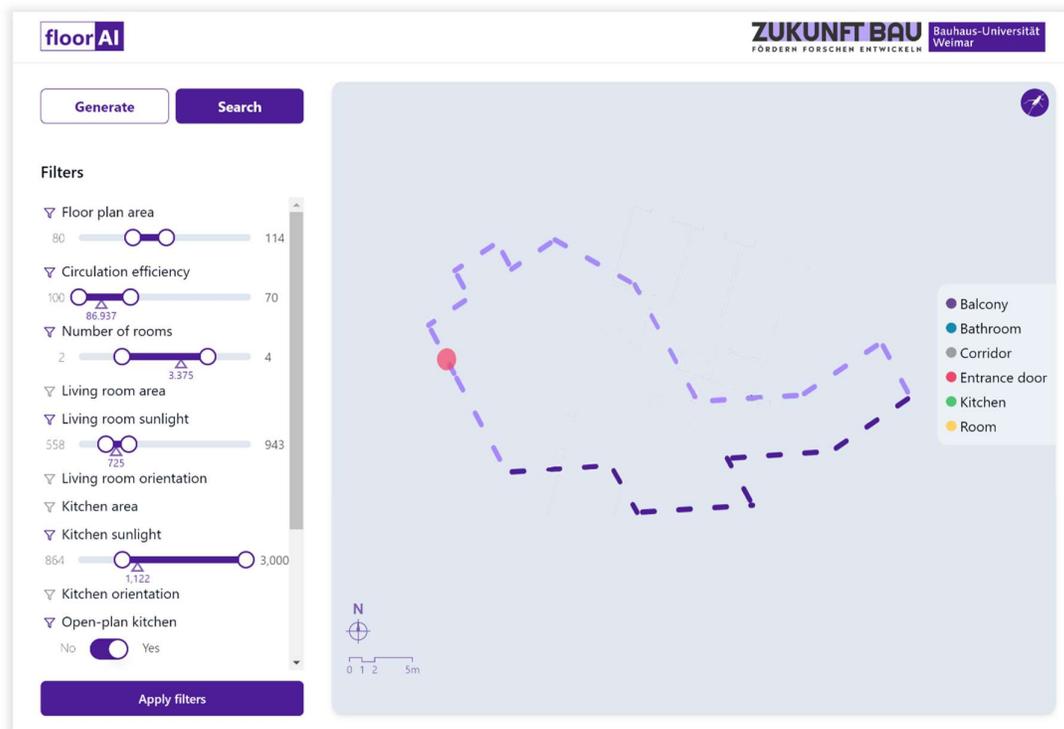


Abbildung 42: Beispiel für eine Vorhersage des Umrisspotentials auf eine komplexe Wohnungsgeometrie des Projekts 4.

Suchfunktionalität

Nachdem die Studierenden das Umrisspotential getestet haben, sollten Sie für verschiedene Umrisse ihres eigenen Entwurfs mit der Suchfunktion nach gebauten Beispielen mit ähnlichem Umriss suchen.

- Die Suche nach bestehenden Grundrissen wurde als potentiell sinnvoll empfunden, zumal die Suche nach Referenzen ein fester Bestandteil der architektonischen Arbeitsabläufe ist.
- Die Teilnehmer empfanden es insbesondere als hilfreich, schnell zu sehen, wie eine bestimmte Anzahl an Räume in eine Umriss untergebracht werden können. Die Einzigartigkeit vieler Layouts (insbesondere bei Projekt 4) machte es manchmal jedoch schwierig, eine genaue Übereinstimmung zu finden.
- Für die Suche wünschten sich die Teilnehmenden zusätzliche Filter, wie z. B. die Haushaltsgröße oder spezifische Raumanforderungen für bestimmte Nutzergruppen.
- Darüber hinaus wurde angemerkt, dass es gut wäre die Prinzipien hinter einer Grundrisslösung zu verstehen. Dies würde ihnen ermöglichen die Prinzipien auf ihren eigenen Entwurf anzuwenden, anstatt einfach Grundrisse zu kopieren. Als wesentliche Grundlage für diese Prinzipien wurde der städtebauliche Kontext und der Grundriss des gesamten Geschosses als wesentliche Information genannt.

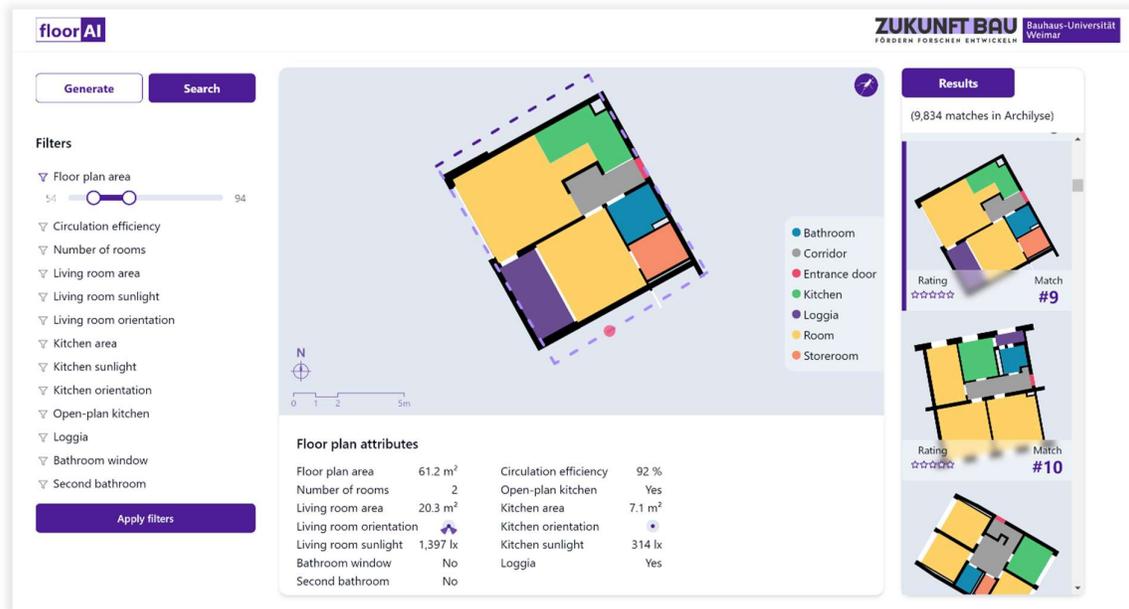


Abbildung 43: Beispiel für eine Suche für einen Umriss die auf eines Projekts 3 angewendet wurde.

Die Suchfunktion wurde von den Studierenden als nützlich bewertet, insbesondere zur schnellen Orientierung, wie verschiedene Raumaufteilungen in einen Umriss integriert werden können. Gleichzeitig zeigte sich, dass die Funktion durch zusätzliche Filter und eine Erklärung der zugrunde liegenden Prinzipien, wie dem städtebaulichen Kontext oder dem Geschossgrundriss, weiter verbessert werden könnte. Dies würde es den Nutzern ermöglichen, nicht nur Inspiration zu finden, sondern auch die zugrundeliegenden Ansätze gezielt auf ihre eigenen Entwürfe anzuwenden.

Automatische Grundrissgenerierung

Abschließend sollten die Studierenden das Generierungswerkzeug nutzen um für ausgewählte Wohnungsumrisse eine konkrete geometrische Raumaufteilung zu erhalten. Dabei konnten sie die Anzahl der gewünschten Räume selbst definieren.

- Von den drei getesteten Heuristiken erwies sich der generative Ansatz als am vielversprechendsten. Selbst fehlerhafte Ergebnisse wurden als wertvolle Inspirationsquellen angesehen, die es Entwerfenden ermöglichten, sie an ihre eigenen Bedürfnisse anzupassen.
- Die Teilnehmer wünschten sich mehr Kontrolle über die generativen Ergebnisse. Wünschenswert wären weitere Eingabeparameter, wie z. B. die Beziehung zur Fassade, die Symmetrieachsen, die Lage bestimmter Räume oder die Definition fixer Bezugspunkte (wie z.B. die Installationsschächte oder Stützen).
- Wie bei der Suchfunktion betonten die Teilnehmer, dass ihr Fokus beim Gebäudeentwurf nicht auf der Gestaltung einzelner Wohnungen liegt, sondern auf der gesamten Etage. Sie äußerten den Wunsch, dass das generative Tool auf der Ebene ganzer Stockwerke funktioniert und strukturelle, visuelle und räumliche Überlegungen über mehrere Wohnungen hinweg integriert.

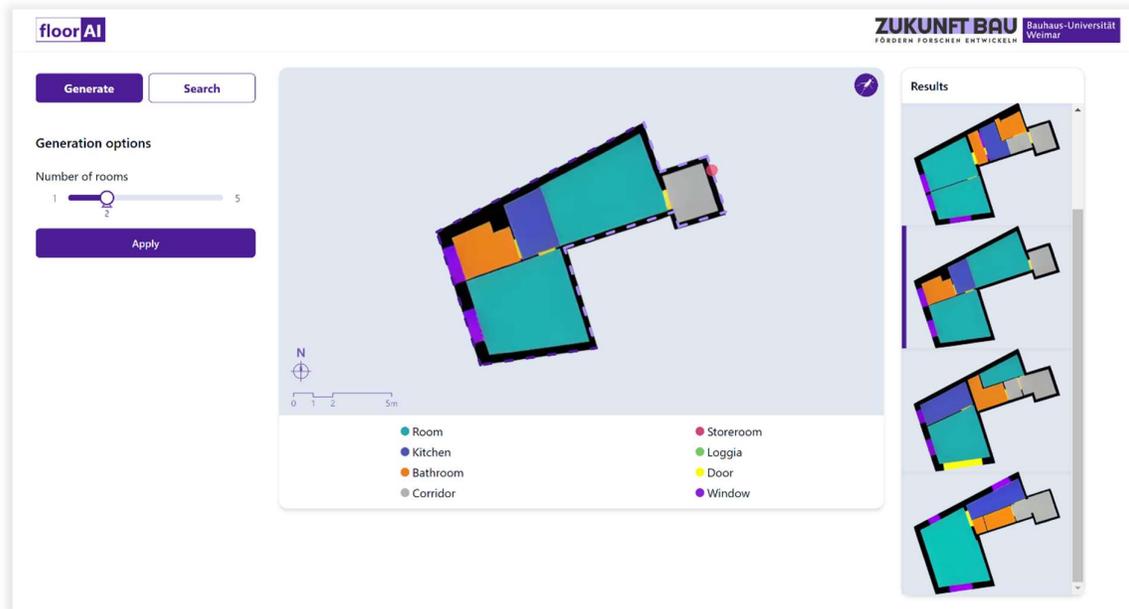


Abbildung 44: Beispiel für die Grundrissgenerierung für einen Wohnungsgrundriss für Projekt 1.

Fazit

In der Anwenderstudie wurde die Nützlichkeit von drei im Projekt entwickelten Entwurfsheuristiken getestet: Umrisspotential, Suche nach ähnlichen Grundrissen und die automatisierte Generierung der Grundrissgeometrie.

Die Entwurfsheuristik **Umrisspotential** wurde von den Teilnehmenden als weniger nützlich bewertet. Sie verließen sich bei der Bewertung von Grundrissen eher auf ihre Intuition und Erfahrung, statt auf numerische Metriken. Einfaches qualitatives Feedback (wie etwa die Aussage, ob ein Raum „gut beleuchtet“ ist) und visuelles Feedback (z.B. wo es im Umriss zu Problemen kommen kann) wäre für die Teilnehmenden hilfreicher gewesen. Dies zeigt, dass Werkzeug in Zukunft stärker an die visuelle und intuitive Arbeitsweise von Architekten angepasst werden muss.

Die **Suchfunktion** wurde als vielversprechend empfunden, da sie es ermöglicht, schnell Referenzgrundrisse zu finden – ein zentraler Bestandteil im Arbeitsalltag von Architekten. Besonders hilfreich war die Möglichkeit, zu sehen, wie eine bestimmte Anzahl an Räumen in einen bestimmten Umriss passen bzw. angeordnet werden können. Außerdem betonten die Teilnehmenden, dass das Verständnis der Prinzipien hinter einem Grundriss wichtiger ist als das bloße Kopieren. Suchergebnisse sollten daher Kontext bieten und Einblicke in die zugrundeliegenden Entwurfsprinzipien ermöglichen, anstatt nur isolierte Wohnungsgrundrisse zu zeigen.

Die **Generierung der Grundrissgeometrie** wurde als die vielversprechendste der drei Heuristiken bewertet. Die Teilnehmenden schätzten es, dass das Tool Entwurfsideen generieren konnte, selbst wenn nicht alle Ergebnisse perfekt waren. Es wurde als Inspirationsquelle gesehen, die an spezifische Bedürfnisse angepasst werden kann. Gleichzeitig äußerten die Teilnehmenden den Wunsch nach mehr Kontrolle über die generierten Entwürfe, beispielsweise durch die Möglichkeit, Parameter wie die Beziehung zur Fassade oder

strukturelle Elemente vorzugeben. Zudem wurde betont, dass die Beschränkung auf eine einzelne Wohnung hinderlich ist, da im typischen Workflow die Entwurfsarbeit auf dem gesamten Geschoss bzw. sogar geschoßübergreifend stattfindet.

Insgesamt zeigte der entwickelte Demonstrator FloorAI ein großes Potenzial, den architektonischen Entwurfsprozess zu unterstützen, insbesondere durch seine generativen Funktionen. Verbesserungen bei der Darstellung des Umrisspotentials, erweiterte Filteroptionen in der Suchfunktion und mehr Kontrolle über die generative Gestaltung könnten die Nützlichkeit des Tools weiter erhöhen. Durch einen stärkeren Fokus auf erweiterte Darstellungs- und Steuerungsmöglichkeiten (wie z.B. geschoßübergreifende Verknüpfungen, Bezug zum Konstruktionsraster und zur Installationsführung, Standardisierung von Räumen wie dem Bad) könnte das Tool noch besser in bestehende Arbeitsabläufe integriert werden.

6 Zusammenfassung & Ausblick

6.1 Zusammenfassung

Im Projekt Neufert 4.0 haben wir untersucht, wie datenbasierte und KI-gestützte Methoden den architektonischen Entwurfsprozess sinnvoll unterstützen können. Dabei richteten wir uns an drei zentralen Forschungsfragen aus: Erstens, wie können multidimensionale Grundrissdaten optimal für maschinelle Lernalgorithmen aufbereitet werden? Zweitens, welche Modelle des maschinellen Lernens eignen sich am besten zur Extraktion von Entwurfsheuristiken, und wie gut lassen sich diese auf neue Problemstellungen übertragen? Drittens, wie können die identifizierten Heuristiken so visualisiert werden, dass sie für Architekt:innen leicht verständlich und praktisch nutzbar sind?

Ein wesentlicher Schwerpunkt lag auf der Datenrepräsentation, die entscheidend für die Trainingsqualität der KI-Modelle war. Der Prozess begann mit einer umfangreichen **Datenbereinigung**: Aus den insgesamt 37.174 Grundrissen wurden fehlerhafte, redundante oder nicht standardisierte Einträge entfernt. Dafür wurde eigens ein Review-Tool entwickelt, mit dem problematische Grundrisse identifiziert und korrigiert wurden. Der bereinigte Datensatz wurde auf der Open-Data-Plattform Zenodo veröffentlicht, um die Transparenz und Nachnutzbarkeit zu fördern.

Um den Informationsgehalt der Grundrisse zu bewerten, führten wir eine **Merkmalsanalyse** durch. Dabei wurden geometrische Merkmale (wie Fläche und Kompaktheit) mit kontextbezogenen Eigenschaften (wie Beleuchtung) kombiniert. Ziel war es, eine reduzierte, aber hochwertige Merkmalsauswahl zu erstellen, die sowohl die Vorhersagegenauigkeit der Modelle maximiert als auch die Datenkomplexität verringert.

Im Projekt wurden **vier Heuristiken** entwickelt, die jeweils auf unterschiedlichen KI-Modellen basierten und spezifische Anforderungen an die Datenrepräsentation stellten. Der Fokus lag dabei auf der Repräsentation der Umrissgeometrie, die als Grundlage für alle Heuristiken diente. Diese wurde durch zahlreiche geometrische Eigenschaften beschrieben und für die KI-Modelle in standardisierte Vektorform gebracht. Für einige Heuristiken wurden spezifische Anpassungen vorgenommen. So wurde bspw. für die Suche nach ähnlichen Grundrissen zusätzlich ein Maß für die Formähnlichkeit integriert, um präzisere Suchergebnisse zu ermöglichen. Die Heuristik Raumdiagramme nutzte ein graphenbasiertes neuronales Netzwerk, für das wir eine graphenbasierte Repräsentation erstellt haben.

Jedes der vier Modelle wurde iterativ entwickelt und getestet. Bis auf die Heuristik „Raumdiagramme“ konnten mit allen Modellen überzeugende Ergebnisse erzielt werden. Aufgrund methodischer Einschränkungen wurde die Heuristik „Raumdiagramme“ nicht in den abschließenden Anwendertest einbezogen.

Für den Anwendertest wurde ein webbasiertes Interface entwickelt, das die KI-Modelle mit gängigen CAD-Tools verknüpfte. Die Ergebnisse des Tests zeigten, dass die entwickelten Heuristiken den Entwurfsprozess sinnvoll unterstützen können. Insbesondere die generative Funktionalität überzeugte durch ihre Fähigkeit, kreative Entwurfsideen zu liefern und alternative Lösungen zu visualisieren. Gleichzeitig wurde der Wunsch nach mehr Steuerungsmöglichkeiten geäußert, um die generierten Entwürfe stärker an spezifische Anforderungen anzupassen. Die

Suchfunktion wurde als wertvoll zur schnellen Identifikation von Referenzgrundrissen angesehen, könnte jedoch durch kontextspezifische Filter und eine bessere Erklärung zugrundeliegender Prinzipien verbessert werden. Die Funktion „Umrisspotential“ zeigte Schwächen in der Akzeptanz, da ihr starker Fokus auf numerische Metriken nicht mit der intuitiven Arbeitsweise von Planenden harmonierte.

6.2 Ausblick

Das Projekt Neufert 4.0 hat gezeigt, dass KI-gestützte Heuristiken großes Potenzial haben, den architektonischen Entwurfsprozess zu unterstützen. Auf Basis der gewonnenen Erkenntnisse lassen sich mehrere Ansätze für zukünftige Entwicklungen ableiten, um die Methoden weiter zu optimieren und ihre Praxistauglichkeit zu erhöhen.

Ein zentraler Ansatzpunkt ist die Erweiterung der Datenbasis. Durch die Integration vielfältiger Grundrissstile und innovativer Wohnformen könnten die Such- und Generierungsfunktionen diverser gestaltet und auf eine breitere Palette architektonischer Kontexte angewendet werden. Ergänzend könnte die Möglichkeit geschaffen werden, nach spezifischen Grundrissstilen oder Nutzungskonzepten zu filtern, um die Ergebnisse stärker auf individuelle Anforderungen abzustimmen.

Zudem sollte der Fokus auf eine stärkere Kontrolle und Anpassbarkeit der generativen Funktionen gelegt werden. Die Möglichkeit, Parameter wie Symmetrieachsen, Fassadenbeziehungen oder strukturelle Elemente gezielt zu definieren, würde es Architekten ermöglichen, die generierten Entwürfe noch besser auf ihre spezifischen Entwurfsziele auszurichten. Eine Verlagerung von der Wohnungs- auf die Geschossebene könnte ebenfalls die Relevanz der Ergebnisse für den Gesamtentwurf steigern.

Ein weiterer wichtiger Schritt ist die Verbesserung der Visualisierung und Benutzerfreundlichkeit. Umrisspotential-Vorhersagen könnten durch intuitivere, visuelle Darstellungen ergänzt werden, die Architekten eine schnellere und praxisgerechte Bewertung von Entwürfen ermöglichen. Ebenso könnte die Integration von Kontextinformationen, wie z. B. städtebauliche Rahmenbedingungen oder baurechtliche Vorschriften, die Relevanz der Ergebnisse erhöhen.

Schließlich könnten die entwickelten Methoden durch Nutzerfeedback in der Praxis kontinuierlich verfeinert werden. Langfristige Tests mit professionellen Architekten in realen Planungsprozessen könnten dazu beitragen, die Methoden gezielt weiterzuentwickeln und ihre Integration in bestehende Workflows zu optimieren.

Literaturverzeichnis

- Ahmed, S., Weber, M., Liwicki, M., Langenhan, C., Dengel, A., & Petzold, F. (2013). Automatic analysis and sketch-based retrieval of architectural floor plans. *Pattern Recognition Letters (PRL)*, 35, 91–100. <https://doi.org/10.1007/s10032-019-00340-1>
- Aichholzer, O., Aurenhammer, F., Alberts, D., & Gärtner, B. (1996). A novel type of skeleton for polygons. *Springer*.
- Basaraner, M., & Cetinkaya, S. (2017). Performance of shape indices and classification schemes for characterising perceptual shape complexity of building footprints in GIS. *International Journal of Geographical Information Science*, 31(10), 1952–1977.
- Chaillou, A. (2019). AI & Architecture - Towards a new approach. Master Thesis, *Harvard University*.
- Charles, R. Q., Su, H., Mo, K., & Guibas, L. J. (2017). PointNet: Deep learning on point sets for 3D classification and segmentation. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 77–85.
- Dupty, H. M., Dong, Y., Leng, S., Fu, G., Goh, Y. L., Lu, W., & Lee, W. S. (2024). Constrained layout generation with factor graphs. *arXiv e-prints*, arXiv:2404.
- Eisenstadt, V., Langenhan, C., & Althoff, K.-D. (2019). Generation of floor plan variations with convolutional neural networks and case-based reasoning. *eCAADe 37 / SIGRadDi*, 79–84.
- Eisenstadt, V., Schulz, K., Langenhan, C., & Althoff, K. D. (2019). Adaptive augmentation of the architectural design process: Case-based reasoning to assist and guide the designer during the early conceptual phases. *Journal of Design Science*, ISSN: 2053-4701.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*.
- Hagberg, A., Swart, P. J., & Schult, D. A. (2008). Exploring network structure, dynamics, and function using NetworkX. *Los Alamos National Laboratory (LANL)*.
- Haralick, R. M., & Shapiro, L. G. (1992). *Computer and robot vision (Volume 1)*. Addison-Wesley Publishing Company.
- Heckmann, O., & Schneider, F. (2011). *Grundrissatlas Wohnungsbau*. Basel: Birkhäuser.
- Hölscher, C., & Conroy Dalton, R. (2016). *Take one building: Interdisciplinary research perspectives of the Seattle Central Library*. Routledge Chapman Hall.
- Hu, M. K. (1962). Visual pattern recognition by moment invariants. *IRE Transactions on Information Theory*, 8(2), 179–187.
- Isola, P., Zhu, J.-Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Kahnemann, D. (2012). *Schnelles Denken, langsames Denken*. Siedler Verlag.
- Khamam, F. (2023). AI in Architectural Design - User-guided floor plan generation using generative adversarial networks. *Master Thesis. Detmold School of Architecture and Interior Architecture*.
- Kohonen, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9), 1464–1480.
- Leng, S., Zhou, Y., Dupty, H. M., Lee, W. S., Joyce, S. C., & Lu, W. (2023). Tell2design: A dataset for language-guided floor plan generation. *arXiv preprint*, arXiv:2311.15941.

- Merrell, P., Schkufza, E., & Koltun, V. (2010). Computer-generated residential building layouts. *ACM Transactions on Graphics (TOG)*, 29(6).
- Neufert, E., Lohmann, M., Merkel, P., Brockhaus, M., & Kister, J. (2018). *Bauentwurfslehre: Grundlagen, Normen, Vorschriften*. 42. Auflage. Springer Vieweg.
- Ploennigs, J., & Berger, M. (2023). Diffusion models for computational design at the example of floor plans. *arXiv preprint*, arXiv:2307.02511.
- Ramesh, A., Dhariwal, P., Nichol, A., Chu, C., & Chen, M. (2022). Hierarchical text-conditional image generation with CLIP latents. *arXiv preprint*, arXiv:2204.06125.
- Richter, K. (2011). Augmenting designers' memory: Case-based reasoning in der Architektur. Dissertation, *Bauhaus-Universität Weimar, Logos Berlin*.
- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Sharma, D., Gupta, N., Chattopadhyay, C., & Metha, S. (2019). A novel feature transform framework using deep neural network for multimodal floor plan retrieval. *IJDAR*, 22, 417–429. <https://doi.org/10.1007/s10032-019-00340-1>.
- Shabani, M. A., Hosseini, S., & Furukawa, Y. (2023). HouseDiffusion: Vector floorplan generation via a diffusion model with discrete and continuous denoising [Supplementary Material].
- Stamm-Teske, W., Fischer, K., & Haag, T. (2010). *Raumpilot Wohnen*. Stuttgart: Krämer Verlag.
- Standfest, M., Franzen, M., Schröder, Y., Medina, L. G., Hernandez, Y. V., Buck, J. H., Tan, Y. L., Niedzwiecka, M., & Colmegna, R. (2022). Swiss Dwellings: A large dataset of apartment models including aggregated geolocation-based simulation results covering viewshed, natural light, traffic noise, centrality, and geometric analysis.
- Sun, F. Y., Hoffmann, J., Verma, V., & Tang, J. (2019). Infograph: Unsupervised and semi-supervised graph-level representation learning via mutual information maximization. *arXiv preprint*, arXiv:1908.01000.
- Wentz, E. A. (2000). A shape definition for geographic applications based on edge, elongation, and perforation. *Geographical Analysis*, 32(2), 95–112.
- Wu, L., Cui, P., Pei, J., Zhao, L., & Guo, X. (2022). Graph neural networks: Foundation, frontiers and applications. *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 4840–4841.
- Yan, X., Ai, T., Yang, M., & Tong, X. (2021). Graph convolutional autoencoder model for the shape coding and cognition of buildings in maps. *International Journal of Geographical Information Science*, 35(3), 490–512.
- Zeisel, J. (2006). *Inquiry by design - Environment / behavior / neuroscience in architecture, interiors, landscape, and planning*. New York: W.W. Norton & Company.
- Zeng, P., Gao, W., Yin, J., Xu, P., & Lu, S. (2024). Residential floor plans: Multi-conditional automatic generation using diffusion models. *Automation in Construction*, 162, 105374.

Anhang

Publikationsliste

- Bielik, M., Valasek, M., Zhang, L., & Schneider, S. (2025). Floor Plan Affordance Prediction: Is the floor plan layout determined by its outline or by the architect? *CAAD Futures 2025*, Hong Kong. (eingereicht)
- Bielik, M., Zhang, L., Schneider, S., & Valasek, M. (2025). Bridging the Gap: Enhancing AI-Generated Floor Plans with Multi-Modal Data Integration. *CAAD Futures 2025*, Hong Kong. (eingereicht)
- Bielik, M., Zhang, L., & Schneider, S. (2023). Big Data, Good Data, and Residential Floor Plans. In M. Turrin, C. Andriotis, & A. Rafiee (Eds.), *Computer-Aided Architectural Design. INTERCONNECTIONS: Co-computing Beyond Boundaries* (pp. 607–622). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-37189-9_40
- Khamam, F., & Schneider, S. (2023). User guided floor plan generation using generative adversarial networks. *34. Forum Bauinformatik*, Bochum, 06.–08.09.2023.
- M., Zhang, L., Bielik, M., Valasek, M., & Schneider, S. (2025). Automated vector-based residential layout generation based on graph neural networks. *CAAD Futures 2025*, Hong Kong. (eingereicht)
- Zhang, L. (2023). Automatic Residential Floor Plan Layout Prediction Based on Graph Neural Networks. *Master Thesis*. Bauhaus-Universität Weimar.

Datenveröffentlichung

Die im Projekt entwickelten Methoden wurden auf GitHub veröffentlicht:

<https://github.com/Bauhaus-InfAU/Neufert4.0>

Die bereinigte Grundrissdatenbank wurde auf Zenedo veröffentlicht:

<https://zenodo.org/records/14223942>