

Potenziale fernerkundlicher Daten und Methoden für die urbane Verkehrsforschung

Inaugural-Dissertation zur Erlangung der
Doktorwürde der Philosophischen Fakultät
der Julius-Maximilians-Universität Würzburg

vorgelegt von Dorothee Stiller aus München



Erstgutachter: Prof. Dr. Stefan Dech
Zweitgutachter: Prof. Dr. Hannes Taubenböck
Drittgutachter: Prof. Dr. Jürgen Rauh

Tag des Kolloquiums: 15.09.2025





*"A developed country is not a place where the poor people have cars but
it is where the rich people use public transport."*

Enrique Peñalosa

Bürgermeister von Bogotá 1998-2000 & 2015-2019

Diese Dissertation wurde in der Abteilung "Georisiken und Zivile Sicherheit" am Deutschen Fernerkundungsdatenzentrum (DFD), Earth Observation Center (EOC) des Deutschen Zentrums für Luft- und Raumfahrt (DLR) in Oberpfaffenhofen angefertigt.



**Deutsches Zentrum
für Luft- und Raumfahrt**
German Aerospace Center



This document is licensed under the Creative Commons Attribution 4.0 International License (CC BY 4.0):
<http://creativecommons.org/licenses/by/4.0> This CC license does not apply to third party material (attributed to another source) in this publication.

Danksagung

Ich möchte all jenen danken, die mich auf dem Weg zur Fertigstellung dieser Dissertation begleitet und unterstützt haben.

Mein besonderer Dank gilt meinem Doktorvater, Prof. Dr. Stefan Dech, der mich mit großer Geduld über die gesamte Zeit hinweg begleitet und mich immer wieder daran erinnert hat, neben allen inhaltlichen Details und Ideen das große Ganze nicht aus den Augen zu verlieren. Danke, Stefan!

Ebenso herzlich danke ich Prof. Dr. Hannes Taubenböck für seine unermüdliche Unterstützung und wertvollen Diskussionen, sein Vertrauen und seine Begeisterung, die stets ansteckend war. Seine motivierenden Worte haben mich immer wieder inspiriert und angespornt. Danke, Hannes!

Ein großer Dank geht auch an Prof. Dr. Jürgen Rauh, der sich als drittes Mitglied meines Mentorats bereit erklärt hat, diese Arbeit zu begleiten. Ich danke Ihnen insbesondere für die Diskussion und Ihre Beteiligung an meiner dritten Studie. Danke, Herr Rauh!

Ein ganz besonderer Dank gilt meinem Mentor Dr. Michael Wurm, der mich mit großer fachlicher Expertise und ebenso viel menschlichem Beistand durch alle Höhen und Tiefen begleitet hat. Ihm verdanke ich die inhaltliche Geschlossenheit dieser Dissertation und dass ich sie am Ende zu Ende gebracht habe. Danke, Michael!

Mein Dank gilt außerdem allen Ko-Autorinnen und Ko-Autoren für eure professionelle Unterstützung bei der Datenerhebung und -analyse, für methodische wie inhaltliche Diskussionen und eure Mitarbeit an den Texten. Ebenso danke ich den vielen Studierenden, die im Rahmen von Praktika und Abschlussarbeiten wertvolle Beiträge geleistet haben.

Danke an Dr. Martin Wegmann, für das erste Seminar, das mich mit der Fernerkundung in Kontakt brachte, und natürlich für den Kontakt zum DLR.

Herzlichen Dank an alle Kolleginnen und Kollegen für den fachlichen wie persönlichen Austausch und für eure Unterstützung. In diesem Kontext, muchas gracias an Marta für die Korrektur

der spanischen Zusammenfassung. Besonders danke ich meinen Weggefährten:innen in der Promotionszeit: Jeroen, Thomas, Ines, Matthias, Ariane, Patrick und Nico, die mir gezeigt haben, dass eine Promotion möglich ist – mit all ihren Herausforderungen. Danke auch an das ST-Office, an Tom und Cherry, für eure Professionalität, den Austausch und die inspirierende und witzige gemeinsame Zeit. Und lasst uns endlich den 2018er Silvaner im Schrank öffnen, dann beginnt vielleicht auch wieder der Bürowein zu blühen.

Ein riesiges Danke geht auch an meine Freund:innen – zu viele, um sie hier alle zu nennen. Einige von euch wussten mehr, andere weniger über das, was ich beruflich eigentlich mache. Aber ihr wart da und habt mich unterstützt – und das zählt. Danke auch an die subkulturellen Räume, die wir gemeinsam gestaltet oder betreten haben. Sie waren für mich ein notwendiger Ausgleich zur wissenschaftlichen Welt und haben mir geholfen, neue Perspektiven zu entwickeln, außerhalb der gewohnten Denkstrukturen.

Ein besonders herzlicher Dank geht an die Chicas, mit euch war das Studium eine Reise voller Überraschungen. Trotz aller Unterbrechungen haben sich unsere privaten und beruflichen Wege immer wieder verbunden. Ihr wart Teil davon, dass ich zur Fernerkundung und zum DLR gekommen bin – und dafür danke ich euch. Miau!

Von ganzem Herzen danke ich meiner Familie, die nie an mir oder meinem Weg gezweifelt hat und mich in allen Lebenslagen unterstützt hat. Ihr habt mir ein freies und selbstbestimmtes Leben ermöglicht – mit Raum für Entwicklung, mit Vertrauen und mit Liebe. Dass ich diese Promotion überhaupt angehen konnte, ist eurer Unterstützung zu verdanken. Das ist nicht selbstverständlich, und ich bin euch unendlich dankbar!

Ein ganz besonderer Dank gilt Flo, der mich mit viel Geduld, Verständnis und emotionalem Beistand begleitet hat. In Momenten des Zweifels hast du mir immer gut zuredet, mich gestärkt und daran erinnert, dass ich das schaffen kann. Gracias für deine liebevolle Unterstützung.

Am Ende bleibt mir noch, ein paar persönliche Gedanken zu teilen:

Ich hoffe, dass diese Arbeit – so klein ihr Beitrag auch sein mag – einen Impuls gibt für eine friedlichere, gerechtere und nachhaltigere Welt, in der alle Menschen die gleichen Chancen haben. Das ist die Welt, für die ich eintreten möchte. Wissenschaft kann – und sollte – dabei eine Rolle spielen: als Werkzeug des Verstehens, des Hinterfragens und des Gestaltens.

Das Leben ist oft zu ernst und dabei viel zu kurz.

Gehen wir mit mehr Leichtigkeit und Menschlichkeit durchs Leben. Verlieren wir nie den Mut, anders zu denken.

Zusammenfassung

Verkehr ist ein wesentlicher Bestandteil des städtischen Lebens. Urbane Mobilität gewährleistet den Zugang zu zentralen Funktionen der Stadt, etwa Arbeitsplätzen, Bildungseinrichtungen und Gesundheitsversorgung, und trägt so maßgeblich zur Förderung sozialer Inklusion bei. Die fortschreitende Urbanisierung und das stetig steigende Verkehrsaufkommen stellen Städte weltweit vor erhebliche Herausforderungen, da die starke Verkehrsnachfrage bei gleichzeitig hoher Bevölkerungsdichte und expansivem Städtewachstum zu einer Konkurrenz um begrenzten Raum, zu Engpässen in der Kapazität des Verkehrssystems, zu negativen Umweltfolgen wie Luftverschmutzung und Lärmbelastung sowie zu sozialen und gesundheitlichen Belastungen führt. In diesem Kontext gewinnen innovative Technologien wie Fernerkundung und offene Geodaten zunehmend an Bedeutung, um datenbasierte Analysen zu ermöglichen, die eine fundierte Grundlage für die Stadt- und Verkehrsplanung bieten.

Das wesentliche Ziel dieser Arbeit ist zu beleuchten, wie Daten aus der Fernerkundung und offene Geodaten in Kombination mit modernen Methoden zur Analyse urbaner Strukturen und Verkehrsmuster eingesetzt werden können, um bestehende Datenlücken zu reduzieren oder zu schließen und inwieweit dies dazu beitragen kann, eine nachhaltige Entwicklung urbaner Räume zu fördern.

Diese Dissertation gliedert sich in drei Teilbereiche: Der erste Teil beschäftigt sich mit der Ableitung verkehrsrelevanter urbaner Strukturen, insbesondere Gebäude, Landnutzung und Bevölkerung, auf Basis von Fernerkundung und offen zugänglichen Geodaten. Am Beispiel von Santiago de Chile wurde eine Deep-Learning-basierte Methode zur Gebäudesegmentierung entwickelt und anschließend erfolgreich auf Medellín, Kolumbien, übertragen. In Kombination mit fernerkundungsbasierten Höhenmodellen konnte ein hochaufgelöstes 3D-Gebäudemodell abgeleitet werden, das durch OpenStreetMap-Daten und Street-View-Bilder semantisch weiter angereichert wurde. So konnte ein multimodaler Ansatz zur Abbildung der urbanen Raumstruktur und zur kleinteiligen Bevölkerungsschätzung entwickelt werden, der neue Perspektiven für datenarme Regionen eröffnet.

Der zweite Schwerpunkt dieser Dissertation liegt auf der Analyse der Erreichbarkeit öffentlicher Verkehrsmittel. Dabei steht der Indikator für Erreichbarkeit 11.2. der Ziele für nachhaltige Entwicklung (engl. *Sustainable Development Goals*, SDG) sowie damit verbundener sozialer und räumlicher Gerechtigkeit im Zentrum der Analysen. Am Beispiel von Medellín wurde un-

tersucht, wie verschiedene Bevölkerungsdatensätze – einschließlich Fernerkundungsdaten und global verfügbarer Datensätze – zur Bewertung der Erreichbarkeit genutzt werden können. Die Ergebnisse zeigen, dass semiformelle Verkehrssysteme wie lokale Minibusse eine zentrale Rolle bei der Verbesserung der Erreichbarkeit spielen. Die Analyse verdeutlicht zugleich, dass sozio-ökonomisch benachteiligte Gruppen häufig deutlich längere Wege zu Haltestellen des formellen Verkehrs zurücklegen müssen. Dies zeigt bestehende räumliche und soziale Ungleichheiten auf und unterstreicht das Potenzial von Fernerkundung und Geodaten als Informationsbasis, um zur Verbesserung der Datengrundlage in der Verkehrsplanung beizutragen.

Als weiterer fernerkundlicher Ansatz zur Erfassung von Verkehr wird im dritten Teil der Dissertation das Potenzial öffentlich zugänglicher Webcam-Daten für eine skalierbare und kostengünstige Verkehrsüberwachung untersucht. Trotz Herausforderungen wie variierender Bildqualität konnte das Objekterkennungsmodell YOLOv8 erfolgreich zur Erfassung von Verkehrsdaten eingesetzt werden. Die Anwendung des Modells auf rund 500.000 Webcam-Bilder aus Berlin, Deutschland, zeigte signifikante Veränderungen des Verkehrsaufkommens während der COVID-19-Pandemie: Während der motorisierte Verkehr um 9.5 % zurückging, nahm der Fahrradverkehr um 25.2 % zu. Diese Ergebnisse zeigen das Potenzial offener Webcam-Daten nicht nur für eine effiziente, großflächige Verkehrsanalyse, sondern auch für langfristige Trendanalysen, die traditionelle, aufwändigere oder kostspieligere Methoden ergänzen können.

Insgesamt verdeutlichen die Arbeiten dieser Dissertation, dass die Kombination moderner Technologien wie Fernerkundung, offener Geodaten und Deep Learning eine fundierte, datengetriebene Basis für die Analyse urbaner Strukturen schafft. Zusätzlich kann so die Erhebung verkehrsrelevanter Parameter, wie die Erreichbarkeit zu öffentlichem Verkehr oder automatisierte Verkehrszählungen durch Webcams weiter vorangetrieben werden. Die vorgestellten Ansätze ermöglichen eine skalierbare, flexible und kosteneffiziente Datengenerierung, die eine nachhaltige, durch Empirie gestützte Stadtentwicklung unterstützen und zur Reduzierung sozialer und räumlicher Ungleichheiten beitragen kann.

Abstract

Transport is a fundamental component of urban life. Urban mobility ensures access to key urban functions – such as employment, education, and healthcare – and thus plays a crucial role in promoting social inclusion. However, ongoing urbanization and steadily increasing traffic volumes present significant challenges for cities worldwide. High transport demand, coupled with dense population and expansive urban growth, leads to competition for limited space, bottlenecks in transport system capacity, adverse environmental impacts such as air pollution and noise, and associated social and health burdens. In this context, innovative technologies such as remote sensing and open geospatial data are becoming increasingly important, as they enable data-driven analyses that provide a sound foundation for urban and transport planning.

The primary objective of this dissertation is to explore how remote sensing data and open geospatial datasets, in combination with modern methods for analyzing urban structures and mobility patterns, can be used to reduce or close existing data gaps – and to what extent this can contribute to sustainable urban development.

This dissertation is divided into three main sections: The first focuses on deriving transport-relevant urban spatial structures – specifically buildings, land use, and population – from remote sensing and publicly available geodata. Using the example of Santiago de Chile, a deep-learning-based method for building segmentation was developed and successfully transferred to Medellín, Colombia. Combined with remote sensing-based elevation models, a high-resolution 3D building model was generated and semantically enriched using OpenStreetMap data and street-view imagery. This enabled the development of a multimodal approach for mapping urban spatial structure and for estimating population distribution at fine spatial scales, offering new perspectives for data-scarce regions.

The second part of the dissertation centers on the analysis of public transport accessibility. The analysis focuses on Sustainable Development Goal (SDG) Indicator 11.2, which addresses accessibility as well as related issues of social and spatial equity. Using the case of Medellín, the study investigates how various population datasets – including remote sensing-based and globally available data – can be leveraged to assess accessibility. The results show that semi-formal transport systems such as the local minibuses play a key role in improving accessibility. At the same time, the analysis highlights that socioeconomically disadvantaged groups often face significantly longer walking distances to formal public transport stops. These findings reveal

persistent spatial and social inequalities and underscore the potential of remote sensing and geospatial data to serve as a valuable information base for enhancing data availability in transport planning.

The third part of the dissertation explores the potential of publicly accessible webcam data as a remote sensing-based approach for scalable and cost-effective traffic monitoring. Despite challenges such as variable image quality, the object detection model YOLOv8 was successfully applied to monitor road traffic. Applying the model to approximately 500,000 webcam images from Berlin, Germany, revealed significant changes in traffic volumes during the COVID-19 pandemic: motorized traffic decreased by 9.5 %, while bicycle traffic increased by 25.2 %. These findings emphasize the potential of open webcam data for efficient, large-scale traffic analysis that can complement traditional, more labor-intensive or costly methods.

Overall, the work presented in this dissertation demonstrates that the integration of modern technologies – such as remote sensing, open geospatial data, and deep learning – can provide a robust, data-driven foundation for analyzing urban structures. Moreover, this combination facilitates the collection of transport-relevant parameters, such as accessibility to public transport or automated traffic counts via webcams. The proposed approaches enable scalable, flexible, and cost-efficient data generation that can support sustainable, empirically grounded urban development and contribute to reducing social and spatial inequalities.

Resumen

El transporte es un componente esencial de la vida urbana. La movilidad urbana garantiza el acceso a funciones clave de las ciudades – como el empleo, la educación y la atención sanitaria – y, por tanto, desempeña un papel crucial en el fomento de la inclusión social. Sin embargo, el desarrollo urbano y el aumento constante del volumen de tráfico presentan desafíos significativos para las ciudades de todo el mundo. La elevada demanda de transporte, unido a la densidad de población y al crecimiento urbano expansivo, genera una competencia por el espacio limitado, restricciones de capacidad en los sistemas de transporte, impactos ambientales adversos como la contaminación atmosférica y acústica, y cargas sociales y de salud. En este contexto, tecnologías innovadoras como la teledetección y los datos geoespaciales abiertos están ganando importancia, ya que permiten realizar análisis basados en datos que proporcionan una base sólida para la planificación urbana y del transporte.

El objetivo principal de esta tesis es explorar cómo los datos de teledetección y los conjuntos de datos geoespaciales abiertos, en combinación con métodos modernos para analizar las estructuras urbanas y los patrones de movilidad, pueden emplearse para reducir o cubrir las carencias de datos existentes, y en qué medida esto puede contribuir al desarrollo urbano sostenible.

Esta tesis se divide en tres secciones principales: La primera se centra en la extracción de estructuras urbanas relevantes para el transporte – específicamente edificios, uso del suelo y población – a partir de datos de teledetección y datos geoespaciales de acceso abierto. Utilizando el ejemplo de Santiago de Chile, se desarrolló un método basado en aprendizaje profundo para la segmentación de edificios y posteriormente se aplicó con éxito a Medellín, Colombia. Combinados con modelos de elevaciones basados en teledetección, se generó un modelo 3D de edificios de alta resolución, el cual se enriqueció semánticamente utilizando datos de OpenStreetMap e imágenes de Google Street View. Este enfoque multimodal permitió el cartografiado detallado de estructuras espaciales urbanas y la estimación de población a escala espacial fina, ofreciendo nuevas perspectivas para regiones con escasez de datos.

La segunda parte de esta tesis es el análisis de la accesibilidad al transporte público. El análisis se centra en el indicador 11.2 de los Objetivos de Desarrollo Sostenible (*Sustainable Development Goals*, SDGs), que aborda la accesibilidad, así como la equidad social y espacial asociada. Utilizando Medellín como ejemplo, el estudio examinó cómo se pueden utilizar diversos conjuntos de datos de población – incluidos los basados en teledetección y los disponibles a nivel mundial – para evaluar la accesibilidad. Los resultados indican que los sistemas de transporte semi-

formales, como los minibuses locales, desempeñan un papel clave en la mejora de la accesibilidad. Al mismo tiempo, el análisis revela que los grupos socioeconómicamente desfavorecidos suelen tener distancias significativamente más largas hasta las paradas de transporte público formal, lo que pone de manifiesto las desigualdades espaciales y sociales existentes y enfatiza el potencial de la teledetección y los datos geoespaciales como bases de información para mejorar las bases de datos en la planificación del transporte.

La tercera parte de la tesis explora el potencial de los datos de cámaras web de acceso público desde un enfoque basado en la teledetección para la monitorización del tráfico de manera escalable y rentable. A pesar de algunos desafíos como la variabilidad en la calidad de las imágenes, se empleó con éxito el modelo de detección de objetos YOLOv8 para capturar datos de tráfico. La aplicación del modelo a aproximadamente 500,000 imágenes de cámaras web reveló cambios significativos en los volúmenes de tráfico durante la pandemia de COVID-19: el tráfico motorizado disminuyó un 9.5 %, mientras que el tráfico en bicicleta aumentó un 25.2 %. Estos resultados subrayan el potencial de los datos abiertos de cámaras web para realizar análisis de tráfico eficientes y a gran escala que pueden complementar los métodos tradicionales, más laboriosos o costosos.

En general, el trabajo presentado en esta tesis demuestra que la combinación de tecnologías modernas como la teledetección, los datos geoespaciales abiertos y el aprendizaje profundo puede establecer una base sólida y basada en datos para analizar estructuras urbanas. Además, esta combinación facilita la recopilación de parámetros relevantes para el transporte, como la accesibilidad al transporte público o los recuentos de tráfico automatizados a través de cámaras web. Los enfoques presentados permiten una generación de datos escalable, flexible y rentable que puede respaldar un desarrollo urbano sostenible basado en evidencia empírica y contribuir a reducir las desigualdades sociales y espaciales.

Inhaltsverzeichnis

Zusammenfassung	iii
Abstract	v
Resumen	vii
Abbildungsverzeichnis	xiv
Tabellenverzeichnis	xv
Abkürzungsverzeichnis	xvii
1 Einleitung	1
1.1 Hintergrund	1
1.2 Forschungslücke	3
1.3 Ziele der Arbeit und Forschungsfragen	5
1.4 Aufbau der Arbeit	7
2 Grundlagen	9
2.1 Das urbane Verkehrssystem	9
2.2 Fernerkundung und Geodaten in der Verkehrsforschung	12
3 Konzeptioneller Rahmen	17
3.1 Bedeutung städtischer Raumstruktur für urbanen Verkehr	17
3.1.1 Gebäude	20
3.1.2 Landnutzung	22
3.1.3 Bevölkerung	22
3.2 Erreichbarkeit öffentlicher Verkehrsmittel	23
3.2.1 Messung der Erreichbarkeit	24
3.2.2 Informeller Transport, semiformeller Transport, Paratransit	26
3.2.3 Die Situation in Medellín, Kolumbien	27
3.2.4 Teilfragen und Zielsetzung	29
3.3 Offene Bilddaten und KI-basierte Analyseverfahren für urbanes Mobilitätsmonitoring	30
3.3.1 Forschungskontext und Zielsetzung	30

3.3.2	Konzept und Potenzial der Nutzung offener Webcam-Daten für die urbane Verkehrsforschung	33
4	Untersuchungsgebiete und Daten	37
4.1	Untersuchungsgebiete	37
4.1.1	Santiago de Chile, Chile	37
4.1.2	Medellín, Kolumbien	38
4.1.3	Berlin, Deutschland	39
4.2	Daten	39
4.2.1	Daten für die großflächige Gebäudeextraktion	39
4.2.2	Daten für die Anreicherung der Gebäudegrundrisse	41
4.2.3	Daten für die Berechnung der Erreichbarkeit öffentlicher Verkehrsmittel	43
4.2.4	Webcam-Bilddaten für die Verkehrszählung	48
5	Methoden	53
5.1	Experimenteller Aufbau für die großflächige Gebäudeextraktion	53
5.1.1	Fine-Tuning	53
5.1.2	Klassifikation und Mosaikerstellung	54
5.1.3	Evaluierung	55
5.2	Erstellung und Validierung des funktionalen 3D-Stadtmodells	56
5.3	Routinganalyse für die Ermittlung der Erreichbarkeit öffentlicher Verkehrsmittel	60
5.4	YOLOv8 für die Erkennung von Verkehrsobjekten	61
6	Ergebnisse	63
6.1	Evaluierung von Mask-RCNN für die Gebäudeextraktion	63
6.2	Funktionales 3D-Stadtmodell	65
6.2.1	Gebäudemodell	65
6.2.2	Ableitung von Gebäudegeschossen	67
6.2.3	Innerstädtische Landnutzung	67
6.2.4	Schätzung der Bevölkerung	69
6.3	Erreichbarkeit des öffentlichen Verkehrs am Beispiel Medellín	71
6.3.1	Erreichbarkeit basierend auf dem formellen öffentlichen Verkehr	71
6.3.2	Erreichbarkeit des semiformalen Verkehrs	73
6.3.3	Erreichbarkeit basierend auf sozioökonomischem Status und Informalität	74
6.4	Detektion von Verkehrsteilnehmenden in Webcam-Bilddaten	77
6.4.1	Test der YOLOv8-Parameter	77
6.4.2	Langfristige Trendanalyse: COVID-19 Fallstudie	78
7	Diskussion	83
7.1	Funktionales 3D Stadtmodell für grundlegende Verkehrsparameter der urbanen Raumstruktur	83

7.1.1	Großflächige Gebäudeextraktion mit Mask R-CNN	84
7.1.2	Semantische Anreicherung des Gebäudemodells	86
7.2	Erreichbarkeit von öffentlichem Verkehr in Medellín	89
7.3	Detektion von Verkehrsteilnehmenden auf Webcam-Bilddaten	96
7.3.1	Webcam-Daten zur Zählung von Verkehrsteilnehmenden	96
7.3.2	Detektion von Verkehrsteilnehmenden mit YOLOv8	97
7.3.3	Langzeit-Verkehrsmonitoring: Detektion von Verkehrsteilnehmenden in Webcam-Szenen vor und während COVID-19	99
8	Fazit und Ausblick	103
	Literatur	109

Abbildungsverzeichnis

1.1	Globale Treibhausgasemissionen	2
3.1	Beispielaufnahmen aus offenen Webcams und Karte ausgewählter Webcam-Standorte in Deutschland	34
4.1	Lage des Studiengebiets Santiago de Chile	38
4.2	Lage des Studiengebiets Medellín	39
4.3	Verwendete Luftbilder und Referenzdaten für Santiago de Chile	40
4.4	Exemplarischer Ausschnitt der OpenStreetMap Gebäudeabdeckung in Santiago de Chile	41
4.5	Übersicht der verwendeten Daten für Santiago de Chile	42
4.6	Visualisierung der verwendeten Bevölkerungsdatensätze für Medellín	45
4.7	Standorte der verschiedenen Verkehrshaltestellen in Medellín	46
4.8	Erweitertes Untersuchungsgebiet für sozioökonomische Analysen und Lage der informellen Siedlungen in Medellín	47
4.9	Beispielfelder der verwendeten Webcams aus Berlin	49
4.10	Entwicklung der gemeldeten COVID-19-Fälle in Berlin im Fallstudienzeitraum	50
5.1	Angewendete Augmentierungen für die großflächige Gebäudeextraktion	55
5.2	Funktionales 3D-Stadtmodell auf Grundlage des multimodalen Ansatzes	56
5.3	Schema zur OSM-basierten Landnutzungskategorisierung	58
5.4	Schematische Darstellung der fünf Experimente zur Bevölkerungsabschätzung auf Einzelgebäudeebene	60
6.1	Klassifikationsergebnisse der Gebäudeextraktion im Vergleich zu den Referenzdaten	65
6.2	Gebäudeextraktion für verschiedene Gebäudetypen in Santiago de Chile und Medellín	66
6.3	Beispielhafte Illustration des 3D-Stadtmodells mit Fokus auf dem Central Business District im Stadtzentrum von Santiago de Chile	66
6.4	Average Precision Error für verschiedene Gebäudehöhen und -flächen	67
6.5	Ergebnisse der Regressionsanalyse zur Abschätzung der Gebäudegeschosse in Abhängigkeit der Gebäudehöhe	68
6.6	Landnutzungskarte auf Einzelgebäudeebene für Santiago de Chile	68
6.7	Streudiagramme mit geschätzten Bevölkerungswerten im Vergleich zu den Referenzdaten des Zensus	70

6.8	Average Precision Error in Relation zu den Landnutzungsanteilen	70
6.9	Durchschnittliche Entfernung zu Fuß zur nächsten Haltestelle des formellen und semiformalen Verkehrs	73
6.10	Durchschnittliche Entfernung zu Fuß zur nächsten Haltestelle des öffentlichen Verkehrs nach sozioökonomischem Status	75
6.11	Durchschnittliche Entfernung zu Fuß zur nächsten Haltestelle des öffentlichen Verkehrs nach Anteil informeller Siedlungen	78
6.12	Absolute und relative Veränderungen der Langzeit-Verkehrszählung mit YOLOv8 während COVID-19	81
7.1	Ergebnisse der großflächigen Gebäudeextraktion mit Mask R-CNN in Santiago de Chile und Medellín	85
7.2	Klassifizierte Gebäude mit Landnutzung im Central Business District in Santiago de Chile	89
7.3	Distanz zu Fuß zur nächsten Haltestelle des formellen und semiformalen Verkehrs	91
7.4	Beispielbilder aus dem Fallstudien-Datensatz zur Veranschaulichung möglicher Detektionsfehler mit YOLO	98

Tabellenverzeichnis

2.1	Unterschiede der urbanen Verkehrssysteme zwischen Globalem Süden und Globalem Norden	11
4.1	Merkmale der Zensudaten für Santiago de Chile	44
4.2	Überblick über die verwendeten Bevölkerungsdatensätze für die Erreichbarkeitsanalysen in Medellín	45
4.3	Überblick über die verwendeten Datensätze der offenen Webcam-Bilddaten	48
4.4	Webcams und Straßennetzklassifikation in Berlin	51
5.1	Übersicht über die fünf Experimente zur Bevölkerungsabschätzung	59
6.1	Evaluierung getesteter Augmentierungen für Mask R-CNN zur Gebäudeextraktion	64
6.2	Mask R-CNN Modellbewertung des Basismodells und des angepassten Modells	64
6.3	Fehlermaße für die Bevölkerungsabschätzung	69
6.4	Erreichbarkeit des öffentlichen Verkehrs unter Verwendung verschiedener Bevölkerungsdatensätze	72
6.5	Unterschiede in der Gehdistanz zur nächsten Haltestelle nach der Erweiterung des U-Bahn-Netzes	76
6.6	Vergleich der Entfernungen zur nächsten Haltestelle nach Siedlungstyp	77
6.7	Zusammenfassung der F1-Scores für die Verkehrsobjekterkennung mit YOLO	79
6.8	Prozentuale Verkehrsdetektionen (Modal Split) pro Webcam im Vergleich der Jahre 2018 (vor COVID-19) und 2020 (während COVID-19)	80
7.1	Schematische Skizzierung von Fehlerarten bei der Detektionen von Verkehrsteilnehmenden in offenen Webcam-Bildern mittels YOLO	99

Abkürzungsverzeichnis

Abkürzung	Beschreibung
APE	Absolut Percent Error
BDSG	Bundesdatenschutzgesetz
BRT	Bus Rapid Transit
CBD	Central Business District
CNN	Convolutional Neural Network
DOM	Digitales Oberflächenmodell
DSGVO	Datenschutz-Grundverordnung
GHS-POP	Global Human Settlement Population
GIS	Geographic Information System
GIS-T	Geographic Information Systems for Transportation
GPS	Global Positioning System
GTFS	General Transit Feed Specification
InSAR	Interferometric Synthetic Aperture Radar
IoU	Intersection over Union
KUG	Kunsturhebergesetz
LiDAR	Light Detection and Ranging
MAE	Mean Absolut Error
nDOM	normalisiertes Digitales Oberflächenmodell
OA	Overall Accuracy
OSM	OpenStreetMap
ÖV	Öffentlicher Verkehr
POIs	Points of Interest

Abkürzung	Beschreibung
POT	Plan de Ordenamiento Territorial
RAE	Relative Absolut Error
ROI	Region of Interest
SAR	Synthetic Aperture Radar
SDG	Sustainable Development Goal
TAZ	Traffic Analysis Zone
UN	United Nations
VKT	Vehicle Kilometer Traveled
YOLO	You Only Look Once

Einleitung

1.1 Hintergrund

Das urbane Verkehrssystem spielt eine zentrale Rolle für die Funktionsfähigkeit und Lebensqualität moderner Städte und ist damit ein unverzichtbares Instrument für die Stadtentwicklung und das reibungslose Funktionieren urbaner Zentren (Nicolas, 2000; Levinson und Falcocchio, 2011). Städtischer Verkehr ist ein zentrales Thema der Ziele für nachhaltige Entwicklung (*Sustainable Development Goals, SDGs*) der Vereinten Nationen (UN), insbesondere von Ziel 11 „Nachhaltige Städte und Gemeinden“, das darauf abzielt, Städte inklusiv, sicher, widerstandsfähig und nachhaltig zu gestalten (United Nations, 2015). Das SDG-Ziel 11.2 fordert insbesondere zugängliche, sichere, erschwingliche und nachhaltige Verkehrssysteme für alle, mit besonderem Augenmerk auf sozial benachteiligte und marginalisierte Bevölkerungsgruppen (United Nations, 2015). Mehr als die Hälfte der Weltbevölkerung lebt aktuell in Städten und nach Prognosen der UN wird dieser Anteil bis zum Jahr 2050 auf 68 % steigen (United Nations, 2019). Diese Entwicklung und der zunehmende Mobilitätsbedarf erhöhen den Druck auf die städtische Infrastruktur und stellen hohe Anforderungen an die Effizienz, Nachhaltigkeit und Resilienz urbaner Transportsysteme (Ceder, 2020).

Ein funktionierendes Verkehrssystem ist essenziell für die wirtschaftliche Leistungsfähigkeit, soziale Inklusion und ökologische Nachhaltigkeit urbaner Räume. Ineffiziente Verkehrsstrukturen beeinträchtigen nicht nur die Lebensqualität der Stadtbevölkerung (Welch et al., 2013; Héritier et al., 2014), sondern verursachen auch erhebliche wirtschaftliche Kosten (Goodwin, 2004; Sweet, 2013) und tragen maßgeblich zur Umweltbelastung bei (Spellerberg, 1998; Condurat et al., 2017; Mansour und Aljamil, 2022). Der Verkehrssektor war im Jahr 2021 für etwa 13.7 % der weltweiten Treibhausgasemissionen verantwortlich (Abbildung 1.1 a), wobei der Straßenverkehr mit 12.7 % den größten Anteil daran hatte (Abbildung 1.1 b). Im Vergleich dazu entfallen nur 0.2 % der globalen Treibhausgasemissionen auf den Schienenverkehr. Angesichts dieser ökologischen und gesellschaftlichen Tragweite, entsteht ein dringender Bedarf an einer fundierten, flächendeckenden Datenbasis über das urbane Verkehrssystem, sowie an innovativen Ansätzen, um städtische Mobilität effizient und nachhaltig zu gestalten.




Abbildung 1.1: Globale Treibhausgasemissionen a) nach Sektoren und b) Gesamtanteile aus dem Verkehrssektor (verändert nach Ge et al., 2024, basierend auf Daten von Climate Watch (Weltressourceninstitut).

Darüber hinaus, ist ein effektives Verkehrsmanagement entscheidend, um die Herausforderungen des urbanen Verkehrssystems zu bewältigen. Eine verbesserte Verkehrssteuerung kann Staus reduzieren, die Verkehrssicherheit erhöhen und auch Emissionen signifikant verringern (Soni und Saraswat, 2017; Mansour und Aljamal, 2022; Armenta-Déu, 2025). Zusätzlich trägt ein leistungsfähiges Verkehrssystem zur wirtschaftlichen Entwicklung bei (Sweet, 2013; Magazzino und Mele, 2021) und fördert eine höhere Lebensqualität für die Bewohner (Héritier et al., 2014; Khomenko et al., 2022). Der wachsende Bedarf an datengesteuerten, nachhaltigen Verkehrslösungen rückt die Nutzung alternativer Datenquellen und Entwicklung neuer Methoden zur Erfassung und Analyse urbaner Mobilität zunehmend in den Fokus (Bibri und Krogstie, 2020; Engin et al., 2020). Die politische und gesellschaftliche Relevanz dieser Themen wird durch politische Initiativen wie dem *European Green Deal* unterstrichen. Dieser fordert eine Reduktion der CO₂-Emissionen im Verkehrssektor um 90 % bis 2050 und hat zum Ziel dies unter anderem durch intelligente Verkehrssteuerung umzusetzen (European Commission, 2019). Gleichzeitig verfehlen Länder wie Deutschland derzeit die EU-Klimaziele und den eigenen Zielwert der CO₂-Jahresemissionsmenge im Verkehrsbereich (Deutscher Bundestag, 2024), was den Handlungsdruck weiter erhöht. Politische und gesellschaftliche Debatten über Klimaschutz und nachhaltige Mobilität verdeutlichen zudem die Notwendigkeit, innovative Technologien zu nutzen, um städtische Verkehrs- und Planungssysteme zukunftsfähig zu gestalten (Roselló et al., 2016; Nieuwenhuijsen, 2020).

Vor dem Hintergrund wachsender Anforderungen an datenbasierte Planungsgrundlagen gewinnen technologische Ansätze wie Fernerkundung und maschinelles Lernen zunehmend an Relevanz. In vielen Regionen liegen nur heterogene, unvollständige, veraltete oder gar keine verlässlichen Daten zu urbanen Strukturen und räumlichen Bevölkerungsverteilungen vor, was

alternative, unabhängige Erfassungsmethoden umso bedeutender macht. Die Analyse städtischer Räume auf Basis von Fernerkundungsdaten ermöglicht eine flächendeckende, aktuelle und von administrativen Quellen unabhängige Erfassung urbaner Strukturen – Strukturen, die in enger Wechselwirkung mit dem Verkehrssystem stehen (Boarnet und Crane, 2001). Entsprechend wurde das Potenzial der Fernerkundung in der Verkehrsforschung erkannt und in einer Vielzahl von Studien aufgegriffen (Zhang und Guindon, 2006; Guindon und Zhang, 2007; El-Gafy et al., 2011; Sakai et al., 2019; Jia et al., 2021; Macioszek und Kurek, 2021). Maschinelles Lernen ermöglicht die automatisierte Erkennung komplexer Muster in den unterschiedlichsten Bilddaten. Insbesondere Deep-Learning-Ansätze, wie etwa Convolutional Neural Networks (CNNs), haben sich dabei als besonders leistungsfähig erwiesen. Studien zeigen, dass diese Verfahren im Vergleich zu klassischen Bildverarbeitungstechniken eine höhere Genauigkeit, Robustheit und Generalisierbarkeit bei der Objekterkennung und -klassifikation aufweisen (vgl. z. B. LeCun et al., 2015; Zhu et al., 2017). Damit bietet die Kombination beider Teilbereiche vielversprechende Ansätze, um die Erfassung, Analyse und Modellierung städtischer Umwelten und des urbanen Verkehrssystems zu ergänzen und zu optimieren.

1.2 Forschungslücke

Der zunehmende Bedarf an nachhaltiger und sozial gerechter Verkehrsplanung in urbanen Räumen steht in einem deutlichen Spannungsverhältnis zur Verfügbarkeit belastbarer Datengrundlagen. Für viele städtische Gebiete bestehen eklatante Datenlücken, insbesondere im Globalen Süden, aber auch in peripheren oder dynamisch wachsenden Regionen des Globalen Nordens. Diese Lücken betreffen zentrale Verkehrs- und Infrastrukturdaten wie Verkehrszählungen, Fahrgastzahlen, Wegeketten und Verkehrsmittelwahl (Mai-Tan et al., 2020), aber auch strukturelle Kontextinformationen, wie die urbane räumliche Struktur, Landnutzungsinformationen oder Bevölkerungsdaten, die für die Modellierung und Bewertung von Mobilitätsmustern essenziell sind (Wang und Taylor, 2016; Levashev, 2017; Ihlanfeldt, 2020; Xu et al., 2024a).

Ein zentrales Problem ist die Fragmentierung und Heterogenität bestehender Datenquellen, die häufig aus verschiedenen, nicht harmonisierten Erhebungsmethoden resultieren, von punktuellen Verkehrserhebungen über Mobilfunkdaten bis hin zu Daten von OpenStreetMap (OSM) (Chan et al., 2023; Griffin et al., 2020). Diese Vielfalt erschwert eine vergleichbare, flächendeckende und zeitlich konsistente Analyse städtischer Mobilität. Insbesondere in Regionen des Globalen Südens fehlen aktuelle und hochaufgelöste Daten zu Gebäude- und Landnutzungsstrukturen, Bevölkerungsverteilungen und der Nutzung von Verkehrsinfrastruktur (Walker et al., 2010; Ahlström et al., 2011; Cervero, 2013; Morales et al., 2017).

In digital erhobenen Datensätzen, etwa aus mobilen Endgeräten oder sozialen Medien, sind bestimmte Bevölkerungsgruppen, wie Personen ohne Smartphones, ältere und jüngere Menschen sowie verschiedene Geschlechter, häufig unterrepräsentiert oder werden gar nicht erfasst (Peterschmitt et al., 2021; Isenberg et al., 2022). Die daraus resultierenden strukturellen Verzerrungen

in den Datensätzen wirken sich unmittelbar auf die Qualität und Aussagekraft nachfolgender Verkehrsanalysen aus. Zudem mangelt es an öffentlich zugänglichen, stadtweiten Datensätzen, die verschiedene Verkehrsdimensionen abbilden, wie beispielsweise Verkehrsgeschwindigkeit, -dichte und -fluss. Bestehende Datensätze beschränken sich häufig auf spezifische kleinräumige oder innerstädtische Bereiche und lassen sich nur bedingt auf andere Kontexte übertragen (Xu et al., 2024a; Dablanc und Adoue, 2025). Dies erschwert insbesondere vergleichende Studien auf interurbaner oder globaler Ebene und behindert die Entwicklung generischer Modellierungsansätze. Auch der Zugang zu dynamischen, zeitnah aktualisierten Daten ist oftmals limitiert. Diese Art von verkehrlich relevanten Daten werden beispielsweise durch festverbaute Sensoren erfasst, deren Installation und Betrieb hohe Kosten verursacht (Atluri et al., 2009), in ihrer Detailtiefe beschränkt sind und beispielsweise nicht in der Lage sind, die gesamte Bandbreite von Fahrzeugtypen unterscheiden zu können bzw. häufig nicht in der Lage sind aktive Modi, wie zu Fuß gehen oder Fahrradfahren, zu erfassen (Köpper und Wieland, 2024). Zudem reichen statische Datensätze oder unregelmäßige Erhebungsintervalle nicht aus, um Veränderungen in der Mobilität adäquat zu erfassen und zu analysieren (Liang et al., 2024). Gleichzeitig fehlt es an skalierbaren, ressourcenschonenden Alternativen zu klassischen Verkehrserhebungen, deren Durchführung insbesondere in Ländern des Globalen Südens durch hohe Kosten und geringe institutionelle Kapazitäten behindert wird (Walker et al., 2010; Cervero, 2013).

Diese bestehenden Datenlücken zeigen den Bedarf an innovativen, leicht zugänglichen, flächendeckenden Datengrundlagen und übertragbaren Methoden auf, die eine hochaufgelöste Analyse urbaner Mobilität ermöglichen. Potenziale bieten hier Fernerkundungsdaten sowie offene Geodaten, wie OSM, Google Street View oder öffentlich zugängliche Webcams, in Kombination mit KI-basierten Auswertungsmethoden (Zhu et al., 2017; Cheng et al., 2020; Zhang et al., 2017b; Aravena Pelizari et al., 2021). Fernerkundung und Geodaten finden bereits Anwendung in der Verkehrsforschung (siehe Abschnitt 2.2). Dennoch fehlt es an systematischen Vergleichen, methodisch konsistenten Vorgehensweisen und übertragbaren Ansätzen, um das volle Potenzial dieser Datenquellen für die Verkehrsforschung nutzbar zu machen. Eine umfassende Untersuchung dieser Potenziale steht weitgehend aus, sowohl hinsichtlich ihrer methodischen Integration als auch ihrer Aussagekraft für die Verkehrs- und Stadtplanung. Dabei sollen diese neuen Datenquellen herkömmliche Verkehrs- und Bevölkerungsdatensätze nicht ersetzen, sondern sie vielmehr ergänzen und insbesondere in jenen Kontexten Lücken schließen, in denen konventionelle Datengrundlagen unvollständig, veraltet oder nicht vorhanden sind.

Daraus ergeben sich folgende Forschungslücken:

- Die nach wie vor eingeschränkte Verfügbarkeit und Qualität räumlich hochaufgelöster Stadtstrukturdaten, insbesondere in dynamisch wachsenden Städten mit geringerer Datenverfügbarkeit.
- Das Fehlen skalierbarer, kosteneffizienter und methodisch nachvollziehbarer Verfahren zur datenbasierten Erfassung urbaner Strukturen und Mobilitätsmuster.

- Ein Mangel an systematischen Evaluierungen der Potenziale neuer, offener Datenquellen, wie offene Webcam-Bilddaten, im Kontext der Verkehrsforschung.
- Die begrenzte Entwicklung multimodaler methodischer Ansätze, die verschiedene Datendimensionen integrieren und auf unterschiedliche urbane Kontexte übertragbar sind.

Die vorliegende Dissertation adressiert diese Forschungslücken, indem sie an der Schnittstelle zwischen Fernerkundung, Geoinformatik und Verkehrsgeographie methodische Ansätze zur Überbrückung bestehender Datenlücken entwickelt und exemplarisch in den urbanen Gebieten Santiago, Medellín und Berlin erprobt. Ziel ist es, die datenbasierte Verkehrs- und Stadtforschung zu erweitern und neue Wege für eine gerechtere, evidenzbasierte Mobilitätsplanung aufzuzeigen, sowohl im Globalen Süden als auch im Globalen Norden.

1.3 Ziele der Arbeit und Forschungsfragen

Das übergeordnete Ziel dieser Dissertation besteht darin, die oben beschriebenen Potenziale von Fernerkundungs- und frei verfügbaren Geodaten für die Analyse verkehrsrelevanter Fragestellungen im urbanen Raum zu erschließen. Insbesondere soll untersucht werden, inwieweit diese Datenquellen und darauf aufbauende geoinformatische Methoden zur Überbrückung bestehender Datenlücken in Städten beitragen können, vor allem dort, wo konventionelle Verkehrs- oder Bevölkerungsdaten unvollständig, veraltet oder gar nicht vorhanden sind oder durch diese Datenquellen sinnvoll ergänzt und präzisiert werden können. Diese Doktorarbeit positioniert sich damit an der Schnittstelle zwischen Fernerkundung, Geoinformatik, Verkehrsgeographie und Stadtforschung.

Ziel ist es, zentrale urbane Struktur- und Mobilitätsmerkmale durch die systematische Integration und Analyse von satelliten- und bodengestützten Geodaten (z. B. höchstaufgelöster Satelliten- und Luftbilder, OSM, Google Street View, Webcams) räumlich hochaufgelöst zu erfassen und methodische Ansätze für deren Auswertung zu entwickeln. Damit werden sowohl räumlich differenzierte Informationen zur städtischen Raumstruktur, zur Erreichbarkeit öffentlicher Verkehrsmittel als auch zur bildbasierten Verkehrsanalyse bereitgestellt. Der Zusammenschluss dieser Themenfelder eröffnet neue Perspektiven für die datenbasierte Verkehrsplanung und Mobilitätsforschung, sowohl im Globalen Süden als auch im Globalen Norden.

Im Zentrum der Dissertation stehen drei komplementäre Forschungsfragen:

1) Wie können fernerkundungsbasierte und offene Geodaten genutzt werden, um zentrale Merkmale der städtischen Raumstruktur – Gebäude, Landnutzung und Bevölkerung – mit hoher räumlicher Auflösung zu erfassen und als Proxydaten für verkehrsbezogene Analysen in datenarmen Regionen dienen?

Im Mittelpunkt steht die Entwicklung eines multimodalen Modells zur Analyse städtischer Raumstrukturen. Hierfür werden ein Gebäudeerkennungungsverfahren in Kombination mit offenen Geodaten zur Ableitung von 3D-Gebäudemodellen, Landnutzungsinformationen und Bevölkerungsverteilungen kombiniert. Der Fokus liegt dabei auf der räumlich differenzierten Erfassung

zentraler Strukturparameter wie Gebäudegröße, -höhe, Nutzungsart und Bevölkerung. Dabei wird am Beispiel von Santiago de Chile untersucht, wie durch die Verschneidung dieser Informationen datenbasierte Entscheidungsgrundlagen für die Verkehrs- und Stadtplanung geschaffen werden können, unabhängig von offiziellen Verwaltungsdaten. Ein besonderes Augenmerk liegt dabei auf der Validierung der Methodik hinsichtlich ihrer Übertragbarkeit auf andere Stadtbeiriche und auch auf andere geographische Regionen wie Medellín, sowie die Genauigkeit bei der flächendeckenden Erfassung urbaner Raumstrukturen. Das übergeordnete Ziel besteht darin, ein übertragbares methodisches Fundament für die Generierung raumbezogener Basisdaten zu schaffen, das evidenzbasierte Verkehrs- und Stadtplanung auch in datenarmen Kontexten ermöglicht.

2) Wie unterscheiden sich Erreichbarkeiten zu öffentlichen Verkehrsmitteln zwischen verschiedenen Siedlungsformen und sozioökonomischen Gruppen und inwiefern kann Fernerkundung helfen, datenbedingte Ungleichheiten in der Analyse zu überwinden?

Vor dem Hintergrund wachsender Städte und zunehmender sozialräumlicher Ungleichheiten stellt sich die Frage, wie der Zugang zu öffentlichen Verkehrsmitteln unter Berücksichtigung verschiedener Datenquellen umfassend analysiert werden kann. Im Fokus steht dabei die Erreichbarkeit nach dem SDG 11.2 als zentrales Maß für Mobilitätsgerechtigkeit im urbanen Raum. Am Beispiel der kolumbianischen Stadt Medellín soll untersucht werden, wie sich die räumliche Verteilung von Erreichbarkeiten zwischen formellen und semiformellen Verkehrssystemen unterscheidet und welche Rolle dabei unterschiedliche Bevölkerungsdatensätze, sozioökonomische Faktoren oder Siedlungsstrukturen spielen. Durch den Vergleich verschiedener Bevölkerungsdatensätze von Katasterdaten, über fernerkundungsbasierter bis hin zu global verfügbaren Datenquellen wird geprüft, inwieweit kleinräumige Unterschiede in der Erreichbarkeit von öffentlichem Verkehr sichtbar gemacht werden können. Die Analyse unterstreicht somit die Bedeutung datenbasierter Methoden zur Identifikation von Ungleichheiten in der Erreichbarkeit öffentlicher Verkehrsmittel und liefert wichtige Hinweise für eine gerechtere Verkehrsplanung in Städten des Globalen Südens.

3) Wie geeignet sind offen zugängliche Webcam-Daten in Kombination mit Deep-Learning-Methoden zur automatisierten Erfassung urbaner Mobilität und zur Analyse langfristiger Veränderungen im Mobilitätsverhalten?

Im Zuge der zunehmenden Verfügbarkeit offener Bilddaten stellt sich die Frage, inwiefern öffentlich zugängliche Webcam-Bilder als datenbasierte Grundlage für die kontinuierliche und kosteneffiziente Verkehrsüberwachung genutzt werden können. Insbesondere für die Analyse dynamischer Veränderungen in Mobilitätsmustern stellen Webcam-Daten eine wertvolle Datenquelle dar. Vor diesem Hintergrund wird das Potenzial kombinierter Methoden aus dem Bereich der Computer Vision und offenen Webcams zur Analyse urbaner Mobilität exemplarisch untersucht. Dafür soll ein KI-Objekterkennungsverfahren, basierend auf *You Only Look Once*, kurz: YOLO, zur Detektion und Quantifizierung verschiedener Verkehrsteilnehmender auf umfangreichen Webcam-Bilddaten und in einem Anwendungsfall zur Analyse von Mobilitätsveränderungen durch die

COVID-19 Pandemie eingesetzt werden. Im Fokus steht die Entwicklung eines praktikablen und skalierbaren Ansatzes zur Verkehrsbeobachtung auf Basis öffentlich verfügbarer Webcam-Daten und moderner Deep-Learning-Modelle.

1.4 Aufbau der Arbeit

Diese Dissertation ist in acht Kapitel gegliedert. Sie vereint Konzepte, Methoden und empirische Analysen aus den Bereichen Fernerkundung, maschinelles Lernen und Verkehrsforschung, um urbane Mobilität in verschiedenen Kontexten datengestützt zu untersuchen.

Kapitel 2 – Grundlagen: Dieses Kapitel stellt die theoretischen und methodischen Grundlagen bereit. Es beginnt mit einer Einführung in das urbane Verkehrssystem und diskutiert die Rolle von Fernerkundung und Geodaten in der Verkehrsforschung.

Kapitel 3 – Konzeptioneller Rahmen: Hier werden die zentralen konzeptionellen Bausteine der Arbeit erläutert. Zunächst wird auf die Bedeutung der städtischen Raumstruktur für die Mobilität eingegangen, mit Fokus auf Gebäude, Landnutzung und Bevölkerungsverteilung. Anschließend folgt eine konzeptionelle Auseinandersetzung mit dem Thema Erreichbarkeit öffentlicher Verkehrsmittel, unter besonderer Berücksichtigung informeller und semiformeller Transportsysteme. Abschließend wird das Potenzial von Webcam-Daten für die automatisierte Erfassung urbaner Mobilität beleuchtet.

Kapitel 4 – Untersuchungsgebiete und Daten: In diesem Kapitel werden die untersuchten Städte (Santiago de Chile, Medellín und Berlin) sowie die verwendeten Datenquellen vorgestellt. Es erfolgt eine detaillierte Beschreibung der Datengrundlagen, von Luftbildern und Gebäudedaten über Bevölkerungs- und Haltestelleninformationen bis hin zu offenen Webcam-Bilddaten inklusive der durchgeführten Vorprozessierungen.

Kapitel 5 – Methoden: Kapitel 5 beschreibt den methodischen Aufbau. Dazu zählt die Erstellung eines funktionalen 3D-Stadtmodells inkl. flächendeckender Gebäudeerkennung mit Mask R-CNN, eine vergleichende Routinganalyse zur Messung der Erreichbarkeit sowie die Objekterkennung in Webcam-Bilddaten mit YOLOv8.

Kapitel 6 – Ergebnisse: Die Ergebnisse der empirischen Untersuchungen werden in diesem Kapitel präsentiert. Dazu gehören die Evaluierung des funktionalen Stadtmodells, die Analyse der Erreichbarkeit öffentlicher Verkehrsmittel sowie die quantitativen Ergebnisse der Webcam-Auswertung hinsichtlich Mobilitätsveränderungen vor und während der COVID-19-Pandemie.

Kapitel 7 – Diskussion: In der Diskussion werden die methodischen Ansätze und Ergebnisse kritisch reflektiert. Im Mittelpunkt stehen sowohl die Übertragbarkeit und Limitationen der entwickelten Verfahren, als auch die Aussagekraft der gewonnenen Erkenntnisse.

Kapitel 8 – Fazit und Ausblick: Das abschließende Kapitel fasst die zentralen Erkenntnisse in Hinblick auf die eingeführten Forschungsfragen zusammen und gibt einen Ausblick auf zukünftige Forschungsperspektiven.

Diese Dissertation stützt sich maßgeblich auf drei Fachartikel, die einem Peer-Review-Verfahren unterzogen wurden, sowie einen begutachteten Konferenzbeitrag. Zwei Fachartikel davon sind in wissenschaftlichen Zeitschriften veröffentlicht, einer befindet sich im Begutachtungsverfahren. Die zentralen Inhalte dieser Arbeiten sind in die Dissertation integriert.

Begutachteter Konferenzbeitrag:

- **Stiller D**, Stark T, Wurm M, Dech S, Taubenböck H (2019). "Large-scale building extraction in very high-resolution aerial imagery using Mask R-CNN". *2019 Joint Urban Remote Sensing Event (JURSE)*, Vannes, Frankreich, 2019, pp. 1-4. doi: [10.1109/JURSE.2019.8808977](https://doi.org/10.1109/JURSE.2019.8808977).

Veröffentlichte begutachtete Zeitschriftenartikel:

- **Stiller D**, Wurm M, Stark T, d'Angelo P, Stebner K, Dech S, Taubenböck H. (2021). "Spatial parameters for transportation: A multi-modal approach for modelling the urban spatial structure using deep learning and remote sensing". *Journal of Transport and Land Use*, 14(1), 777–803. doi: [10.5198/jtlu.2021.1855](https://doi.org/10.5198/jtlu.2021.1855).
- **Stiller D**, Wurm M, Sapena M, Nieland S, Dech S, Taubenböck H (2025). "Does formal public transport serve the city well? The importance of semiformal transport for accessibility in Medellín, Colombia". *PLoS ONE*, 20(4): e0321691. doi: [10.1371/journal.pone.0321691](https://doi.org/10.1371/journal.pone.0321691).

Eingereichter Zeitschriftenartikel:

- **Stiller D**, Wurm M, Staab J, Stark T, Starz G, Rauh J, Dech S, Taubenböck H (in Review). "Open Webcam Data for Traffic Monitoring: YOLOv8 Detection of Road Users Before and During COVID-19". Manuskript zur Begutachtung eingereicht bei *Transportation Research Interdisciplinary Perspectives*.

Grundlagen

Dieses Kapitel dient der thematischen Verortung der Arbeit im Kontext der urbanen Mobilitätsforschung und der geowissenschaftlich-technischen Datenanalyse. Es bietet einen Überblick über zentrale Merkmale urbaner Verkehrssysteme sowie deren spezifische Ausprägungen im Globalen Süden und Norden (Abschnitt 2.1). Darauf aufbauend wird der aktuelle Forschungsstand zur Nutzung von Fernerkundungs- und Geodaten in verkehrswissenschaftlichen Anwendungsfeldern zusammengefasst (Abschnitt 2.2). Ziel ist es, relevante wissenschaftliche Perspektiven und methodische Ansätze aufzuzeigen, die für die nachfolgenden empirischen Analysen von Bedeutung sind.

2.1 Das urbane Verkehrssystem

Das urbane Verkehrssystem ist ein zentrales Element moderner Städte und prägt sowohl die soziale Teilhabe als auch die wirtschaftliche Leistungsfähigkeit urbaner Räume (Nuhn und Hesse, 2006; Sweet, 2013; Stanley und Stanley, 2017). Bereits 1977 identifizierte Thomson in *Great Cities and Their Traffic* sieben zentrale Faktoren, die das urbane Verkehrsproblem charakterisieren. Diese umfassen (1) die Verkehrsbewegung, einschließlich Staus, Verkehrsmanagement und Verkehrsverhalten, (2) Unfälle, (3) Überlastung des öffentlichen Verkehrs zu Stoßzeiten (*peak-hour crowding*), (4) unzureichende Nutzung öffentlicher Verkehrsmittel außerhalb der Hauptverkehrszeiten (*off-peak inadequacy*), wobei beide Aspekte eng mit der Finanzierung des öffentlichen Verkehrs verknüpft sind, (5) Herausforderungen für Fußgänger hinsichtlich Erreichbarkeit und Infrastruktur, (6) die negativen Umweltauswirkungen des Verkehrs sowie (7) Parkraumprobleme (Thomson, 1977). Thomsons Systematisierung bietet bis heute eine gültige Perspektive auf urbane Verkehrssysteme und die damit verbundenen Herausforderungen (Rodrigue et al., 2016).

Charakteristika des urbanen Verkehrssystems

Der städtische Verkehr ist eng mit der urbanen Raumstruktur, der Landnutzung und der Bevölkerungsverteilung verflochten. Die Verkehrsinfrastruktur, wie Straßen und öffentlicher Nahverkehr, ist ein Schlüsselfaktor für die Ausprägung der urbanen Form und hat direkten Einfluss auf die Dichte, die Struktur und die räumliche Organisation von Städten (Glaeser, 2020; Maparu und Mazumder, 2021). Damit wird ebenfalls die Erreichbarkeit und die Verteilung von Wohn-,

Arbeits- und Freizeiteinrichtungen beeinflusst. Umgekehrt ist die Beziehung wechselseitig, denn die Stadtform wirkt sich auch auf den Verkehrsbedarf und den Ausbau der Infrastruktur aus und beeinflusst damit auch die Verkehrsmittelwahl (Boarnet und Crane, 2001).

Verkehr in urbanen Gebieten ist durch hohe Bevölkerungsdichten, komplexe Modal-Splits und eine verstärkte Staudynamik geprägt. Stau ist dabei ein vielschichtiges Phänomen, das durch das Zusammenspiel sozioökonomischer, verhaltensbezogener und städtebaulicher Faktoren beeinflusst wird, insbesondere hohe Einkommensniveaus und Beschäftigungsagglomerationen wirken dabei stauverstärkend (Rahman et al., 2021). Besonders die Verbreitung des Automobils hat zur Ausbreitung suburbaner Strukturen beigetragen und autozentrierte Stadtmuster wie das rasterförmige Straßennetz begünstigt (Rodrigue et al., 2016). Gleichzeitig beeinflusst die Landnutzung das Mobilitätsverhalten und die Entstehung und Intensität von Verkehrsströmen (Van Acker und Witlox, 2010). Urbanes Mobilitätsverhalten wird zudem stark von sozioökonomischen Faktoren geprägt, insbesondere in Städten mit ungleicher Infrastrukturverteilung und sozialer Segregation (Barbosa et al., 2021). Eine gut ausgebaute öffentliche Verkehrsinfrastruktur und der gleichmäßige Zugang zu zentralen Dienstleistungen der Stadt können den Einfluss sozioökonomischer Unterschiede, insbesondere des Einkommens, auf das Mobilitätsverhalten deutlich abschwächen (Barbosa et al., 2021).

Mobilität bewegt sich generell in einer Konkurrenz zwischen Individualverkehr und öffentlichem Verkehr. Die Wahl des Verkehrsmittels wird von Faktoren wie den individuellen Einstellungen und dem Lebensstil, der Art der Reise, der wahrgenommenen Qualität der einzelnen Verkehrsmittel und situativen Variablen beeinflusst (Beirão und Sarsfield Cabral, 2007). Dabei bietet der Individualverkehr zwar Flexibilität, geht jedoch mit erheblichen Problemen wie Verkehrsüberlastung, Flächenverbrauch und Umweltbelastungen einher. Ein gut gebauter öffentlicher Verkehr ist daher eine zentrale Voraussetzung für klimafreundliche Mobilität und eine nachhaltige Alternative zum motorisierten Individualverkehr (Ceder, 2020; Glazener und Khreis, 2019; Chatziioannou et al., 2023; United Nations, 2015).

Während sich allgemeine Merkmale des Stadtverkehrs über verschiedene Weltregionen hinweg beobachten lassen, zeigen sich deutliche Unterschiede zwischen Städten des Globalen Nordens und des Globalen Südens (Tabelle 2.1). Der Globale Süden sieht sich mit schnellen Urbanisierungsprozessen, informellen Transportlösungen und einer rapiden Motorisierung konfrontiert. Diese rasante Motorisierung geht oft nicht mit adäquatem Infrastrukturausbau einher (Koizumi et al., 2013; Tiwari und Phillip, 2021). Zudem dominiert der öffentliche Verkehr, ergänzt durch informelle Angebote wie Minibusse oder Motorradtaxi (Zegras und Gakenheimer, 2006; Nelson, 2021). Im Vergleich dazu sind Städte des Globalen Nordens durch eine höhere Automobildichte, eine stärkere Regulierung und ausgebaute Verkehrsinfrastrukturen charakterisiert, was auf unterschiedliche sozioökonomische Voraussetzungen und stadtplanerische Entwicklungen zurückzuführen ist. Zudem werden verstärkt Strategien der Verkehrsvermeidung, Verkehrsverlagerung und Verkehrsverbesserung verfolgt, um die negativen Auswirkungen des Verkehrs zu reduzieren.

Tabelle 2.1: Übersicht und Sammlung der zentralen Unterschiede der urbanen Verkehrssysteme zwischen Globalem Süden und Globalem Norden.

	Globaler Süden	Globaler Norden
<i>Bevölkerungsdichte und -verteilung</i>	Hohe Dichte im Zentrum, niedrigere Dichte in Randgebieten, starke Urbanisierungsdynamik	Variabel, oft suburbanisiert, geringere Urbanisierungsdynamik
<i>Modal Split</i>	Dominanz von öffentlichem Verkehr und informellen bzw. semiformellen Systemen, steigende Motorisierung	Hoher Anteil an Privatfahrzeugen, zunehmend multimodale Systeme
<i>Verkehrsinfrastruktur</i>	Konzentration auf zentrale Zonen, Defizite in der Peripherie	Flächendeckende Verkehrsnetze, höhere Investitionen in nachhaltigen Umbau
<i>Motorisierung</i>	Rasch wachsend, teils unreguliert	Teilweise rückläufig durch politische Eingriffe, Förderung der E-Mobilität oder Car-Sharing
<i>Ansätze der Politik</i>	Oft reaktiv, Fokus auf Großprojekte (z. B. <i>Bus Rapid Transit</i> , BRT)	Proaktiv, umfassende Planung und Regulierung

Hinweis: Die in der Tabelle aufgeführten Punkte werden im weiteren Verlauf von Abschnitt 2.1 erläutert.

Urbane Verkehrssysteme im Globalen Süden

Zentral für viele Städte im Globalen Süden ist das Nebeneinander von dicht besiedeltem Stadtkern mit besserer Verfügbarkeit von öffentlichem Verkehr und peripheren Zonen, in denen Transportmöglichkeiten begrenzt sind, was sich auch in der Erreichbarkeit von zentralen funktionalen Orten der Stadt widerspiegelt. Arellana et al., 2021 zeigen dies anhand eines Vergleichs zwischen Bogotá und Barranquilla in Kolumbien. In Bogotá sorgt das auf öffentlichen Verkehr ausgerichtete System, insbesondere das gut entwickelte Schnellbussystem (engl. *Bus Rapid Transit*, BRT), für eine verbesserte Erreichbarkeit. Demgegenüber ist Barranquilla stärker vom Autoverkehr geprägt und weist ausgeprägtere soziale Ungleichheiten beim Zugang zum öffentlichen Verkehrsangebot auf. Ökonomischer Wohlstand fördert zudem den Anstieg des Privatfahrzeug- und Motorradbesitzes, was neue Herausforderungen im Hinblick auf Verkehrsstaus, Luftverschmutzung und Verkehrssicherheit schafft und die Verkehrsinfrastruktur wird im Hinblick auf den Bedarf nicht adäquat entwickelt (Koizumi et al., 2013).

Sozio-ökonomisch schlechter gestellte Bevölkerungsgruppen, die auch in peripheren Stadtgebieten leben, sind besonders benachteiligt, da ihnen erschwingliche und zuverlässige Verkehrsmittel fehlen (Zegras und Gakenheimer, 2006). Soziale Ungleichheit wird daher auch im Rahmen des urbanen Verkehrssystems und seiner Erreichbarkeit diskutiert (Guzman et al., 2017; Lutz et al.,

2024). Informelle und semiformelle Verkehrssysteme entstehen häufig aus dieser Notwendigkeit heraus, füllen wichtige Versorgungslücken, sind jedoch oft schlecht reguliert und bergen Sicherheitsrisiken (Cervero und Golub, 2007; Nelson, 2021; Okami et al., 2022).

Urbane Verkehrssysteme im Globalen Norden

Im Gegensatz dazu setzt eine Vielzahl der Städte des Globalen Nordens gezielt politische Maßnahmen ein, um den Anstieg des motorisierten Individualverkehrs zu steuern. Beispiele wie Seoul und Singapur zeigen, dass frühzeitige Eingriffe, etwa durch restriktive Zulassungsregelungen und Investitionen in den öffentlichen Verkehr, private Fahrzeugnutzung wirksam eindämmen können (Barter, 1999). Städte im Globalen Norden verfügen im Vergleich tendenziell über stabilere und systematisch entwickelte Verkehrsinfrastrukturen. Der öffentliche Nahverkehr ist häufig gut ausgebaut und wird durch integrierte Rad- und Fußwegenetze ergänzt, wodurch ein gewisser Grad an institutionalisierter Multimodalität erreicht wird (Sclar und Toubert, 2011). Trotz dieser Strukturen bleibt die Motorisierungsrate hoch, und der Individualverkehr dominiert weiterhin den urbanen Mobilitätsalltag. In vielen Städten führt dies nach wie vor zur Überschreitung gesetzlicher Emissionsgrenzwerte. Als Reaktion darauf kommen vermehrt politische Steuerungsmaßnahmen zum Einsatz, darunter City-Mautsysteme, temporäre oder sektorale Fahrverbote, Umweltzonen, Parkraumbewirtschaftung sowie Investitionen in leistungsfähige Massentransportsysteme (Barter, 1999; Haitao et al., 2019; Wang et al., 2022).

Vor allem Großstädte verfolgen verstärkt nachhaltige Mobilitätsstrategien, etwa durch die Förderung von Elektromobilität und den Einsatz intelligenter Verkehrssysteme, um die Umweltwirkungen des Verkehrssektors zu reduzieren (Glazener und Khreis, 2019; Gao und Zhu, 2022). Die zukünftige Ausgestaltung urbaner Verkehrssysteme, sowohl im Globalen Süden als auch im Globalen Norden, wird maßgeblich davon abhängen, inwieweit integrierte Mobilitätslösungen entwickelt werden können, welche ökologische Nachhaltigkeit mit sozialer Gerechtigkeit und struktureller Resilienz verbinden (Glazener und Khreis, 2019).

2.2 Fernerkundung und Geodaten in der Verkehrsforschung

Die zunehmende Verfügbarkeit von Fernerkundungs- und Geodaten hat neue Möglichkeiten in der Verkehrsforschung erschlossen. Durch Satellitenbilder, Luftbilder, OSM und andere Geodaten lassen sich sowohl Elemente der Verkehrsinfrastruktur und der urbanen Raumstruktur, als auch Verkehrsflüsse ableiten. Damit können Fernerkundung und Geodaten einen wertvollen Beitrag zur Verbesserung von Verkehrsmodellen und der Verkehrsplanung insbesondere dort leisten, wo herkömmliche Erhebungsmethoden wie Befragungen oder Verkehrszählungen aus finanziellen, sicherheitsbezogenen oder logistischen Gründen nicht einsetzbar sind (Cervero, 2013; Wang et al., 2017).

Einsatz von Fernerkundungsdaten in der Verkehrsforschung

Fernerkundungsdaten und -methoden bieten vielfältige Anwendungsmöglichkeiten für die Verkehrsforschung. Dabei haben sie häufig Vorteile gegenüber herkömmlichen Verkehrserhebungen, wie beispielsweise Verkehrsbefragungen oder Verkehrszählraten, da sie eine großflächige und andauernde Überwachung des Verkehrsflusses ermöglichen (Sakai et al., 2019). Großes Potential und ein praktischer Nutzen ergibt sich insbesondere für Gebiete ohne Zählinfrastruktur, wie etwa im ländlichen Raum oder in Ländern des Globalen Südens (Stiller et al., 2021). Erdbeobachtungsdaten werden zunehmend für die großflächige Erfassung und Bewertung von Straßeninfrastruktur eingesetzt (Jia et al., 2021). Dabei kommen verschiedene Sensordaten zum Einsatz, je nach zu erfassendem Parameter. Zur Ableitung zentraler Straßenmerkmale wie Mittellinien, Breite und Neigung werden Orthophotos in Kombination mit LiDAR-Daten verwendet (Ural et al., 2015). Sehr hoch aufgelöste Satellitenbilder, etwa von WorldView-2 oder Gaofen-2, dienen ebenfalls der Zustandsanalyse von Straßen- und Gehwegoberflächen (Shahi et al., 2016; Wang et al., 2024a). Darüber hinaus konnte gezeigt werden, dass Synthetic Aperture Radar (SAR) sowie Interferometric SAR (InSAR) eine flächendeckende und kosteneffiziente Erfassung struktureller Schäden an Fahrbahnen und Brücken ermöglichen (Vaccari et al., 2018; D'Aranno et al., 2019; Gajurel et al., 2024). Insbesondere in urbanen Gebieten stellen jedoch die komplexen und häufig unregelmäßigen Straßenverläufe, etwa durch Zufahrten und Einfahrten wie Parkplätze, eine besondere Herausforderung für automatisierte Verfahren dar (Ural et al., 2015).

In der urbanen Verkehrsforschung spielt die städtische Raumstruktur eine zentrale Rolle, da sie wichtige Basisparameter wie Bebauung, Landnutzung und Bevölkerungsverteilung beschreibt, die maßgeblich das Mobilitätsverhalten beeinflussen (Krehl et al., 2016; Zhang et al., 2019). Insbesondere in datenarmen Regionen bieten Fernerkundungsverfahren eine vielversprechende Alternative zur Erhebung dieser Parameter, da sie großflächig, objektiv und kosteneffizient aktuelle Informationen liefern können (Machado und Quintanilha, 2019). So ermöglicht etwa die Extraktion von 3D-Gebäudemodellen aus Orthophotos und Höhenmodellen nicht nur die Ableitung baulicher Dichte, sondern dient auch als Grundlage für die Analyse von Landnutzung und Bevölkerung (Wurm et al., 2011; Hecht et al., 2013; Stiller et al., 2021). Die Verteilung verschiedener Landnutzungen wiederum beeinflusst maßgeblich die Verkehrsmittelwahl und den Mobilitätsbedarf und lässt sich zunehmend durch die Kombination von Fernerkundungsdaten mit freiwillig erhobenen geographischen Informationen (engl. *Volunteered Geographic Information*, VGI) wie OSM ermitteln (Fonte et al., 2017). Auch die innerstädtische Bevölkerungsverteilung, ein Schlüsselfaktor für die Schätzung von Verkehrsaufkommen, kann mithilfe satellitengestützter Verfahren modelliert werden (Wurm et al., 2009; Stevens et al., 2015; Biljecki et al., 2016).

Fernerkundung wurde ebenfalls für die direkte Extraktion von Verkehrsobjekten und die Ableitung verkehrsrelevanter Parameter, wie Verkehrsdichte und Geschwindigkeit, verwendet. Die Detektion von Staus sowie die Erfassung verkehrsrelevanter Parameter wie Fahrzeugdichte und mittlerer Geschwindigkeit konnte mithilfe von Befliegungsdaten erfolgreich demonstriert werden. Dabei kam ein Verfahren zur Veränderungserkennung zwischen Bildpaaren zum Einsatz

(Palubinskas et al., 2008). In einer weiterführenden Studie wurde gezeigt, dass Zeitserien von Luftbildern eine robuste Grundlage für die Schätzung von Stauparametern darstellen, insbesondere bei wiederholten Befliegungen (Palubinskas et al., 2010). Ergänzend dazu wurden LiDAR-Daten in Kombination mit hochaufgelösten Luftbildern genutzt, um bewegte Objekte präzise zu extrahieren und deren Geschwindigkeit abzuschätzen (Toth und Grejner-Brzezinska, 2005). Dies ermöglicht eine dreidimensionale Erfassung von Verkehrsteilnehmenden, die sich besonders für urbane Gebieten mit komplexen Verkehrsstrukturen anbietet. Darüber hinaus wurde das Potenzial radarbasierter Fernerkundung getestet. Anhand von TerraSAR-X-Daten konnte eine automatische Extraktion von Verkehrsflüssen realisiert werden (Suchandt et al., 2010). Dabei wurde die Bewegung von Objekten direkt gemessen, was eine kontinuierliche und wetterunabhängige Beobachtung des Verkehrsgeschehens erlaubt. Das stellt insbesondere bei Nacht und Bewölkung einen wesentlichen Vorteil gegenüber optischen Sensorsystemen dar.

Ergänzend zu klassischen Fernerkundungssystemen wie Satelliten- oder Luftbildsensoren gewinnen auch bodengebundene Bildquellen wie Webcams bzw. offene Kamerabildraten zunehmend an Bedeutung für die verkehrswissenschaftliche Analyse (Faro et al., 2008; Ide et al., 2017; Hoxha et al., 2023). Aufgrund ihrer hohen zeitlichen Auflösung und ihrer Verfügbarkeit im urbanen Raum ermöglichen sie eine kontinuierliche und nahezu in Echtzeit erfolgende Beobachtung des Verkehrsgeschehens (Khazukov et al., 2020; Aung und Lwin, 2024). Daher können Webcams als neuartige, niedrigschwellige Form fernerkundlicher Datenerhebung interpretiert werden (Zhang et al., 2017b; Staab et al., 2021).

Neben klassischen bildverarbeitungsbasierten Ansätzen werden zunehmend maschinelle Lernverfahren implementiert, beispielsweise durch den Einsatz von Deep-Learning-Methoden, sowohl für die Extraktion von Verkehrsinfrastruktur (Liu et al., 2024; Abdollahi et al., 2020), als auch für die Ableitung von Verkehrsdichten. So wurden beispielsweise Verfahren zur Schätzung der Verkehrsdichte aus WorldView-3 Satellitenbildern unter Verwendung von CNNs entwickelt (Sakai et al., 2019). Obwohl keine exakte Detektion einzelner Fahrzeuge ermöglicht wurde, konnte eine Ableitung von Dichtewerten erreicht werden, die wiederum zur Berechnung von Verkehrsflussindikatoren herangezogen wurden. Auch offene Webcam-Daten werden zunehmend mithilfe von CNNs für Verkehrsanalysen genutzt. Zhang et al., 2017a zeigten etwa, dass ein Fully Convolutional Network (FCN) erfolgreich zur Fahrzeugzählung auf Webcam-Videodaten im urbanen Kontext angewendet werden kann. Weitere Studien setzten YOLO zur Detektion von Fußgängern und Fahrzeugen in öffentlich verfügbaren Kameradaten ein, teils unter variablen Licht- und Wetterbedingungen (Tung et al., 2019; Aung und Lwin, 2024). Diese Entwicklungen unterstreichen das Potenzial von Deep-Learning-Verfahren, nicht nur für klassische Fernerkundungsdaten, sondern auch für niedrigauflösende, heterogene Bildquellen wie Webcams für die Verkehrsbeobachtung nutzbar zu machen.

Einsatz von Geodaten in der Verkehrsforschung

Geodaten stellen eine zentrale Grundlage der verkehrswissenschaftlichen Forschung dar und werden zunehmend im Rahmen von Open-Data-Initiativen durch öffentliche Institutionen, Städte und zivilgesellschaftliche Organisationen bereitgestellt. Dazu zählen unter anderem Verkehrsnetzdaten, Informationen zu Straßen- und Verkehrsinfrastrukturen, Katasterdaten sowie Verkehrszählungen. Ergänzend kommen soziodemografische Merkmale wie Bevölkerungsdichte und -struktur sowie Landnutzungsinformationen zu Wohn- und Arbeitsstandorten hinzu, die insbesondere in der Modellierung der Verkehrsnachfrage eine zentrale Rolle spielen. Ein zentrales Anwendungsfeld ist die Routenplanung und -optimierung im Transportwesen. Geodaten zur Topografie, zu Straßencharakteristika oder zu Geschwindigkeitsbegrenzungen bieten ein erhebliches Potenzial zur Verbesserung ökonomischer, ökologischer und sozialer Aspekte des Fahrzeugroutings. So konnte in einer simulationsbasierten Studie gezeigt werden, dass durch den gezielten Einsatz solcher Daten Emissionen reduziert, Transportkosten gesenkt und die Belastung von Fahrpersonal verringert werden können (Klumpp, 2018).

Darüber hinaus wird in der Verkehrsforschung zunehmend auf geokodierte Daten aus mobilen Endgeräten zurückgegriffen. Studien zeigen, dass insbesondere GPS- und Mobilfunkdaten wertvolle Einblicke in Mobilitätsverhalten und räumlich-zeitliche Bewegungsmuster ermöglichen (Burkhard et al., 2017). Auch Geodaten aus sozialen Medien wie Facebook (Salanova Grau et al., 2017) oder X, ehemals Twitter (Soliman et al., 2017; Essien et al., 2020), werden zunehmend zur Analyse urbaner Mobilität herangezogen. Im Vergleich zu klassischen Erhebungsverfahren wie Umfragen oder Beobachtungen zeichnen sich diese Datenquellen durch eine kontinuierliche Verfügbarkeit und große Stichprobengröße aus (Ahas et al., 2017). Gleichzeitig bestehen methodische Herausforderungen hinsichtlich Datenqualität, Repräsentativität und Datenschutz (Smith et al., 2012; Petutschnig et al., 2021; Isenberg et al., 2022).

Geoinformationssysteme (GIS) haben sich in diesem Zusammenhang als unverzichtbare Werkzeuge etabliert. Unter dem Begriff *Geographic Information Systems for Transportation* (GIS-T) werden sie als integraler Bestandteil der Verkehrsplanung verstanden, da sie sowohl die Verwaltung, Visualisierung und algorithmische Analyse raumbezogener Daten als auch die Unterstützung von Planungs- und Entscheidungsprozessen ermöglichen (Borzacchiello et al., 2009; Miller und Shaw, 2015). Typische Anwendungsfelder sind die Pflege von Geodatenbanken, Netzwerk- und Erreichbarkeitsanalysen sowie die Modellierung zukünftiger Verkehrsszenarien (Borzacchiello et al., 2009).

In spezifischen Anwendungsfällen wurde die Bedeutung von Geodaten durch weitere Studien hervorgehoben. So wurde gezeigt, dass durch die Verwendung von GPS-Trajektorien Verkehrsmittel mit hoher Genauigkeit identifiziert werden können (Li et al., 2021). Zudem wurde dargelegt, dass Geodaten, Big Data, maschinelles Lernen und künstliche Intelligenz eine zentrale Rolle in zukünftigen „Smart City“-Verkehrsstrategien einnehmen werden und als essentiell angesehen werden, bestehende und aufkommende Herausforderungen des Verkehrssystems zu bewältigen

(Ang et al., 2022). Auch in der Analyse von Bikesharing-Systemen wird zunehmend auf Geodaten zurückgegriffen, etwa zur Ableitung von Fahrzwecken oder zur Verbesserung der Integration in den öffentlichen Verkehr (Schmidt et al., 2021).

Als eine der wichtigsten offenen Geodatenquellen hat sich OSM etabliert. Aufgrund der offenen Lizenzierung und hohen Detailtiefe wird OSM in der verkehrswissenschaftlichen Forschung vielfältig eingesetzt. So konnte eine hohe Übereinstimmung zwischen OSM-Daten und kommunalen Open-Data-Angeboten im Bereich der Fahrradinfrastruktur festgestellt werden, insbesondere bei Radfahrstreifen (Ferster et al., 2019). Im Bereich der Beurteilung der Fußgängerfreundlichkeit („Walkability“) wurde die Nützlichkeit von OSM-Daten vor allem in ländlichen Regionen hervorgehoben, da dort offizielle Daten häufig nicht verfügbar sind (Dunn et al., 2018). In modellbasierten Anwendungen wurden Points of Interest (POIs) aus OSM zur Extraktion von Attraktivitätsmaßen für Aktivitätsstandorte verwendet, wobei sich die Datenqualität mit amtlichen Quellen vergleichen ließ (Klinkhardt et al., 2021). Im Bereich des Güterverkehrs wurden OSM-Daten zur Planung von Transportrouten eingesetzt. Ihre standardisierte Datenstruktur erleichtert die Integration, wenngleich in bestimmten Bereichen aufgrund von Unvollständigkeit auf ergänzende Datenquellen zurückgegriffen werden sollte (Sierpiński, 2017). Der Aufbau multimodaler urbaner Verkehrsmo-delle inklusive privatem und öffentlichem Verkehrssystem, sowie Landnutzung, konnte mit Hilfe von OSM erfolgreich demonstriert werden, wobei sich auch hier Datenlücken und Inkonsistenzen zeigten (Gil, 2015). Die Anwendbarkeit von OSM für mikroskopische Zielwahlmodelle wurde mit manuell akquirierten Daten verglichen, wobei für Bildungsaktivitäten gute Resultate erzielt wurden, während für berufliche Aktivitäten aufgrund unvollständiger Daten die genutzten OSM-Daten als nicht geeignet bewertet wurden (Briem et al., 2019). Zur Steigerung der Datenvollständigkeit und -qualität wird empfohlen, OSM-Daten mit behördlichen Quellen zu kombinieren (Szwoch, 2019).

Damit wird das Potenzial deutlich, das in der Verfügbarkeit, Qualität und gezielten Kombination offener und offizieller Geodaten für datenbasierte Verkehrsanalyse und -planung liegt, insbesondere in Kontexten mit eingeschränkter Datenverfügbarkeit.

Konzeptioneller Rahmen

Diese Dissertation adressiert die Herausforderungen einer datengestützten Analyse urbaner Mobilität vor dem Hintergrund wachsender Urbanisierung, ökologischer Zielkonflikte und sozialräumlicher Disparitäten. Um einen Zugang zur Problemstellung zu ermöglichen, ist die Untersuchung in drei zentrale Forschungsfragen untergliedert. Der nachfolgende konzeptionelle Rahmen dient dazu, diese Forschungsfragen theoretisch einzuordnen, die zugrunde liegenden Annahmen und Begriffsverständnisse zu klären und die methodische Ausrichtung inhaltlich zu fundieren. Dabei wird innerhalb dieses Kapitels die Verbindung zwischen den empirischen Analysen und den übergeordneten wissenschaftlichen Zielsetzungen der Arbeit nachvollziehbar hergestellt.

3.1 Bedeutung städtischer Raumstruktur für urbanen Verkehr

Städte sind Hotspots des Verkehrs. Dieses Phänomen wird durch das stetige Wachstum und die Verdichtung der Stadtbevölkerung weiter verstärkt (United Nations, 2019). Einerseits fördert die räumliche Nähe innerhalb der Städte Innovation, wirtschaftlichen Wohlstand und Bildung und lockt dadurch immer mehr Menschen in die städtischen Ballungsräume (z. B. Glaeser, 2011). Andererseits hat eine räumliche Konzentration auch negative Auswirkungen, z. B. Platzmangel, Zunahme der Umweltverschmutzung, Lärmemissionen und Staus. Verkehrsbedingte Umweltverschmutzung und Lärm sind in dichten städtischen Umgebungen besonders problematisch und stellen ein Problem für die öffentliche Gesundheit der lokalen Bevölkerung dar (Choi und Zhang, 2017; Okokon et al., 2015). Darüber hinaus hat ein unzureichender städtischer Verkehr auch wirtschaftliche und ökologische Auswirkungen (Rodrigue et al., 2016).

Die städtische Raumstruktur spielt in der Stadtverkehrsforschung eine wichtige Rolle und beschreibt die morphologischen Dimensionen, aber auch die funktionalen Merkmale einer Stadt (McCormack und Shiell, 2011; Krehl et al., 2016). Dazu gehören unter anderem die Verteilung von Verkehrsnetzen, Waren- und Dienstleistungsströmen, Jobs, Bevölkerung und Landnutzung (Farber und Li, 2013; Parr, 2013). In der Literatur wurde festgestellt, dass die städtische Raumstruktur z. B. mit der Wahl des Verkehrsmittels (Tracy et al., 2011), dem aktiven Verkehr (Cheng et al., 2019), dem Grad der Aktivität und Mobilität (Chen et al., 2019), dem Pendelverhalten (Sohn, 2005), der Reisezeit, dem Energieverbrauch des Individualverkehrs (Liddle, 2013) und den zurückgelegten Fahrzeugkilometern (engl. *vehicle kilometer traveled*, VKT) (Ihlanfeldt, 2020) einschließlich der

CO₂-Emissionen (Lee und Lee, 2020) in Verbindung steht. Dementsprechend wird die aktive Planung von Merkmalen der städtischen Raumstruktur als ein wirksames Instrument für die Verkehrsplanung verstanden, die als „intelligentes Wachstum“ bezeichnet wird (Jin, 2019; Tracy et al., 2011). Darüber hinaus sind die Merkmale der städtischen Raumstruktur, einschließlich der Landnutzung sowie der Bevölkerung und ihrer Verteilung, von entscheidender Bedeutung für die Vorhersage des Reiseverhaltens und die Schätzung der Verkehrsnachfrage (Zhang et al., 2019). Diese Informationen dienen als Basisdaten für Modelle, die sich mit Verkehrsprognosen befassen, z.B. für die Zwecke der Verkehrsgenerierung (engl. *trip generation*) und der Schätzung von Quelle und Ziel der unternommenen Wege (engl. *origin and destination*, O/D) (Machado und Quintanilha, 2019). Gebäude dienen beispielsweise als minimale räumliche Einheiten, in denen Wege bzw. Fahrten ihre Quelle und Ziel haben (Sevtsuk und Mekonnen, 2012), und sind die Grundlage, um weitere Merkmale zu definieren, wie beispielsweise Informationen über Nutzung und Bevölkerung (Hecht et al., 2013). Daher ist eine ausreichende Kenntnis über die städtische Raumstruktur notwendig, um angemessene Gegenmaßnahmen zu ergreifen und negative Begleiterscheinungen des Verkehrs zu reduzieren und gleichzeitig das Mobilitätsbedürfnis der Gesellschaft zu befriedigen.

Für viele urbane Gebiete fehlt es jedoch an relevanten Basisdaten, z. B. für die Abschätzung der Nachfrage (Levashev, 2017). Die Aussagekraft vieler Verkehrsmodelle ist durch die geringe räumliche Abdeckung, und die spärliche, aggregierte oder veraltete Datenverfügbarkeit begrenzt, was zu verzerrten und ungenauen Ergebnissen führt. Dies ist besonders in Ländern des Globalen Südens zu beobachten, in denen die Infrastruktur für eine umfassende Datenerfassung fehlt (Mai-Tan et al., 2020; Huang et al., 2021). Obwohl die Qualität und Quantität offener Geodaten, etwa von OSM (Barrington-Leigh und Millard-Ball, 2017; Tian et al., 2019), kontinuierlich zunimmt, bestehen in vielen Regionen nach wie vor erhebliche Lücken in der Verfügbarkeit. Insbesondere in hochdynamischen Städten des globalen Südens sind diese notwendigen Daten oft veraltet, unvollständig, nicht zuverlässig oder generell nicht vorhanden (Cervero, 2013; Walker et al., 2010). Darüber hinaus können traditionelle Methoden wie Umfragen und Verkehrszählungen zur Erhebung von Daten für Quelle-Ziel-Schätzungen insbesondere in Ländern des Globalen Südens oft nicht umgesetzt werden, da es an finanziellen Mitteln und qualifiziertem Personal mangelt. Dies, so argumentieren Machado und Quintanilha, 2019, kann zum Beispiel teilweise durch hohe Kriminalitätsraten in Städten erschwert werden. Diese Umstände führen dazu, dass geeignete Verkehrsmodelle für Länder des Globalen Südens kaum vorhanden sind (Wang et al., 2017). Darüber hinaus sind aggregierte Daten auf Verwaltungsebene oft die primäre Datenquelle für Verkehrsprognosen. Diese aggregierten räumlichen Einheiten werden aber dem nötigen Detailgrad komplexer, kleinräumiger urbaner Landschaften insbesondere in dichten städtischen Umgebungen nicht gerecht (Nordenholz et al., 2019). Eine hohe räumliche Auflösung zuverlässiger Basisdaten ist auch für agentenbasierte Modelle von Vorteil, z.B. für die Untersuchung der Auswirkungen des Verkehrs auf die lokale Bevölkerung in Bezug auf verkehrsbedingten Lärm (Kaddoura et al., 2016; Khomenko et al., 2022) und Emissionen (Linton et al., 2015; Xu et al., 2024b). Wenn dementsprechende Daten nicht verfügbar sind, müssen alternative Quellen herangezogen werden.

Die Fernerkundung könnte als eine solche Alternative dienen und möglicherweise fehlende Daten für den Verkehr liefern (Machado und Quintanilha, 2019). Die Fernerkundung 1) ermöglicht eine großflächige Abdeckung über Verwaltungsgrenzen hinweg, 2) bietet eine objektive Betrachtung, 3) hilft bei der Erfassung aktueller Informationen und 4) ist zeit- und kosteneffizient. Obwohl die Nutzung der Fernerkundung Fachwissen voraussetzt (Sherbinin et al., 2002; Young et al., 2017) und die Verfügbarkeit der entsprechenden Fernerkundungsdaten voraussetzt, wurde sie in verschiedenen Studien im Themengebiet Verkehr eingesetzt (Bowen et al., 2004; Guindon und Zhang, 2007; Kopsiaftis und Karantza, 2015; Machado und Quintanilha, 2019; Palubinskas et al., 2010; Salvo et al., 2017; Zhang und Guindon, 2006; Zhang et al., 2010). Aljoufie et al., 2013 analysierten beispielsweise die räumlich-zeitliche Beziehung zwischen Stadtwachstum und Verkehr. Dincer et al., 2019 zeigten anhand von Landsat-Daten, wie Infrastrukturprojekte zu einem Anstieg der bebauten Flächen und der Bevölkerung geführt haben. Generell lassen sich mit Fernerkundungsdaten verschiedene Aspekte der städtischen Raumstruktur erfassen. Um die Ausbreitung von Siedlungen zu überwachen, ist es möglich, ihre Ausdehnung abzuleiten, die die horizontale 2D-Ausbreitung beschreibt (Angel et al., 2011; Taubenböck et al., 2019). Mit den aus Stereo- oder Tri-Stereo-Satellitendaten gewonnenen Höheninformationen lässt sich ein digitales Oberflächenmodell (engl. *digital surface model*, DOM) oder ein normalisiertes digitales Oberflächenmodell (engl. *normalized digital surface model*, nDOM) generieren. Damit können zudem die vertikale Ausbreitung von Städten und deren Dichte als Proxies abgeleitet werden (Wurm et al., 2011, 2014). Darüber hinaus ermöglicht die Kombination von Fernerkundung und Google Street View die Ableitung von Gebäudeetagen, wodurch tiefgreifende Analysen der städtischen Raumstruktur durchgeführt werden können (María et al., 2016; Taubenböck et al., 2018).

Ziel dieses Abschnitts der Dissertation ist es, die Anwendbarkeit fernerkundungsbasierter Daten und abgeleiteter Geoinformationen als Proxyvariablen zur Unterstützung verkehrsbezogener Studien zu untersuchen, insbesondere in Regionen, für die keine oder nur unzureichende verkehrsrelevante Basisdaten vorliegen. Zu diesem Zweck fokussiert sich dieser Teil auf drei Faktoren, die erstens, wesentlich zu den Merkmalen der städtischen Raumstruktur beitragen, und zweitens, mit Hilfe von Fernerkundungs- und offenen Geodaten erschlossen werden können: *Gebäude*, *Landnutzung* und *Bevölkerung*. Diese drei Schlüsselparameter der städtischen Raumstruktur werden mit einer sehr hohen räumlichen Auflösung für zwei beispielhafte Megastädte abgeleitet, Santiago de Chile und Medellín, um die folgenden Aspekte zu untersuchen:

- *Gebäude*: Wo befinden sich die Gebäude und wie können diese anhand ihrer Fläche, Höhe und Anzahl der Stockwerke charakterisiert werden?
- *Landnutzung*: Welche Art der Landnutzung kann diesen Gebäuden zugeordnet werden, und wie ist die Landnutzung folglich über die Stadt verteilt?

- *Bevölkerung*: Wie viele Menschen können den einzelnen Gebäuden zugeordnet werden, und wie sieht es mit der innerstädtischen Bevölkerungsverteilung aus? Welche Art von Daten wird benötigt, um valide Bevölkerungszahlen zu erhalten, die die Verkehrsmodelle unterstützen?

Um diesen Fragestellungen nachzugehen, wird ein multimodales funktionales 3D-Stadtmodell erstellt, das diese wichtigen Merkmale der städtischen Raumstruktur mit vier Detailebenen erfassen kann. In einem ersten Schritt werden die 3D-Gebäude erstellt (Ebene-1). Dazu werden state-of-the-art Deep-Learning-Methoden zur semantischen Segmentierung von Orthophotos für die flächenhafte Ableitung von Gebäudegrundrissen mit Höheninformationen aus einem nDOM eingesetzt. In einem zweiten Schritt werden Bilddaten aus Google Street View verwendet, um die Anzahl der Stockwerke für eine Stichprobe von Gebäuden zu ermitteln und ein Regressionsmodell zu trainieren, um die Stockwerkanzahl stadtweit zu bestimmen (Ebene-2). Drittens werden Landnutzungsdaten und POIs von OSM verwendet, um detaillierte Landnutzungsinformationen abzuleiten (Ebene-3). Viertens wird eine Bevölkerungsabschätzung auf der Ebene einzelner Gebäude durchgeführt, um die innerstädtische Bevölkerungsverteilung zu ermitteln (Ebene-4). Die verwendeten Datengrundlagen sind für viele Regionen der Welt verfügbar, jedoch nicht flächendeckend oder in gleicher Qualität. Daher werden in dieser Arbeit fünf Experimente mit unterschiedlich hohem semantischen Detailgrad durchgeführt (näher beschrieben in Abschnitt 5.2). Sie dienen dazu, systematisch zu untersuchen, wie stark der jeweilige Informationsgehalt die Genauigkeit der Bevölkerungsverteilung beeinflusst und ab welchem Detailgrad verlässliche Aussagen möglich sind. Damit ermöglichen die Ergebnisse auch eine Bewertung der Anwendbarkeit des Ansatzes in Regionen mit eingeschränkter Datenverfügbarkeit.

Der folgende Abschnitt konzentriert sich auf die drei Parameter der städtischen Raumstruktur, die in diesem ersten Teil der Doktorarbeit behandelt werden: *Gebäude*, *Landnutzung* und *Bevölkerung*. Für jeden Parameter wird jeweils die Bedeutung im Zusammenhang mit dem städtischen Verkehr hervorgehoben und es werden fernerkundliche Methoden zu seiner Bestimmung erläutert.

3.1.1 Gebäude

Hauptmerkmale der städtischen Raumstruktur sind Gebäude. Sie können als grundlegender physischer Bestandteil der räumlichen Struktur einer Stadt betrachtet werden und werden als Grundlage für jede weitere Semantik, z. B. der Landnutzung und der Bevölkerung, benötigt (Hecht et al., 2013). In diesem Zusammenhang spielen Extraktions- und Klassifikationsverfahren eine entscheidende Rolle in der Bildanalyse innerhalb der urbanen Fernerkundung. Für die Extraktion von Gebäuden existieren zahlreiche Ansätze, beispielsweise unter Verwendung von Formmetriken (Sirmacek et al., 2012), Schatteninformationen (Ngo et al., 2015) oder einer Kombination aus Bild- und Höheninformationen (Sohn und Dowman, 2007). Es ist möglich, aus Gebäudedaten (2D

und 3D) die Bebauungsdichte bzw. Kompaktheit abzuleiten, die sich als wesentliches Merkmal für das städtische Verkehrssystem erwiesen hat (Chen et al., 2019; Liddle, 2013; Resch et al., 2016).

Trotz ihrer Bedeutung für die Stadtplanung sind Gebäudedaten für viele Regionen der Welt nur spärlich vorhanden. Obwohl OSM Gebäudedaten bereitstellt, ist nur wenig über deren weltweite Vollständigkeit bekannt. Für die Region Lombardei in Norditalien wurde festgestellt, dass sie zu 57% vollständig sind (Brovelli und Zamboni, 2018). Für München, Deutschland, fanden Fan et al., 2014 einen hohen Grad an Vollständigkeit, allerdings mit wenig Informationen zu den Gebäudeattributen, z. B. Gebäudehöhe oder Anzahl der Stockwerke. In anderen Regionen, insbesondere in Ländern des Globalen Südens, ist hingegen mit einer geringeren Vollständigkeit sowie mit weniger umfassenden Attributinformationen zu rechnen.

Ergänzend stehen inzwischen globale Datensätze wie die Microsoft Building Footprints zur Verfügung, die KI-basiert Gebäudegrundrisse ableiten. Diese bieten zwar eine breite Abdeckung, variieren jedoch stark in Qualität und Aktualität und zeigen in komplexen urbanen Räumen teils deutliche Lücken (Microsoft, 2025). Für Europa liefert EUBUCCO eine strukturierte, offene Datenbank mit Informationen zu Baujahr, Nutzung und Gebäudehöhe, allerdings beschränkt auf 27 europäische Länder (Milojevic-Dupont et al., 2023).

Fernerkundungsdaten und -methoden können als Alternative zu diesen großflächig verfügbaren Datensätzen und zur Erfassung fehlender bzw. unvollständiger Gebäudedaten dienen. Obwohl sich die Fernerkundung seit Jahrzehnten mit der bildbasierten Gebäudeextraktion befasst (McKeown, 1990), bleibt die automatisierte Gebäudeerkennung nach wie vor herausfordernd (Bittner et al., 2017; Ghanea et al., 2016; Li et al., 2024). In den vergangenen Jahren wurden verstärkt Deep-Learning-Techniken angewendet und führten zu erheblichen Verbesserungen bei Klassifizierungsaufgaben in urbanen Regionen (Huang et al., 2018; Xu et al., 2018; Li et al., 2024). Darüber hinaus bieten die Methoden des Deep Learning den Vorteil, für komplexe urbane Strukturen einsetzbar zu sein (Bittner et al., 2018) und eine Vielzahl unterschiedlicher Gebäudetypen zu erfassen (Ji et al., 2018). Da weiterhin Defizite in der Vollständigkeit offener Geodaten bestehen, können Deep-Learning-Ansätze dabei helfen, diese Lücken zu schließen (Zhu et al., 2017). Dabei zeigte sich, dass Deep-Learning-Ansätze herkömmliche Verfahren in ihrer Leistungsfähigkeit deutlich übertreffen können (Ma et al., 2019; Zhu et al., 2017; Wang et al., 2024b). Insbesondere bei der Extraktion von Gebäuden liefern sie sehr präzise Ergebnisse (Hui et al., 2019). Zum Einsatz kommen dabei unter anderem Verfahren der semantischen Segmentierung sowie des Transferlernens (Wurm et al., 2019b).

Auf Grundlage der resultierenden 2D-Gebäudegrundrisse können mithilfe eines aus Satelliten- daten abgeleiteten nDOM Höheninformationen ergänzt werden, um daraus 3D-Gebäudemodelle zu generieren (Wurm et al., 2021). Ein DOM enthält die Höhe aller Objekte auf der Erdoberfläche, wobei sowohl natürliche als auch künstliche Objekte abgebildet werden. Ein nDOM enthält nur die

Höhen von Objekten in Bezug auf die Bodenoberfläche. Die 3D-Gebäude können als Grundlage für die Bestimmung weiterer wichtiger Faktoren der städtischen Raumstruktur verwendet werden: Landnutzung und Bevölkerung (z. B. Wurm et al., 2011).

3.1.2 Landnutzung

Jede Art der Landnutzung hat ihre spezifischen Auswirkungen auf die urbane Mobilität und kann als Generator oder Attraktor von Bewegungen dienen (Nuhn und Hesse, 2006). Eine diverse Landnutzung wurde mit kürzeren Fahrten (Srinivasan et al., 2013), einer Verringerung der Fahrzeugemissionen durch die Reduzierung des Verkehrsaufkommens (Choi und Zhang, 2017), einer stärkeren Nutzung öffentlicher Verkehrsmittel (Stevenson et al., 2016) und einer höheren Wahrscheinlichkeit der Nutzung nicht motorisierter Verkehrsmittel (Duncan et al., 2010; Faghih-Imani et al., 2014) in Verbindung gebracht. Es wurde zudem festgestellt, dass die Wahl des Verkehrsmittels und das Pendelverhalten mit der Landnutzung zusammenhängen (Hu et al., 2018; Jin, 2019; Sun et al., 2017) und sich die Landnutzung generell auf die Wahl des Verkehrsmittels auswirkt (Van Acker und Witlox, 2010). Darüber hinaus kann die innerstädtische Verteilung eines bestimmten Landnutzungstyps den Anteil des Privatautobesitzes erhöhen oder verringern. Cao et al., 2019 fanden dabei heraus, dass die Verlagerung von Wohngebieten in den Außenbereich der Stadt den Anteil des Autobesitzes erhöht und die Verlagerung von Wohngebieten in den Innenbereich der Stadt den Autobesitz verringert. Für die Nutzung und Akquise relevanter Landnutzungsdaten, gibt es eine Vielzahl von Studien, die auf VGI zurückgreifen, insbesondere auf OSM-Daten (OpenStreetMap contributors, 2025). Der Vorteil der Verwendung von OSM-Landnutzungsdaten besteht darin, dass sie eine kostenfreie und fein aufgeschlüsselte Datenbank bereitstellen, die eine detaillierte Bestimmung der Landnutzung ermöglicht, was mit Fernerkundungsdaten allein nicht möglich wäre (Fonte et al., 2017; Schultz et al., 2017). Die Landnutzung spielt auch bei der Bevölkerungsabschätzung eine wichtige Rolle (Biljecki et al., 2016).

3.1.3 Bevölkerung

Die Bevölkerung wird häufig als Schlüsselvariable für die Schätzung der Verkehrsnachfrage (Choupani und Mamdoohi, 2016) und für Erreichbarkeitsanalysen (Sarlás et al., 2020) verwendet. Hohe Siedlungsdichten wirken sich positiv auf die Nutzung von Fahrrad-Sharing-Angeboten aus (Faghih-Imani et al., 2014) und senken die Wahrscheinlichkeit, dass Haushalte über mehr als ein Auto verfügen (Soltani und Somenahalli, 2005), was die Nachhaltigkeit im Verkehrssektor unterstützt. Darüber hinaus betonten Zhang und Guindon, 2006, dass sich innerstädtische Bevölkerungsunterschiede entscheidend auf die Nutzung städtischer Verkehrssysteme auswirken. Srinivasan et al., 2013 stellten fest, dass eine hohe Dichte der Wohnbevölkerung und eine vielfältige Landnutzung zu kürzeren Fahrten führen und betonten, dass beide Faktoren miteinander verwoben sind. Ansätze zur Ableitung von innerstädtischen Bevölkerungsmustern können in Top-Down- und Bottom-Up-Ansätze unterteilt werden, indem die Gesamtbevölkerung der Stadt auf kleinere

Einheiten (z. B. Verkehrsanalysezonen, engl. *Traffic Analysis Zones*, TAZs), administrative Gebiete oder ähnliches verteilt oder disaggregiert wird bzw. indem die Bevölkerung von Teilen der Stadt auf die gesamte Stadt hochgerechnet oder aggregiert wird (Stevens et al., 2015; Taubenböck et al., 2008; Wu et al., 2005; Wurm et al., 2009). Der Vorteil des Top-Down-Ansatzes besteht darin, dass keine kleinräumigen und detaillierten Bevölkerungsdaten erforderlich sind, sondern nur die Gesamtbevölkerungszahl einer Stadt, wodurch die Übertragbarkeit des Ansatzes erhöht wird.

3.2 Erreichbarkeit öffentlicher Verkehrsmittel

Die Erreichbarkeit öffentlicher Verkehrsmittel ist ein entscheidender Aspekt der urbanen Mobilität. Der Zugang zu öffentlichen Verkehrsmitteln fördert nicht nur die soziale Inklusion, sondern schafft auch Chancengleichheit für verschiedene gesellschaftliche Gruppen (Saif et al., 2019). Darüber hinaus ist sie von wesentlicher Bedeutung, um Menschen den Zugang zu Beschäftigung, Bildung, Gesundheitsversorgung und anderen grundlegenden Dienstleistungen zu ermöglichen (Boisjoly et al., 2017). Allgemein wird Erreichbarkeit als das Maß an Bequemlichkeit definiert, mit dem bestimmte Standorte mit Hilfe eines oder mehrerer Verkehrsmittel erreicht werden können (Boisjoly et al., 2017; Geurs und Wee, 2023; Wee und Geurs, 2011).

Im Jahr 2015 verabschiedeten die UN die Agenda 2030 mit 17 Zielen für nachhaltige Entwicklung, den SDGs. Das übergeordnete Ziel bestand darin, die globale wirtschaftliche, soziale und ökologische Nachhaltigkeit voranzutreiben (United Nations, 2015). Im Rahmen des SDG 11 „Nachhaltige Städte und Gemeinden“ wurden sieben Unterziele formuliert, darunter das Ziel 11.2, das darauf abzielt, bis 2030 „Zugang zu sicheren, bezahlbaren, zugänglichen und nachhaltigen Verkehrssystemen für alle“ zu gewährleisten (United Nations, 2015). Zur Messung des Status und der Fortschritte in Bezug auf Ziel 11.2 auf globaler Ebene verwendet UN Habitat einen distanzbasierten Indikator, der den Anteil der Bevölkerung mit bequemem Zugang zu öffentlichen Verkehrsmitteln schätzt (Holzwarth, 2021). Dieser bequeme Zugang wird als Gehdistanz im Straßennetz zu Haltestellen des öffentlichen Nahverkehrs (ÖV-Haltestellen) innerhalb von 500 m bei Verkehrssystemen mit geringer Kapazität (z. B. Bus) und 1000 m bei Verkehrssystemen mit hoher Kapazität (z. B. U-Bahn, Bahn, Fähre) definiert (UN-Habitat, 2021b).

Für diese Erreichbarkeitsbewertung sind detaillierte räumliche Daten erforderlich. Diese umfassen die Anzahl und Lage der ÖV-Haltestellen, das Straßennetz sowie die Wohnorte der lokalen Bevölkerung, um die Entfernungen zu analysieren, die Einzelpersonen zurücklegen müssen, um diese Haltestellen zu erreichen. Daten zu ÖV-Haltestellen stammen in der Regel aus Beständen von Verkehrsbehörden (z. B. als *General Transit Feed Specification* (GTFS)-Daten) oder aus OSM (Bok und Kwon, 2016; Jäppinen et al., 2013; Lantseva und Ivanov, 2016). Daten über das Straßennetz sind ebenfalls aus OSM verfügbar. Heutzutage gelten OSM-Straßendaten weltweit als relativ vollständig und sind insbesondere in dicht besiedelten Gebieten wie urbanen Räumen gut kartiert (Barrington-Leigh und Millard-Ball, 2017), auch wenn hinsichtlich der Datenvollständigkeit und -qualität weiterhin Unterschiede in Bezug auf den spezifischen Datensatz

oder die betrachtete Region gibt (Herfort et al., 2023; Zhou et al., 2022). In Ländern mit hoher Datenverfügbarkeit sind Bevölkerungsdaten mit feiner räumlicher Auflösung überwiegend durch nationale oder lokale Volkszählungen erhältlich, sofern diese öffentlich verfügbar gemacht werden. In anderen Regionen, insbesondere in Ländern des Globalen Südens, sind offizielle Bevölkerungsdaten mit hoher räumlicher Auflösung kaum verfügbar. Um diese Lücke zu schließen, bieten Fernerkundungsdaten eine unabhängige Möglichkeit zur Ableitung von Siedlungsstrukturen. Sie können für Bevölkerungsschätzungen genutzt werden und helfen, fehlende Bevölkerungsdaten zu kompensieren (Sapena et al., 2022). Auf globaler Ebene gibt es fernerkundungsbasierte Bevölkerungsdatensätze in unterschiedlichen räumlichen Auflösungen, zum Beispiel für 250 x 250 m Raster (z. B. GHS-POP (Freire et al., 2016)) und 100 x 100 m Raster (z. B. WorldPop (Stevens et al., 2015; Tatem, 2017)). Im Gegensatz zu globalen Ansätzen gibt es auch subglobale Ansätze, die Bevölkerungsdaten auf kontinentaler (Doda et al., 2022; McKeen et al., 2023), nationaler (Biljecki et al., 2016; Palacios-Lopez et al., 2022) oder städtischer Ebene (Georganos et al., 2019; Lu et al., 2010; Stiller et al., 2021) erfassen. Um die Erreichbarkeit zu messen, sind zuverlässige Bevölkerungsdaten unerlässlich.

In den folgenden drei Unterkapiteln wird nun auf diese drei Schlüsselaspekte von Erreichbarkeit von öffentlichen Verkehrsmitteln eingegangen: 1) die Betrachtung bestehender Ansätze zur Messung der Erreichbarkeit und Bewertungen des von der UN vorgeschlagenen Indikators, 2) die Besonderheiten von informellem und semiformellem Verkehr, sowie 3) die Charakteristika des öffentlichen Verkehrssystems in Medellín.

3.2.1 Messung der Erreichbarkeit

Der von den UN vorgeschlagene SDG-Indikator 11.2 misst die Erreichbarkeit zu öffentlichen Verkehrsmitteln anhand der geographischen Entfernung. Erreichbarkeit ist jedoch ein komplexes Konzept mit unterschiedlichen Ausprägungen, und es gibt eine Vielzahl von Methoden zu ihrer Messung. Die in den einschlägigen Studien beschriebenen Ansätze (Boisjoly et al., 2017; Geurs und Wee, 2004) lassen sich in vier Kategorien einteilen: 1) orts- bzw. raumbasierte Ansätze, 2) infrastruktur- bzw. distanzbasierte Ansätze, 3) nutzenbasierte Ansätze und 4) personenbezogene Ansätze. Der von den UN vorgeschlagene SDG-Indikator fällt in die zweite Kategorie, die infrastruktur- bzw. distanzbasierten Ansätze, und gehört genauer zu jenen, die Erreichbarkeit unmittelbar anhand der Entfernung messen (Albacete et al., 2015). Der Indikator bietet einen praktikablen Ansatz, der globale Vergleiche der Erreichbarkeit zu öffentlichen Verkehrsmitteln ermöglicht (Holzwarth, 2021). Er wird insbesondere aufgrund seiner Praktikabilität und breiten Anwendbarkeit in unterschiedlichen regionalen Kontexten gewählt, da er nicht auf hochgenaue oder kontextspezifische Daten angewiesen ist, die möglicherweise nicht in allen Regionen verfügbar sind. Im Gegensatz zu anderen Methoden, die detaillierte lokale Daten zu Einkommen, Flächennutzung, Fahrtrouten, Fahrthäufigkeiten oder Reisezeiten erfordern, bietet dieses distanzbasierte Maß einen standardisierten und leicht anwendbaren Ansatz. Dies macht den Indikator besonders geeignet

für großflächige oder länderübergreifende Bewertungen der Erreichbarkeit oder Vergleichsstudien, bei denen solche lokalen Daten schwer zu erheben oder uneinheitlich erfasst werden, z. B. in Ländern des Globalen Südens.

Allerdings werden die Verlässlichkeit und Anwendbarkeit des SDG-Indikators auch in der Fachwelt kritisch diskutiert. Beispielsweise haben mehrere Studien den UN-SDG-Indikator 11.2 in verschiedenen geographischen und analytischen Kontexten untersucht und die von den UN vorgeschlagene Methode mit anderen Maßen verglichen (Akuraju et al., 2020; Ochoa-Covarrubias et al., 2021). Fried et al., 2020 verglichen beispielsweise das von den UN vorgeschlagene Maß mit einem ortsbasierten Erreichbarkeitsindikator, der Einkommensdaten, Reisezeiten und Flächen-nutzung für das Fallbeispiel des Minibus-Systems in Nairobi einbezieht. Sie betonen insbesondere die Notwendigkeit, unkonventionelle Verkehrsmittel wie informelle Transportmöglichkeiten zu berücksichtigen. Diese stellen eine wichtige Transportart dar, sind jedoch aufgrund ihres informellen Charakters in offiziellen Daten unterrepräsentiert oder nicht vorhanden. Tiwari und Phillip, 2021 untersuchten den UN-Indikator in zwei kleineren indischen Städten und bewerteten die resultierende Erreichbarkeit für verschiedene formelle und informelle Verkehrsmittel bei unterschiedlichen Entfernungen zur nächsten Haltestelle. Sie empfahlen die Berücksichtigung informeller Verkehrsmittel und eine Anpassung der Erreichbarkeitsdistanz von 500 m.

Eine kritische Untersuchung des SDG-Indikators 11.2 führten Brussel et al., 2019 durch. Der Hauptkritikpunkt ist, dass der Indikator eher die Erreichbarkeit zu öffentlicher Verkehrsinfrastruktur misst, als die Erreichbarkeit zu funktionalen Aktivitätsorten der Stadt. Die Autoren argumentieren, dass das vorgeschlagene Maß für den SDG-Indikator 11.2 nicht ausreicht, um Ungleichheiten in der Verteilung der Erreichbarkeit und die Komplexität von Verkehrssystemen abzubilden. Andere kritisieren, dass Studien, die sich ausschließlich auf die Gehdistanz als Indikator für die Qualität des öffentlichen Verkehrs konzentrieren, wichtige Barrieren der Erreichbarkeit außer Acht lassen, etwa die wahrgenommene Qualität der städtischen Umgebung (Tiznado-Aitken et al., 2018), sowie Aspekte wie Erschwinglichkeit, Zuverlässigkeit, subjektive Sicherheitswahrnehmung, Kapazität und zeitliche Komponenten des öffentlichen Verkehrs (Fried et al., 2020). Diese Einflussfaktoren könnten dazu führen, dass Personen zwar in der Nähe einer Haltestelle wohnen, diese jedoch nicht nutzen. Sogar UN Habitat selbst hält ein Maß für den Zugang zu Aktivitätsorten der Stadt für geeigneter, wenn Daten dafür existieren würden und in Städten auf der ganzen Welt einheitlich angewendet werden könnte (UN-Habitat, 2021b).

Insbesondere ist die Definition der UN bezüglich der einzubeziehenden Verkehrsmittel uneinheitlich dokumentiert. Während eine frühere Quelle informelle öffentliche Verkehrsmittel ausdrücklich ausschließt und sich ausschließlich auf formelle Angebote konzentriert (United Nations, 2015), spricht sich eine neuere Publikation hingegen dafür aus, auch Paratransit-Systeme einzubeziehen, und erkennt deren Bedeutung für die Erreichbarkeit ausdrücklich an (Holzwarth, 2021). Informeller und semiformeller Transport spielt eine wichtige Rolle im städtischen Verkehr (O'Brien und Evans, 2017). Eine vereinfachte Betrachtung der urbanen Realität, die informelle Verkehrssysteme und Siedlungen ausblendet, kann zu verzerrten Einschätzungen des tatsächlichen

Zustands des städtischen Verkehrs durch öffentliche Behörden führen. Zusätzlich argumentieren Tiwari und Phillip, 2021 für die Einbeziehung informeller und semiformeller öffentlicher Verkehrsdienste oder Paratransit bei der Betrachtung des lokalen öffentlichen Verkehrssystems. Diese Sichtweise stimmt eher mit der Realität in vielen Ländern weltweit überein, in denen informelle und semiformelle Verkehrsmittel genutzt werden, insbesondere im Globalen Süden (Cervero und Golub, 2007), wo sie sogar die primäre Transportoption darstellen können (Okami et al., 2022).

3.2.2 Informeller Transport, semiformeller Transport, Paratransit

Formeller öffentlicher Verkehr wird in der Regel von offiziellen Stellen betrieben, die entweder öffentlich oder privat sind, und unterliegen Vorschriften, die Fahrerausbildung, die Einhaltung lokaler Sicherheitsstandards, feste Tarife, Arbeitsrechtsschutzvorschriften, festgelegte Routen und Fahrpläne umfassen (Kumar et al., 2021). Im Gegensatz dazu wird informeller und semiformeller öffentlicher Verkehr, auch als Paratransit bezeichnet, nicht von offiziellen Stellen betrieben (Cervero und Golub, 2007). In Lateinamerika ist semiformeller Transport in der Regel autorisiert, operiert dennoch mit einem gewissen Grad an Informalität, während informeller Transport oft als illegal betrachtet wird, was dazu führt, dass die Behörden aktiv gegen diese Transportdienste vorgehen (Tun et al., 2020). Informelle und semiformelle Transportdienste sind im Allgemeinen unregelmäßig und locker geregelt, meist ohne festgelegte, aber bekannte Haltestellen, und die Routen können flexibel (für die Mehrheit der informellen Dienste) oder weitgehend festgelegt (für die Mehrheit der semiformellen Dienste) sein (Kumar et al., 2021; Tun et al., 2020). Diese Dienste können flexibel auf Marktveränderungen und Nachfrageschwankungen reagieren und bieten damit ein Maß an Anpassungsfähigkeit, das formellen, staatlich organisierten Verkehrssystemen mit hohen Fahrzeugkapazitäten oft fehlt (Cervero und Golub, 2007). Darüber hinaus sind informelle und semiformelle Transportmöglichkeiten häufig kostengünstiger (Woolf und Joubert, 2013).

Informelle und semiformelle Verkehrsmittel in Lateinamerika weisen eine große Vielfalt auf und unterscheiden sich je nach Region nicht nur in ihrer Form, sondern auch in ihrer lokalen Bezeichnung. Diese beinhalten Motorräder und Autos, die 3-5 Passagiere befördern (z. B. 'Concho', 'Taxi colectivo'), Minibusse für 10-20 Passagiere (z. B. 'Colectivo', 'Lotação'), Microbusse mit Kapazitäten von 20-35 Passagieren (z. B. 'Buseta', 'Chimeco') und größere Busse für 30-70 Passagiere (z. B. 'Diablo rojo', 'Ejecutivo') (Tun et al., 2020). In anderen Regionen der Welt umfassen die Fahrzeuge beispielsweise Zweiräder wie 'Xe Om' in Vietnam oder 'Boda-boda' in Uganda (Müller und Doeverspeck, 2023; Turner und Nguyen, 2024), Dreiräder wie 'Qingqis' in Pakistan (Starkey et al., 2021), Minibusse wie 'matatus' in Kenia oder 'jeepney' auf den Philippinen (Fried et al., 2020; Mateo-Babiano et al., 2020) oder größere Busse wie 'Molue' in Nigeria (Amiegbekhor, Popoola et al., 2021).

Informelle und semiformelle Transportangebote schließen häufig die Lücke, die durch das Fehlen eines formellen öffentlichen Massenverkehrs entsteht. Sie sind insbesondere in Ländern des Globalen Südens weit verbreitet (Cervero und Golub, 2007), vor allem in urbanen Räumen mit begrenzter Verkehrsinfrastruktur, die zugleich von schnellem Bevölkerungswachstum und

ausgedehnter städtischer Expansion geprägt sind (Kumar et al., 2021; Tucho, 2022). Schnell wachsende Städte sind häufig geprägt durch ungeplante, weniger dicht besiedelte Siedlungen an den ehemaligen Stadträndern, die Ausdehnung informeller Wohngebiete sowie zunehmende Reiseentfernungen. Diese Entwicklungen gehen oftmals mit einem Rückgang der Quantität, Qualität und des Zustands öffentlicher Verkehrsmittel einher – bis hin zu deren vollständigem Fehlen (Kumar et al., 2021). Teilweise übernehmen informelle und semiformelle Transportsysteme unter der Organisation lokaler Behörden oder zivilgesellschaftlicher Akteure feste Strukturen wie Fahrpläne und Routen und nähern sich damit formellen Verkehrssystemen an (Cervero und Golub, 2007). Diese Form der informellen Regulierung kann dazu beitragen, die Erreichbarkeit zu verbessern, insbesondere in Kommunen, denen die Ressourcen fehlen, um in umfassende öffentliche Verkehrsinfrastruktur zu investieren (Cervero und Golub, 2007). Informelle und semiformelle Verkehrsmittel weisen häufig auch ein höheres Maß an räumlicher Anbindung auf und spielen eine wichtige Rolle bei der Förderung der sozialen Inklusion von marginalisierten Gruppen (Nelson, 2021; Palacios-Lopez et al., 2022; Tun et al., 2020).

Allerdings wird auch die selbst- oder schlecht regulierte Natur von informellem und semiformellem Transport kritisiert. Die verwendeten Fahrzeuge befinden sich oft in suboptimalen Zuständen, was Sicherheitsbedenken aufwirft. Die fehlende Regulierung dieser Dienste kann ebenso zu einem Überangebot führen, das einen intensiven Wettbewerb unter den Fahrern erzeugt. In ihrem Bestreben, günstiger und schneller zu sein, entsteht oft eine ausbeuterische Arbeitsumgebung: Fahrer arbeiten lange Stunden für unzureichende Bezahlung und können sich kaum angemessene Sicherheitsstandards für ihre Fahrzeuge leisten (Cervero und Golub, 2007). Behörden in vielen Regionen haben Schwierigkeiten, wie mit diesen Bedenken umzugehen ist, ob sie diese nicht offiziellen Transportmöglichkeiten einbinden oder bekämpfen und unterdrücken sollen (Cervero und Golub, 2007). Da informelle und semiformelle Transportsysteme stark kontextabhängig und durch spezifisch regionale Merkmale geprägt sind, lässt sich keine allgemeingültige Handlungsempfehlung für ihren Umgang ableiten (Cervero und Golub, 2007).

3.2.3 Die Situation in Medellín, Kolumbien

Neben formellen öffentlichen Verkehrsmitteln spielt auch informeller und semiformeller öffentlicher Verkehr eine wichtige Rolle für die Einwohner von Medellín. Das formelle öffentliche Verkehrssystem umfasst Standardbusse und das U-Bahnnetz, das aus schienengebundenen U-Bahnlinien, Seilbahnen und Metroplús-Bussen (eine Form des BRT-Systems) besteht (Metro de Medellín, 2021). Im Gegensatz dazu existieren auch semiformelle Transportoptionen in Medellín, Minibusse, die lokal als ‚*Colectivos*‘ bekannt sind. Vage Schätzungen deuten darauf hin, dass etwa 250.000 Bewohner in der Metropolregion Medellín auf diese Verkehrsdienste angewiesen sind, die in mehr als 70 Sektoren der Stadt verkehren (Pareja, 2015). Diese Minibusse haben eine Kapazität von 10–20 Personen (Tun et al., 2020) und operieren als semiformeller Verkehr, der bestimmten Standards entspricht, jedoch nicht vollständig in das formelle Verkehrssystem integriert ist (Echeverri et al., 2011). Sie sind flexibel, bieten eine größere Netzabdeckung und höhere Frequenz, wodurch

die Anzahl der Umstiege für die Nutzer reduziert wird (Tun et al., 2020). Von kleineren privaten Unternehmen betrieben, dürfen sie bestimmte Routen (*„rutas de transporte público colectivo“*) betreiben und ergänzen damit das formelle Verkehrssystem in Medellín (Echeverri et al., 2011; Jimenez und Rengifo, 2016). Ihre Routen oder Ziele werden in der Regel auf Schildern angezeigt, die an der Windschutzscheibe des Fahrzeugs angebracht sind (Jimenez und Rengifo, 2016). Minibusse operieren normalerweise ohne festgelegte Haltestellen und können Passagiere entlang der Route an beliebigen Orten abholen oder absetzen (Jimenez und Rengifo, 2016). Aufgrund der teilweisen Integration der Minibusse in das offizielle öffentliche Verkehrssystem von Medellín sind jedoch Informationen über Minibus-Haltestellen und deren Standorte verfügbar, was auf einen gewissen Grad an Regulierung und Systematisierung hinweist. Neben den semiformalen Minibussen sind auch informelle Verkehrsdienste, wie Mototaxis, vorhanden, die aktiv von der Mobilitätsbehörde Medellín kontrolliert und bekämpft werden (Restrepo, 2019). Aufgrund fehlender zuverlässiger Daten sind diese auch nicht Gegenstand dieser Analyse. Dennoch gibt es in anderen Regionen Bestrebungen, diese Wissenslücke zu schließen, indem verlässliche Daten über diese weitgehend unregulierten öffentlichen Verkehrsmittel erhoben werden, mit dem Ziel, sie in die Stadtplanung zu integrieren (Jimenez und Rengifo, 2016; Klopp und Cavoli, 2019; Williams et al., 2015).

Eine weitere strukturelle Besonderheit in Medellín sind die informellen Siedlungen der Stadt. Im Vergleich zu formellen Gebieten sind informelle Siedlungen durch ungeplante und unregulierte Bebauung gekennzeichnet. Sie entstehen oft ohne Genehmigung und rechtliche Sicherheit und sind meist nur unzureichend mit Infrastruktur versorgt (UN-Habitat, 2015). Informelle Siedlungen werden von Menschen mit unterschiedlichen sozioökonomischen Hintergründen bewohnt, von Wohlhabenden bis hin zu sozial Benachteiligten (UN-Habitat, 2015). Das Mobilitätsverhalten und der Zugang zu öffentlichen Verkehrsmitteln in informellen Gebieten kann sich erheblich unterscheiden (Teffo et al., 2019). Dies konnte ebenfalls in Medellín beobachtet werden. In informellen Gebieten konnte eine geringere Wegezahl, eine niedrigere Motorisierungsrate, weniger Autofahrten und eine höhere Anzahl von Fußwegen und Fahrten mit öffentlichen Verkehrsmitteln festgestellt werden (Heinrichs und Bernet, 2014), basierend auf Daten von Quelle-Ziel-Erhebungen für Medellín aus den Jahren 2005 und 2011/2012. Darüber hinaus fehlt informellen Gebieten das gleiche Maß an räumlicher Anbindung wie formellen Gebieten. Medellín liegt in einem Tal und ist von einer bergigen Landschaft umgeben. Große Teile der informellen Siedlungen befinden sich an den Stadträndern in Gebieten mit steilem Gelände (Vivir en El Poblado, 2022). Um diese räumliche Barriere zu überwinden, installierten die zuständigen Behörden in Medellín im Jahr 2004 Seilbahnen, die die informellen Siedlungen in peripheren Hanglagen mit dem U-Bahnnetz verbinden und so die Anbindung für die Bewohner verbessern sollten (Goodship, 2016; Vivir en El Poblado, 2022). Heinrichs und Bernet, 2014 schlussfolgern, dass die Integration der Seilbahn ins U-Bahnssystem vorteilhaft ist, da sie die Nutzung informeller Verkehrsmittel verringern und damit verbundene Sicherheitsrisiken reduzieren kann. In derselben Studie wurden die Auswirkungen der Seilbahnen auf die Gemeinden in informellen Siedlungen untersucht. Dabei zeigte sich, dass die Seilbahnen die Erreichbarkeit durch verkürzte Reisezeiten, höhere Zuverlässigkeit und sogar

geringere Kosten im Vergleich zu alternativen Busverbindungen deutlich verbessern konnten. Dennoch wurde festgestellt, dass die Ticketpreise für viele Bewohner weiterhin zu hoch sind. Die verantwortlichen Behörden haben das U-Bahnsystem weiter verstärkt ausgebaut, indem sie bis zum Jahr 2021 neue Seilbahnlinien eingeführt haben (Metro de Medellín, 2021). Tatsächlich nutzen viele Menschen weiterhin informelle und semiformelle Verkehrsmittel in Medellín, da formelle Verkehrsmittel oft nicht die Nachfrage decken und ungleichmäßig im Stadtgebiet verteilt sind. Weitere Beispiele aus Kolumbien zeigen, dass trotz der umfangreichen Erweiterung des offiziellen öffentlichen Verkehrs die Abhängigkeit von informellen und semiformellen Verkehrsmitteln weiterhin besteht (Prieto, 2014).

Die strukturellen Merkmale Medellín, einschließlich starker sozialräumlicher Disparitäten und eines vielschichtigen öffentlichen Verkehrssystems, machen die Stadt zu einem geeigneten Untersuchungsgebiet für die empirische Untersuchung des SDG-11.2-Indikators. Erstens, besteht das öffentliche Verkehrssystem in Medellín aus formellen und semiformellen Komponenten (Heinrichs und Bernet, 2014), und zweitens, gibt es in der Metropolregion Medellín große Gebiete mit informellen Siedlungen (Kühnl et al., 2021; Wurm et al., 2023). Dies macht Medellín zu einem idealen Studiengebiet, das eine Untersuchung des übergeordneten Ziels der Gleichheit im Rahmen der UN-Nachhaltigkeitsziele ermöglicht. Daher zielt diese Doktorarbeit darauf ab, zu analysieren, ob die offizielle Erreichbarkeitsrate mit insgesamt 38.35 % unter Verwendung des SDG-Indikators (UN-Habitat, 2021a) als realistische Maßzahl betrachtet werden kann, wenn semiformeller Minibusverkehr in die Analyse einbezogen wird.

3.2.4 Teilfragen und Zielsetzung

Vor diesem Hintergrund adressiert dieser Teil der Doktorarbeit die folgenden Teilfragen, die sich auf den spezifischen Fall von Medellín konzentrieren:

1. Wie variiert die Erreichbarkeit innerhalb des Stadtgebiets?
2. Zeigt die Erreichbarkeit Unterschiede durch die Nutzung von formellen und semiformellen Verkehrsmitteln? Inwieweit trägt informeller öffentlicher Verkehr zur gesamten Erreichbarkeit des öffentlichen Verkehrs bei?
3. Welche Rolle spielt die Erweiterung des U-Bahnsystems in Medellín (2016 vs. 2021) bei der Verbesserung der Erreichbarkeit zu öffentlichen Verkehrsmitteln?
4. Gibt es Unterschiede in der Erreichbarkeit zu öffentlichen Verkehrsmitteln in informellen Siedlungen im Vergleich zu formellen Siedlungen und wie korreliert die Erreichbarkeit mit sozioökonomischen Faktoren?
5. Können Fernerkundungsdaten als praktikable Lösung zur Überbrückung der Datenlücke in Gebieten ohne Bevölkerungsdaten dienen, insbesondere in Regionen mit weniger verlässlichen Daten, wie dem Globalen Süden?

Um diese Fragen zu beantworten, wird der SDG-Indikator 11.2 für die Stadt Medellín berechnet, unter der Verwendung der vorgeschlagenen UN-Methode, um die Erreichbarkeit der Gehdistanz zur nächsten Haltestelle zu messen. Darüber hinaus wird analysiert, wie die Erreichbarkeit zu öffentlichen Verkehrsmitteln räumlich über das städtische Gebiet hinweg variiert, indem die mittleren Gehdistanzen auf drei verschiedenen räumlichen Skalen verglichen werden: 1) auf der Ebene der gesamten Stadt (vergleichbar mit dem Ansatz des SDG-Indikators 11.2), 2) innerhalb administrativer Einheiten (Sektoren) und 3) innerhalb von Rasterzellen. Zudem wird untersucht, wie Fernerkundungsdaten bei der Beurteilung dieser Erreichbarkeiten helfen können, indem drei verschiedene Arten von Bevölkerungsdaten mit einbezogen werden: 1) Bevölkerungsdaten basierend auf disaggregierten Zensusdaten auf Ebene der Katastergebäude (Sapena et al., 2022), 2) ein fein granularer fernerkundungsbasierter Bevölkerungsdatensatz auf der Ebene einzelner Gebäude (Stiller et al., 2021) und 3) WorldPop-Daten, ein weltweit verfügbarer fernerkundungsbasierter Bevölkerungsdatensatz in 100 x 100 m Auflösung (Tatem, 2017). Da es in Medellín formelle sowie informelle und semiformelle Verkehrsmittel gibt und diese bislang nicht im Hinblick auf Erreichbarkeit untersucht wurden, wird die Erreichbarkeit zu den verschiedenen Verkehrssystemen separat betrachtet. Im Rahmen der Untersuchung werden weiter die sozialen Implikationen der Erreichbarkeit öffentlicher Verkehrsmittel betrachtet (Saif et al., 2019). Dafür werden die Unterschiede in der Erreichbarkeit unter Berücksichtigung sozioökonomischer Faktoren sowie der Unterscheidung zwischen formellen und informellen Siedlungstypen analysiert.

3.3 Offene Bilddaten und KI-basierte Analyseverfahren für urbanes Mobilitätsmonitoring

3.3.1 Forschungskontext und Zielsetzung

Das Verkehrsaufkommen steigt weltweit aufgrund wachsender Mobilitätsanforderungen, der Zunahme von Autos und Lkw sowie der steigenden Anzahl zurückgelegter Fahrzeugkilometer (Cameron et al., 2004). Eine präzise Datenerfassung und -analyse im Bereich Verkehr sind entscheidend, um verschiedene Mobilitätsherausforderungen zu adressieren, wie etwa die Detektion, Klassifikation und Zählung von Verkehrsteilnehmenden, um Verkehrssysteme besser zu analysieren, zu planen und zu bewerten (Azimjonov und Özmen, 2021; Zhang et al., 2022). Traditionelle Methoden zur Erhebung von Verkehrsdaten, einschließlich manueller Überwachung oder der Installation von Sensoren, sind häufig aufwendig und kostenintensiv. Obwohl kamerabasierte Verkehrsüberwachung mittlerweile verbreitet ist und trotz bedeutender Fortschritte in automatisierten Ansätzen innerhalb der wissenschaftlichen Gemeinschaft (Dubska et al., 2015; Hoxha et al., 2023; Staab et al., 2021), sind manuelle Auswertungen in der Praxis weiterhin gängig (Zhang et al., 2024).

Automatisierte Ansätze haben sich als vielversprechend erwiesen, um Bilddaten aus dem Verkehrsbereich effizient zu analysieren und damit den Bedarf an manueller Auswertung zu reduzieren. Neben „traditionellen“ Computer-Vision-Techniken (Al-qaness et al., 2021; Azimjonov und Özmen, 2021; Zhang et al., 2022) bieten CNNs eine alternative Lösung für die Verkehrs-

überwachung. Im Bereich der CNN-basierten Objekterkennung sind die YOLO (*You Only Look Once*) Modelle aufgrund ihrer geringen Hardwareanforderungen weit verbreitet (Al-qaness et al., 2021; Azimjonov und Özmen, 2021). Als sog. *single stage detectors* identifizieren YOLO-Modelle gleichzeitig Bounding-Boxen und klassifizieren Objekte, was die Geschwindigkeit und Genauigkeit verbessert. Sie erreichen eine hohe Präzision bei gleichzeitig geringer Rechenleistung, was eine Echtzeitauswertung selbst auf Geräten mit begrenzten Hardware-Ressourcen ermöglicht (Kumar et al., 2024). Seit der Einführung von YOLOv1 im Jahr 2015 (Redmon et al., 2016) wurden YOLO-Modelle kontinuierlich weiterentwickelt.

Für die Detektion von Verkehrsteilnehmenden wird in diesem Teil der Dissertation YOLOv8 verwendet, das gegenüber früheren Versionen von YOLO eine höhere Erkennungsgenauigkeit aufweist (Ultralytics, 2025; Huang et al., 2024). Verschiedene Varianten des YOLO-Modells wurden bereits für die Detektion von Verkehrsteilnehmenden in unterschiedlichen Kontexten eingesetzt. So kam YOLOv3 beispielsweise bei der Detektion, Klassifikation und Zählung von Fahrzeugen in Videos zum Einsatz (Al-qaness et al., 2021; Azimjonov und Özmen, 2021). Optimierte YOLO-Modelle wurden zudem auf verschiedene Verkehrsszenarien in China angewendet (Cao et al., 2019; Zhang et al., 2022; Zhu et al., 2021). Auch zur Stauerkennung auf US-amerikanischen Autobahnen wurde YOLOv1 eingesetzt (Chakraborty et al., 2018), während mit YOLOv4 Verkehrsschilder in Taiwan erkannt wurden (Dewi et al., 2021). Mit YOLOv3 wurde Videomaterial ausgewertet, wodurch Verkehrszählungen möglich waren, sowie die Bestimmung von Fahrtrichtung und Geschwindigkeit (Khazukov et al., 2020). Darüber hinaus wurde YOLOv8 durch Fine-Tuning zur Erkennung kleiner Objekte in Verkehrsszenen weiterentwickelt (Khalili und Smyth, 2024), ebenso zur Detektion bewegter Objekte in Videos von Benchmark-Datensätzen (Safaldin et al., 2024). Trotz der kontinuierlichen Weiterentwicklung der YOLO-Modelle gibt es bisher keine Studien, die eine der neuesten YOLO-Versionen in Kombination mit offenen Webcam-Daten zur Zählung von Verkehrsteilnehmenden einsetzen. Darüber hinaus wurde YOLO noch nicht auf offene Webcam-Daten aus Deutschland angewendet, um Verkehrsmuster und -veränderungen über mehrere Monate hinweg zu identifizieren.

Offene Webcam-Daten können dabei wertvolle Einblicke für Verkehrsanalysen und das Verkehrsmonitoring bieten. So wurden beispielsweise mit Webcams in Washington D.C. aktive Verkehrsteilnehmende wie Fußgänger und Radfahrende über einen Zeitraum von etwa 20 Monaten gezählt. Dabei wurden täglich 24 Bilder erfasst und anschließend durch einen crowdsourcing-basierten Ansatz annotiert (Hipp et al., 2015). Zur Schätzung von Fahrzeugdichte und -anzahl kamen sowohl Regressionsmethoden als auch ein Deep-Learning-basierter FCN-Ansatz zum Einsatz (Zhang et al., 2017a). Der Einfluss von Wetter und Lichtverhältnissen auf die Erkennungsgenauigkeit von YOLOv1 für Fahrzeuge und Personen wurde ebenfalls mithilfe öffentlich zugänglicher Videokameras untersucht (Tung et al., 2019). Auch YOLOv8 wurde verwendet, um die Entfernung zwischen Webcams und Fahrzeugen zu schätzen (Aung und Lwin, 2024). Das Potenzial von Webcam-Daten für Verkehrsmodelle wurde darüber hinaus in einer groß

angelegten Studie gezeigt. Diese greift auf öffentliche Webcams an Kreuzungen und Straßen als Datenbasis zurück, um in den Videoaufnahmen Fahrzeugdichten sowie räumliche Mobilitätsmuster in städtischen Umgebungen zu analysieren (Thakur et al., 2012).

Offene Webcam-Daten bieten mehrere Vorteile: Sie sind kostengünstig, Webcams sind bereits installiert und weit verbreitet, wodurch eine potenziell große Datenquelle für das Verkehrsmonitoring zur Verfügung steht. Die Nutzung dieser Art von Daten bringt jedoch erhebliche Herausforderungen mit sich. Dazu gehören nicht standardisierte Bildformate, Variationen in der Bildqualität, eine geringe zeitliche Auflösung mit inkonsistenten Erfassungsraten (die von kontinuierlichem Video bis hin zu Intervallen von mehreren Minuten reichen), sowie Datenausfälle in den Aufnahmen. Darüber hinaus erschweren Umweltfaktoren wie Regen, unterschiedliche Kameraperspektiven mit Weitwinkel, mögliche Überlagerung von Objekten und die Variabilität der Objektgrößen die Analyse weiter (Zhang et al., 2017b). Zudem wirft die Nutzung offener Webcam-Daten Bedenken hinsichtlich des Schutzes personenbezogener Daten und der Privatsphäre auf, insbesondere wenn Aufnahmen analysiert werden, die unbeabsichtigt identifizierbare Personen oder sensible Standorte erfassen können (Du et al., 2019).

Die Analysen in diesem Teil der Doktorarbeit werden in Deutschland durchgeführt, mit einem besonderen Fokus auf Berlin. Der Testzeitraum deckt dabei zwei spezifische Situationen ab: die COVID-19-Pandemie sowie eine normale Situation (vor COVID-19), wodurch Veränderungen der Mobilität in verschiedenen gesellschaftlichen Situationen analysiert werden können. Der erste Nachweis von COVID-19 trat erstmals Ende 2019 auf und entwickelte sich bis März 2020 zu einer Pandemie. Dieses gesellschaftliche Ausnahmeereignis bietet die Grundlage zur Analyse von Mobilitätsveränderungen für diese Auswertung. Die Mobilität wurde während COVID-19 erheblich durch Lockdowns, Reisebeschränkungen und andere Maßnahmen beeinflusst. Studien haben Veränderungen im Mobilitätsverhalten während der Pandemie aufgezeigt, einschließlich einer allgemeinen Reduzierung der Mobilität aufgrund von Lockdowns, einer verstärkten Nutzung nachhaltiger und aktiver Transportmittel (wie Radfahren und Gehen) und Verschiebungen in den Pendelmustern aufgrund von Homeoffice (Ghosh et al., 2020; Liu, 2020; Molloy et al., 2021; Xin et al., 2022). Während des Untersuchungszeitraums beeinflussten hohe Infektionsraten und infolgedessen einschränkende Maßnahmen die Mobilität. In Deutschland durchgeführte Studien konnten eine allgemeine Reduktion der Mobilität, eine Verschiebung von öffentlichem Verkehr hin zur Nutzung von Autos, Gehen und Radfahren sowie Veränderungen der Reisegewohnheiten aufgrund von Lockdowns und Beschränkungen feststellen (Anke et al., 2021; Kolarova et al., 2021; König und Dreßler, 2021).

Die zuständige Behörde betreibt mehrere offizielle und automatische Verkehrszählstationen in Berlin, die hauptsächlich passive Infrarot-Technologie oder Induktionsschleifen verwenden. Diese Stationen bieten in der Regel keine präzise Unterscheidung zwischen den Klassen der Verkehrsteilnehmenden, wobei in der Regel nur zwischen Auto- und Lkw-Objekten unterschieden

werden kann oder separate Zählstationen für Fahrräder verwendet werden. An den ausgewählten Webcam-Standorten oder in deren Nähe sind keine permanenten Verkehrszählstationen installiert (Verkehrsinformationszentrale Berlin, 2023a).

3.3.2 Konzept und Potenzial der Nutzung offener Webcam-Daten für die urbane Verkehrsforschung

Webcams werden häufig von öffentlichen Behörden oder privaten Einrichtungen für Zwecke wie Verkehrsüberwachung, Sicherheit oder Tourismus betrieben, was bedeutet, dass keine zusätzlichen Installationskosten anfallen. Darüber hinaus ermöglicht die räumliche Verteilung der Webcams die Datenerhebung aus verschiedenen städtischen und ländlichen Gebieten, was groß angelegte, standortübergreifende Analysen ermöglicht. Offene Webcam-Daten ermöglichen damit auch longitudinale Studien, da viele Webcams seit Jahren in Betrieb sind und damit auch eine geeignete Datenbasis für Trendanalysen bieten. Diese Zugänglichkeit und Skalierbarkeit machen offene Webcam-Daten zu einer wertvollen Ressource für die Untersuchung von Verkehr mit minimalem finanziellen Aufwand.

Offene Webcam-Daten können aus verschiedenen Quellen stammen (Abbildung 3.1 a). Verkehrsspezifische Webcams, die explizit für die Verkehrsüberwachung installiert wurden, bieten Bilder mit klarem Fokus auf Straßen, Kreuzungen und andere verkehrsrelevante Bereiche. Dadurch wird sichergestellt, dass die relevanten Zielobjekte wie Fahrzeuge, Fahrräder und Fußgänger gut erfasst werden können, mit angemessenen Objektgrößen und guter Sichtbarkeit. Während die Mehrheit solcher Kameras nicht öffentlich übertragen wird, sind einige von Behörden, wie Stadt- und Straßenverwaltungen, öffentlich zugänglich gemacht worden. Diese Webcams decken häufig zentrale städtische Straßen, Kreuzungen, Autobahnen oder Landstraßen ab und bieten wichtige Daten für die Verkehrsanalyse.

Im Gegensatz dazu können auch andere Webcams genutzt werden und wertvolle Einblicke für die Mobilitätsforschung liefern. Dazu zählen Webcams aus dem Bereich Wetterbeobachtung, Tourismus oder Baustellenmonitoring. Diese Kameras erfassen häufig wichtige mobilitätsbezogene Merkmale wie Straßen, Radwege, Fußgängerwege, Eisenbahnlinien oder Verkehrsknotenpunkte (z. B. Flughäfen und Häfen). Beispielsweise können Webcams, die Wahrzeichen, Naturschutzgebiete, zentrale Plätze, Strände, Skigebiete oder Wanderwege zeigen, unbeabsichtigt verkehrsrelevante Elemente in ihren Aufnahmen enthalten. Ebenso können Kameras, die den Baufortschritt für Brücken, Straßen oder größere Infrastrukturprojekte überwachen, den Verkehr rund um diese Standorte erfassen. Diese Arten von Webcams stellen jedoch Herausforderungen für die Mobilitätsanalyse dar. Da ihr primärer Fokus nicht der Verkehr ist, enthält das aufgenommene Bildmaterial oftmals nur einen kleinen Anteil verkehrsrelevanter Bereiche, wie etwa einen Abschnitt einer Straße oder eines Radweges. Dies führt häufig dazu, dass die Objekte unverhältnismäßig klein erscheinen oder sich in weniger prominenten Teilen des Bildausschnitts befinden. Daher mag




Abbildung 3.1: Potenzial offener Webcamdaten. a) Beispielaufnahmen aus offenen Webcams, die verkehrsrelevante Szenen erfassen; b) Karte ausgewählter Webcam-Standorte in Deutschland mit verkehrsrelevanten Bildern (Stiller et al., eingereichtes Manuskript).

dieses Bildmaterial Potenzial für die Verkehrsanalyse bieten, doch seine Nutzbarkeit kann eingeschränkt sein, insbesondere wenn hochauflösende Details für eine präzise Objekterkennung und -klassifikation erforderlich sind.

Trotz seines Potenzials ist die Nutzung offener Webcam-Daten mit erheblichen Herausforderungen verbunden. Zhang et al., 2017b identifizierten vier wesentliche Probleme bei Webcam-Bilddaten: niedrige Bildrate, niedrige Auflösung, starke Überlagerung und große Variabilität der Perspektiven. Aufbauend auf diesen Beobachtungen werden im Folgenden wesentliche technische und umweltbedingte Einschränkungen identifiziert, die die Datenerhebung und -analyse weiter erschweren:

- **Datenqualität und Konsistenz:** Die fehlende Standardisierung der Bildformate und Auflösungen über verschiedene Kameras hinweg erschwert die Integration von Daten aus verschiedenen Webcams und führt zu Inkonsistenzen in der Datenpipeline. Einige Webcams produzieren hochauflösende und klare Bilder, während andere körnige und qualitativ minderwertige Bilddaten liefern, insbesondere ältere oder schlecht gewartete Geräte. Zeitliche Inkonsistenzen wie unterschiedliche Bildraten oder unregelmäßige Erfassungsintervalle, von durchgehenden Videoaufnahmen bis hin zu Aktualisierungen im Minuten- oder Stundenabstand, erschweren die kontinuierliche Zeitreihenanalyse.

- Betriebliche Zuverlässigkeit: Webcams sind anfällig für Ausfälle aufgrund technischer Störungen, Internetverbindungsprobleme oder Abschaltungen durch Betreiber, was die Datenerhebung beeinträchtigt. Diese Unterbrechungen können zu Datenverlust oder der Erfassung von „eingefrorenen“ Bildern führen, bei denen es sich um wiederholte Aufnahmen handelt, die entstehen, wenn der Webcam-Stream nicht aktualisiert wird und dauerhaft die selbe Aufnahme zeigt. Solche Ausfälle können in ihrer Dauer variieren, von Minuten bis zu mehreren Wochen, oder in einigen Fällen dauerhaft werden. Diese Variabilität erschwert die Kontinuität und Konsistenz der Datenaufnahme.
- Umweltfaktoren: Wetterbedingungen wie Regen, Nebel, Schnee oder schlechte Lichtverhältnisse während der Nacht und Dämmerung können die Sichtbarkeit beeinträchtigen und die Zuverlässigkeit von Objekterkennungsalgorithmen verringern (Tung et al., 2019). Ebenso können künstliche Beleuchtung, nasse Straßenoberflächen oder Blendung durch Fahrzeuglichter die Bildqualität weiter verschlechtern.
- Kameraposition und Perspektive: Verschiedene Kamerawinkel und -perspektiven stellen zusätzliche Herausforderungen für die Objekterkennung dar. Kameras, die in großer Höhe oder Entfernung montiert sind, können kleinere Verkehrsteilnehmende wie Fußgänger oder Radfahrer schwer erkennbar machen. Umgekehrt können Kameras in unmittelbarer Nähe in belebten städtischen Gebieten oder an stark frequentierten Kreuzungen Probleme mit Objektüberlappungen und -überlagerungen haben.
- Ethische und rechtliche Bedenken: Die Nutzung von Webcam-Daten für Forschungszwecke führt zu erheblichen ethischen und datenschutzrechtlichen Fragestellungen. Webcams können unbeabsichtigt sensible Orte oder identifizierbare Personen erfassen, was Herausforderungen für den Datenschutz und die Anonymisierung mit sich bringt (Benton et al., 2023). Um diese Bedenken zu adressieren, müssen Forschende allgemeine ethische Prinzipien einhalten (Kochupillai et al., 2022), wie die Minimierung der negativen Auswirkungen, die Sicherstellung der Datensicherheit und die Verarbeitung nur der Daten, die zur Erreichung der Forschungsziele erforderlich sind (Mok et al., 2014). Die Einhaltung breiterer rechtlicher Rahmenwerke, wie der Europäischen Datenschutz-Grundverordnung (DSGVO), ist unerlässlich, um die Privatsphäre zu schützen und eine verantwortungsvolle Nutzung von Daten sicherzustellen (Benton et al., 2023).

In Deutschland wurden bis Ende 2023 etwa 250 öffentlich zugängliche Webcams im Bereich der Mobilität identifiziert (Abbildung 3.1 b). Diese umfassen Kameras, die innerstädtische Bereiche, Straßen oder Kreuzungen erfassen. Diese Sammlung ist jedoch nicht vollständig und dient vielmehr als Illustration für die Abdeckung und das Potenzial von Webcams für die Verkehrsforschung. Die Mehrheit dieser Webcams erfasst Standbilder anstelle von Videoaufnahmen. Autobahn-Webcams sind aus diesem Datensatz ausgeschlossen. Seit März 2022 wurde die öffentliche Übertragung von Autobahnkameras in Deutschland aufgrund von Sicherheitsbedenken im Zusammenhang mit der aktuellen geopolitischen Lage eingestellt (Balser, 2022). Dieses Beispiel verdeutlicht, wie

geopolitische Faktoren die Verfügbarkeit und Anwendung von Webcam-Daten in bestimmten Kontexten beeinflussen können. In Deutschland wird die rechtliche Landschaft für die Nutzung von Webcam-Daten durch strenge Datenschutzbestimmungen geprägt, einschließlich der DSGVO, des Bundesdatenschutzgesetzes (BDSG) und des Kunsturhebergesetzes (KUG). Diese Rahmenwerke setzen klare Grenzen für die rechtmäßige Verarbeitung personenbezogener Daten und verlangen Maßnahmen wie Anonymisierung und Verpixelung zum Schutz der Rechte von Individuen.

Untersuchungsgebiete und Daten

Zur Beantwortung der Forschungsfragen dieser Arbeit werden verschiedene urbane Untersuchungsgebiete analysiert und verschiedene Datengrundlagen herangezogen. Dieses Kapitel stellt die ausgewählten Untersuchungsräume vor (Abschnitt 4.1) und beschreibt die verwendeten Datenquellen (Abschnitt 4.2).

4.1 Untersuchungsgebiete

Als Untersuchungsgebiete wurden drei Städte mit unterschiedlichen geographischen, sozioökonomischen und infrastrukturellen Kontexten ausgewählt: Santiago de Chile, Medellín und Berlin. Im Folgenden werden die drei Untersuchungsgebiete näher vorgestellt.

4.1.1 Santiago de Chile, Chile

Santiago de Chile ist die Hauptstadt und die bevölkerungsreichste Metropolregion Chiles. Die Bevölkerung des urbanen Gebiets von Santiago („Área Urbana“) beträgt 5,2 Millionen Einwohner, während die gesamte Agglomeration („Metropolitana de Santiago“) eine Bevölkerung von 7,1 Millionen umfasst (Instituto Nacional de Estadísticas Chile, 2017). Somit lebt fast die Hälfte der chilenischen Bevölkerung in Santiago de Chile oder in dessen unmittelbarer Umgebung. Zudem stellt die Stadt das wirtschaftliche und politische Zentrum sowie den wichtigsten Verkehrsknotenpunkt des Landes dar. Die urbane Struktur ist komplex und umfasst Wohngebiete, Gated Communities, Freizeiteinrichtungen sowie Bürogebäude (Bähr und Meyer-Kriesten, 2007). Das Studiengebiet umfasst den größten Teil des städtischen Kerns namens Gran Santiago mit 4,9 Millionen Einwohnern und bei einer Fläche von 591 km² mit einer Bevölkerungsdichte von 8.282 Einwohnern pro km² (Abbildung 4.1). Santiago de Chile wurde als Studiengebiet gewählt, da hier relevante Daten zum Testen und Validieren des vorgeschlagenen Ansatzes zur Verfügung standen. Darüber hinaus hat das Stadtgebiet von Santiago in den letzten Jahrzehnten eine bemerkenswerte Expansion erlebt und wird voraussichtlich noch weiterwachsen (Puertas et al., 2014). Santiago hat im Vergleich zu seiner wirtschaftlichen Entwicklung einen relativ niedrigen Motorisierungsgrad. Dennoch hat die Stadt mit einer erheblichen Luftverschmutzung zu kämpfen, insbesondere mit Feinstaub und Stickoxiden, wobei der Verkehr für 56 % bzw. 87 % der Emissionen verantwortlich ist (Zegras, 2010). Um dem entgegenzuwirken, haben die Behörden seit 1986 eine dauerhafte Beschränkung eingeführt, die bei hoher Schadstoffbelastung die Zufahrt von Fahrzeugen ohne

Katalysator entsprechend dem Kennzeichen verbietet (Grange und Troncoso, 2011). Diese Maßnahmen wurden in der Folgezeit ausgeweitet und eine Minderung der Luftverschmutzung konnte nur durch die Einführung eines Fahrverbots für alle Fahrzeuge mit Katalysatoren an Tagen mit hoher Schadstoffbelastung erzielt werden (Grange und Troncoso, 2011).




Abbildung 4.1: Lage des Studiengebiets Santiago de Chile. Links: Chile und die Region Metropolitana; rechts: die Region Metropolitana mit der administrativen Grenze von Gran Santiago inkl. Studiengebiet (Stiller et al., 2021).

4.1.2 Medellín, Kolumbien

Medellín ist nach Bogotá die zweitbevölkerungsreichste Metropolregion Kolumbiens mit etwa 4,2 Millionen Einwohnern. Von den zuständigen Behörden wurden frühzeitig Maßnahmen zur Entwicklung und zum Ausbau des öffentlichen Verkehrs ergriffen und die erste U-Bahnlinie wurde bereits 1991 eingeweiht (Metro de Medellín, 2021). Seitdem wurden erhebliche Erweiterungen des öffentlichen Verkehrssystems vorgenommen, wobei nicht nur zusätzliche Buslinien eingeführt wurden, sondern auch weitere U-Bahnlinien sowie mehrere Seilbahnlinien (Metro de Medellín, 2021). Die erste Seilbahnlinie in Medellín wurde im Jahr 2004 errichtet und verbindet informelle Gebiete im Nordosten mit der bereits bestehenden Nord-Süd-Metro-Bahnlinie (Goodship, 2015). Solch komplexe öffentliche Verkehrsinfrastrukturen sind in Städten Lateinamerikas selten zu finden. Im Gegensatz zu Medellín ist die kolumbianische Hauptstadt Bogotá mit über 10 Millionen Einwohnern in ihrer Metropolregion ausschließlich auf ein straßengebundenes BRT-System angewiesen (Rodriguez et al., 2017). Aufgrund der frühzeitigen Einführung und der stetigen Erweiterung des öffentlichen Verkehrssystems bietet Medellín daher eine ideale Grundlage, um als Untersuchungsgebiet zu dienen.

Das betrachtete Untersuchungsgebiet 1 (engl. *Region of Interest 1*, ROI 1) umfasst einen großen Teil der Gemeinde Medellín mit einer Fläche von etwa 96 km² (Abbildung 4.2 a). Es besteht aus insgesamt 200 administrativen Einheiten, sogenannten Sektoren (span. *sectores*), mit fast 1,8 Millionen Einwohnern laut Zensusdaten von 2018. Das ROI 1 wurde auf Basis

der gemeinsamen Abdeckung der drei in dieser Untersuchung verwendeten und verglichenen Bevölkerungsdatensätze ausgewählt. Das Gelände innerhalb dieses Untersuchungsgebiets ist sehr heterogen, da sich die Stadt Medellín im *Aburrá*-Tal befindet, das auf beiden Seiten von Bergen umgeben ist (Abbildung 4.2 b). Für die Analysen wurde ein erweitertes Untersuchungsgebiet (ROI 2) verwendet, das die gesamte Stadt Medellín umfasst. Hierfür liegen sowohl sozioökonomische Daten als auch Gebietsgrenzen der informellen Siedlungen vor.




Abbildung 4.2: Lage des Studiengebiets Medellín mit Überblick über die Untersuchungsgebiete. a) ROIs in Medellín: ROI 1 (blau) und ROI 2 (orange); b) Lage von Medellín (Stiller et al., 2025).

4.1.3 Berlin, Deutschland

Berlin ist mit 3,7 Millionen Einwohnern im Kerngebiet und 6,2 Millionen in der Metropolregion Deutschlands bevölkerungsreichste Stadt (Amt für Statistik Berlin-Brandenburg, 2023, 2024). Die urbane Struktur Berlins ist vielschichtig und geprägt durch eine Mischung aus dichten innerstädtischen Wohnquartieren, weitläufigen Plattenbausiedlungen, historischen Stadtvierteln, Bürostandorten, Grünflächen und Infrastruktureinrichtungen (Elkins und Hofmeister, 2005). Berlin führt meist das Ranking der deutschen Städte mit den größten Stau Problemen an. Im Jahr 2022 standen Autofahrer dort insgesamt 71 Stunden im Stau (INRIX, 2023). Der Modal Split in Berlin für alle zurückgelegten Wege beträgt: 18 % Fahrrad, 26 % motorisierter Individualverkehr, 27 % öffentlicher Nahverkehr und 30 % zu Fuß (Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin, 2018).

4.2 Daten

4.2.1 Daten für die großflächige Gebäudeextraktion

Die Gebäudeextraktion und die Erstellung des 3D-Stadtmodells wird am Beispiel Santiago de Chile entwickelt und auf die Stadt Medellín übertragen. Für Santiago de Chile wird für die Gebäudeextraktion ein hochauflösendes RGB-Luftbild-Orthophotomosaik von Gran Santiago genutzt,

das online über das offizielle Geoportal von Chile verfügbar ist (Abbildung 4.3 a; verfügbar online bei Infraestructura de Datos Geoespeciales Chile, 2019). Die geometrische Auflösung beträgt 0.35 m, und die Aufnahme stammt von Januar 2014. Die gebirgsartigen Regionen, in denen sich keine Gebäude befinden, wurden in dem Mosaik ausmaskiert. Dadurch ergibt sich eine Untersuchungsregion mit einer Gesamtfläche von etwa 700 km². Da für Medellín keine hochauflösenden Luftbilddaten für die Gebäudedetektion verfügbar waren, kamen Satellitenbilder des WorldView-Satelliten zum Einsatz. Die verwendeten Aufnahmen stammen von Januar 2020 für West- und Zentral-Medellín und von Juni 2018 für Ost-Medellín. Diese verfügen über eine geometrische Auflösung von 1.2 m für die multispektralen Bänder und 0.3 m für das panchromatische Band. Mithilfe von Pan-sharpening wurden die multispektralen Bänder mit dem panchromatischen Band kombiniert, um ein hochauflösendes RGB-Bild mit einer Bodenauflösung von 0.3 m zu erzeugen.




Abbildung 4.3: Studiengebiet Santiago de Chile mit a) den verwendeten Luftbildern sowie die Standorte der Referenzdaten; c) Referenzdaten aus Gebiet 1 (area 1) mit einer Fläche von 3.28 km² werden für das Training und die Validierung genutzt, während die Referenzdaten aus b) Gebiet 2 (area 2) mit einer Fläche von 0.27 km² für Testzwecke herangezogen werden (Stiller et al., 2019b).

Für Santiago de Chile wurden Ground-Truth-Daten für zwei semantische Klassen manuell erstellt, „Gebäude“ und „Hintergrund“, wobei unklare Fälle visuell mit hochauflösendem, dreidimensionalem Google-Earth-Bildmaterial verglichen wurden (Abbildung 4.3 b und c). Eine manuelle Abgrenzung ist erforderlich, da für das Untersuchungsgebiet keine vollständigen und genauen Referenzdaten, z. B. über OSM, verfügbar sind (Abbildung 4.4). Diese Daten werden

für das Training, die Validierung sowie für Testzwecke benötigt, wobei die Testdaten in einem unabhängigen Stadtgebiet von Santiago erstellt werden (Gebiet 2 in Abbildung 4.3 b). Durch diesen Ansatz wird sichergestellt, dass das trainierte Modell zuverlässig auf neue Daten angewendet werden kann, die nicht für das Training und die Validierung des Modells genutzt wurden.



Abbildung 4.4: Exemplarischer Ausschnitt der OSM Gebäudeabdeckung in Santiago de Chile. Es ist deutlich erkennbar, dass vor allem im mittleren und unteren Bildbereich sehr viele Gebäude fehlen.

4.2.2 Daten für die Anreicherung der Gebäudegrundrisse

DOM und nDOM

Um Höheninformationen zu den vorhandenen 2D-Gebäudegrundrissen hinzuzufügen und so 3D-Objekte zu erhalten, können z. B. Stereo- oder Tri-Stereo-Daten verwendet werden. Bei der Verwendung von Stereobildern sind Boden und Straßen in dicht bebauten Gebieten oft verdeckt. Tri-Stereo-Bilder werden aus drei Perspektiven aufgenommen, wodurch diese ungesehenen Bereiche reduziert werden und die erhöhte Redundanz zu einer verbesserten Höhengenaugkeit führt. Normalerweise werden Tri-Stereo-Daten im Submeterbereich verwendet, um digitale Höhenmodelle in dicht bebauten städtischen Gebieten zu erstellen. Aufgrund der Größe des Untersuchungsgebiets in Santiago wurde jedoch auf panchromatische Tri-Stereo-Bilder aus dem Jahr 2014 mit einer geometrischen Auflösung von 2 m zurückgegriffen, die vom SPOT-7-Satelliten aufgenommen wurden und eine Fläche von etwa 1.300 km² über Gran Santiago abdecken (Abbildung 4.5 a). Auf Basis der SPOT-7-Daten wurde ein DOM nach einem vollautomatischen Ansatz für optische Satellitenbilder erstellt (d'Angelo und Reinartz, 2011; Krauß, 2014). Zur Verbesserung

der räumlichen Übereinstimmung der Multisensordaten wurden die SPOT-7-Daten mit der Lage des Orthophotomosaiks ko-registriert. Für die Generierung eines nDOM, das ausschließlich oberirdische Informationen enthält, wurde der Ansatz von Perko et al., 2015 verwendet. Nach diesem Verfahren wurde ebenfalls für Medellín ein stadtweites DOM sowie ein nDOM auf Basis der verfügbaren WorldView-Daten erstellt.

Um das stadtweite nDOM von SPOT-7 zu validieren, wurden DOM-Daten mit einem Pixelabstand von 0.12 m verwendet, die aus „VHR-DSM“ des DLR MACS (Lehmann et al., 2011) abgeleitet und mit einem Algorithmus für sehr hoch aufgelöste Satellitenbilddaten (Piltz et al., 2016) verarbeitet wurden. Die luftgestützten sehr hoch aufgelösten Daten decken einen Streifen im Nordosten Santiagos mit einer Gesamtfläche von etwa 17.6 km² ab (Abbildung 4.5 b).




Abbildung 4.5: Übersicht der verwendeten Daten für Santiago de Chile. a) Nadir-Multispektraldaten von SPOT-7; b) Lage der sehr hoch aufgelösten DOM-Daten; c) OSM-Landnutzungspolygone; d) OSM-POIs (Stiller et al., 2021).

Gebäudegeschosse aus Google Street View-Daten

Die Anzahl der Stockwerke pro Gebäude ist ein wichtiger Faktor der städtischen Raumstruktur und dient als eine der Eingangsvariablen für das Verfahren zur Bevölkerungsabschätzung. Um die Anzahl der Stockwerke pro Gebäude zu ermitteln, wurde eine Regressionsanalyse durchgeführt, um die Stockwerke in Abhängigkeit von der Gebäudehöhe zu schätzen (Wurm et al., 2019a). Daher wurde eine Stichprobe mit 100 Gebäuden verschiedenster Höhen aus dem Datensatz der Gebäudegrundrisse aus Santiago de Chile gezogen. Für diese 100 Gebäude wurden Google Street View-Bilder manuell inspiziert, um die Anzahl der Stockwerke für jedes dieser Gebäude zu ermitteln.

OSM-Daten: Landnutzungspolygone und POIs

Die OSM-Initiative stellt kostenfrei Geodaten zur Verfügung (OpenStreetMap contributors, 2025), die in dieser Arbeit für die Ableitung von Landnutzungsinformationen auf der Ebene einzelner Gebäude verwendet wurden. Zu diesem Zweck wurden zwei der verschiedenen von OSM bereitgestellten Datensätze akquiriert: Landnutzungspolygone und POIs (Abbildung 4.5 c und d). Die Landnutzungspolygone enthalten 17 Landnutzungskategorien für das Untersuchungsgebiet, z. B. Wohnen, Gewerbe, Militär, Park und Industrie. Die POIs umfassen insgesamt 114 sehr unterschiedliche Kategorien, z. B. Café, Hotel, medizinische Einrichtungen, Geschäfte, Schule, usw. Um einige Fehlklassifizierungen innerhalb des Gebäudedatensatzes zu beseitigen, wurden weiterhin zusätzliche OSM-Daten verwendet: OSM-Straßen und OSM-Wasserlinien.

Zensusdaten

Die verwendeten Zensusdaten für Santiago stammen aus dem Jahr 2017 des nationalen Statistikinstituts Chiles (Instituto Nacional de Estadísticas Chile, 2017), die die Bevölkerungszahlen in zwei unterschiedlichen Raumeinheiten enthalten, auf der administrativen Ebene von Stadtblöcken (span. *manzanas*; vergleichbar mit der Gebäudeblockebene) und der Bezirke (span. *distritos*) (Tabelle 4.1). Die Daten wurden verwendet, um 1) die Bevölkerungszahlen der kleinen Einheiten zu summieren, um die Gesamtbevölkerung für das Studiengebiet zu ermitteln, und 2) um die Genauigkeit verschiedener Ansätze zur Schätzung der Bevölkerung auf Gebäudeebene zu validieren. Der Ansatz mit der höchsten Genauigkeit wurde auch für die Bevölkerungsdisaggregation für Medellín verwendet. Dazu wurde eine Gesamtbevölkerungszahl basierend auf den Zensusdaten von 2018 verwendet (Departamento Administrativo Nacional de Estadística (DANE), 2018).

4.2.3 Daten für die Berechnung der Erreichbarkeit öffentlicher Verkehrsmittel

Bevölkerungsdaten

In den Analysen werden drei verschiedene Arten von Bevölkerungsdatensätzen verglichen, um den Einfluss auf die Erreichbarkeit zu bewerten. Diese Datensätze repräsentieren unterschiedliche Detailgrade räumlicher Granularität (Abbildung 4.6; Tabelle 4.2). Durch diesen Vergleich können

Tabelle 4.1: Merkmale der Zensusdaten 2017 von INE (span. *Instituto Nacional de Estadísticas Chile*, nationales Statistikinstitut Chile) (nach Stiller et al., 2021).

	Baublockebene	Bezirke
<i>Gesamtzahl der Einheiten</i>	34.507	297
<i>Mittlere Größe (m²)</i>	14.666m ² (ca. 120×120m)	2.524.978m ² (ca. 1.600×1.600m)
<i>Grundfläche (m²), min-max</i>	227–4.225.893m ²	376.571–39.845.877m ²
<i>Mittlere Einwohnerzahl</i>	148	16.458

zwei wesentliche Aspekte beurteilt werden: Erstens, ob auf Fernerkundung basierte Datensätze eine wertvolle Alternative zu offiziellen Zensusdaten in datenarmen Regionen darstellen können, und zweitens, inwieweit globale Datensätze wie WorldPop trotz ihrer inhärenten Einschränkungen in der Lage sind, Erreichbarkeiten in unterschiedlichen städtischen Umgebungen näherungsweise darzustellen.

Zunächst wurden vektorbasierte Bevölkerungsdaten auf Gebäudeebene verwendet, die auf Zensusdaten, Landnutzung und Katastergebäuden basieren (Sapena et al., 2022). Die Bevölkerung pro Gebäude wurde durch eine Top-down-Disaggregierungsmethode berechnet, bei der offizielle Zensusdaten, die Anzahl der Stockwerke pro Gebäude und offizielle Landnutzungsinformationen einbezogen wurden (Sapena et al., 2022). Dieser Datensatz kann als sehr genauer Bevölkerungsdatensatz angesehen werden (Datensatz 1). Zweitens wurde der hochdetaillierte, vektorbasierte Bevölkerungsdatensatz verwendet, basierend auf Fernerkundungsdaten und offenen Geodaten (Datensatz 2 (Stiller et al., 2021), verwendete Daten vorgestellt in Abschnitt 4.2.2, verwendete Methoden vorgestellt in Abschnitt 5.2). Drittens wurde der weltweit verfügbare WorldPop-Bevölkerungsdatensatz verwendet (Tatem, 2017), für das Jahr 2020 in Kolumbien (Bondarenko et al., 2020), der als Raster mit einer Gitterweite von etwa 100×100m verfügbar ist (Datensatz 3).

Daten zu ÖV-Haltestellen

Es wurden Daten zu ÖV-Haltestellen aus verschiedenen Quellen verwendet, die sowohl Haltestellen von Verkehrsmitteln mit geringer, als auch mit hoher Kapazität beinhalten (Abbildung 4.7). Wie bereits erwähnt, sind GTFS-Daten eine der Hauptquellen zur Erfassung der Standorte von ÖV-Haltestellen. Allerdings veröffentlichen nur 2.45 % der lateinamerikanischen Verkehrsunternehmen ihre Informationen zu öffentlichen Verkehrsmitteln als GTFS-Datensätze (Bok und Kwon, 2016).

Um die Standorte formeller Verkehrsmittel zu erhalten, wurden freiverfügbare GTFS-Daten für Medellín genutzt (Laar, 2020), wobei redundante und irrelevante Datenpunkte entfernt wurden. Zusätzlich wurden diese Daten mit Informationen der lokalen Verkehrsbehörde *Metro de Medellín*




Abbildung 4.6: Visualisierung der verwendeten Bevölkerungsdatensätze. a) Bevölkerungsdatensatz 1: disaggregierte Bevölkerungsdaten aus dem Zensus pro Katastergebäude; b) Bevölkerungsdatensatz 2: Bevölkerung pro Gebäude abgeleitet aus Fernerkundungsdaten; c) Bevölkerungsdatensatz 3: WorldPop Rasterdaten (100x100m) (Stiller et al., 2025).

Tabelle 4.2: Überblick über die verwendeten Bevölkerungsdatensätze für die Erreichbarkeitsanalysen in Medellín. Alle drei Bevölkerungsdatensätze sind für ROI 1 verfügbar, während Datensatz 2 nicht für das erweiterte Untersuchungsgebiet ROI 2 vorliegt (nach Stiller et al., 2025).

	Datensatz 1	Datensatz 2	Datensatz 3
Quelle	Sapena et al., 2022	Stiller et al., 2021 (vgl. Abschnitt 4.2.2 und 5.2)	Bondarenko et al., 2020; Tatem, 2017
Bevölkerung innerhalb ROI 1	1.770.534	1.762.586	2.441.854
Beschreibung	Bevölkerungsdaten auf Gebäudeebene, erstellt durch Nutzung von Katastergebäuden und Zensusdaten	Bevölkerungsdaten auf Gebäudeebene, erstellt durch Nutzung von Fernerkundung und offenen Daten	Globale Bevölkerungsdaten mit 100x100m Rasterzellengröße

angereichert (Metro de Medellín, 2021), indem 31 neue U-Bahn-Stationen integriert wurden, die nach den zuletzt verfügbaren GTFS-Daten von 2016 bis zum Jahr 2021 zusätzlich installiert wurden. Dabei wurde die Erweiterung des U-Bahn-Netzes durch die Ergänzung der neuen Linie M (Februar 2019), Linie O (November 2019) und Linie P (Juni 2021) berücksichtigt. Für eine umfassende Analyse der Auswirkungen dieser neu installierten U-Bahnlinien wurden daher zwei Datensätze zu U-Bahnstandorten verwendet: U-Bahn-Stationen für 2016 und U-Bahn-Stationen für 2021. Daten zu Minibus-Haltestellen, die einen wesentlichen Anteil der ÖV-Haltestellen ausmachen, wurden von den lokalen Behörden in Medellín bezogen.




Abbildung 4.7: Standorte der verschiedenen Verkehrshaltestellen in Medellín für U-Bahn (links), Bus (mittig) und semiformalen Minibus (rechts). Die Anzahl der Haltestellen pro Typ ist in Klammern angegeben (Stiller et al., 2025).

Sozioökonomische Daten

Um den Einfluss sozioökonomischer Faktoren auf die Erreichbarkeit öffentlicher Verkehrsmittel zu untersuchen, wurden sozioökonomische Daten für das erweiterte ROI2 verwendet, wie in Abbildung 4.8 dargestellt. Die sozioökonomischen Daten stammen aus dem Zensus von Medellín aus dem Jahr 2018 (Departamento Administrativo Nacional de Estadística (DANE), 2018). Diese Daten umfassen Informationen über die Anzahl der Haushalte in jedem Sektor, die jeweils einer von sechs sozioökonomischen Gruppen zugeordnet sind („*estrato socioeconómico*“). Diese Kategorien reichen von 1 („*sehr niedrig*“ oder „*sehr arm*“) bis 6 („*sehr hoch*“ oder „*sehr reich*“).

Zur Ableitung eines sozioökonomischen Indexes für jeden Sektor wurde der Mittelwert anhand der Anzahl der Haushalte in den spezifischen sozioökonomischen Gruppen berechnet (Abbildung 4.8 a). Dadurch erfolgte eine Klassifizierung der Sektoren in fünf sozioökonomische Gruppen, die jeweils durch einen bestimmten sozioökonomischen Index repräsentiert sind: Gruppe 1 („*sehr*

„niedrig“ mit einem Index <2), Gruppe 2 („niedrig“ mit einem Index von 2-3), Gruppe 3 („mittel“ mit einem Index von 3-4), Gruppe 4 („hoch“ mit einem Index von 4-5), und Gruppe 5 („sehr hoch“ mit einem Index von 5-6).




Abbildung 4.8: Erweitertes Untersuchungsgebiet ROI 2 für sozioökonomische Analysen. a) Sozioökonomische Daten pro Sektor; b) Lage der informellen Siedlungen; c) Anteil der informellen Siedlungen pro Sektor. Der sozioökonomische Index reicht von 1 ('sehr niedrig/arm') bis 6 ('sehr hoch/reich'), und der Prozentsatz der Informalität gibt den Anteil der Sektorfläche an, der von informellen Siedlungen bedeckt ist (Stiller et al., 2025).

Daten zu informellen Siedlungen

Die Standorte der informellen Siedlungen im erweiterten ROI2 von Medellín sind in Abbildung 4.8 b dargestellt. Diese informellen Siedlungen befinden sich in Medellín häufig in steilen Gebieten am Stadtrand, was sie einem höheren Risiko von Erdbeben aussetzt (Wurm et al., 2023). Die Daten zu informellen Siedlungen stammen aus dem Flächennutzungs- und Bebauungsplan 2014, *Plan de Ordenamiento Territorial* (POT), der von der Stadt Medellín veröffentlicht wurde (City of Medellín, 2014).

Innerhalb dieses Datensatzes wurden zwei Kategorien als informelle Siedlungen ausgewählt, *Comprehensive Improvement* (*Mejoramiento Integral*, MI) und Consolidation Level3 (*Consolidación Nivel3*, CN3), basierend auf der Klassifizierung durch die Stadtverwaltung, die diesen Siedlungstyp als prekär kategorisiert (Instituto Social de Vivienda y Hábitat de Medellín, 2019). Diese Einstufung wurde auch von Kühnl et al., 2021 verwendet. Die Sektoren wurden auf der Grundlage des Anteils informeller Siedlungen in fünf Klassen eingeteilt und zusätzlich in formell oder informell klassifiziert, wobei informelle Sektoren mindestens 2 % informeller Siedlungen beinhalten müssen. Diese Kategorien wurden verwendet, um den Zusammenhang zwischen dem Anteil an Informalität innerhalb der Sektoren und der Gehdistanz zur nächstgelegenen ÖV-Haltestelle zu untersuchen, sowie die Entfernungen in formellen und informellen Sektoren zu vergleichen (Abbildung 4.8 c):

- 2 % Abdeckung durch informelle Siedlungen: als formell betrachtet
- 2 % bis 25 % Abdeckung durch informelle Siedlungen: kaum informell
- 25 % bis 50 % Abdeckung durch informelle Siedlungen: mäßig informell
- 50 % bis 75 % Abdeckung durch informelle Siedlungen: größtenteils informell

- 75 % Abdeckung durch informelle Siedlungen: stark informell

4.2.4 Webcam-Bilddaten für die Verkehrszählung

Für die Analysen wurden Webcam-Bilder verwendet, die reale Verkehrsszenen im städtischen Kontext darstellen. Um Datenschutzbedenken zu entgegnen, wird die Einhaltung der DSGVO und verwandter Vorschriften sichergestellt, indem wichtige Prinzipien beachtet werden, wie das Sammeln nur der für die Forschungsziele notwendigen Daten. Zudem wurden sensible Bereiche in den Bildausschnitten bereits anonymisiert. Beispielsweise sind in den gesammelten Bildern Kennzeichen nicht lesbar, und größere sensible Bereiche wie Wohngebäude sind verpixelt und damit unkenntlich gemacht.

Tabelle 4.3 bietet einen Überblick über die vier vorbereiteten Datensätze. Insgesamt wurden 16 Webcams für die 110 Parameter-Experimente verwendet, und ein Subset von 10 Webcams wurde für die COVID-19-Fallstudie genutzt. Die Webcams weisen eine Aktualisierungsfrequenz von einem Bild pro Minute und eine Bildauflösung von 640×480 Pixel auf.

Tabelle 4.3: Überblick über die verwendeten Datensätze der offenen Webcam-Bilddaten (nach *Stiller et al.*, eingereichtes Manuskript).

	Beschreibung	Anzahl der ausgewählten Webcams	(ca.) Anzahl der Bilder
<i>Roh-datensatz</i>	Die Gesamtheit der Bilddaten, die von allen Webcams ohne Filterung oder Vorverarbeitung erfasst wurden	16	4,63 mio.
<i>Basis-datensatz</i>	Eine verfeinerte Version des Rohdatensatzes, die nur Tageszeitaufnahmen enthält. Fehlerhafte und unvollständige Bilddateien wurden entfernt und Bereiche wie Parkplätze und weit entfernte Straßenabschnitte durch Zuschneiden maskiert	16	1,96 mio.
<i>Referenz-datensatz</i>	Ein Subset von Bildern (drei zufällig ausgewählte Bilder pro Webcam) aus dem Basisdatensatz. Relevante Verkehrsobjekte wurden in diesen Bildern manuell markiert, um als Referenz für die Analyse zu dienen	16	48
<i>Fallstudien-Datensatz</i>	Ein Subset des Basisdatensatzes, das ausschließlich Bilder von Webcams in Berlin enthält. Es deckt den Zeitraum vom 31. Oktober bis 18. Dezember in den Jahren 2018 (pre-COVID-19) und 2020 (während COVID-19) ab	10	493.000

Der **Rohdatensatz** umfasst 4,63 Millionen Bilder, die von 16 Webcams in drei Städten in Deutschland gesammelt wurden: 12 Kameras in Berlin, 2 in Nürnberg und 2 in Ulm (Abbildung 4.9).



Abbildung 4.9: Beispielbilder der 16 verwendeten Webcams aus Berlin. Hervorgehobene Kameras wurden für die COVID-19-Fallstudie genutzt (Stiller et al., eingereichtes Manuskript).

Der **Basisdatensatz** wurde durch Filtern und Zuschneiden aus dem Rohdatensatz abgeleitet, wodurch ein Datensatz mit 1,96 Millionen Bildern entstand. Die Filterung erfolgte durch die Auswahl von ausschließlich tagsüber aufgenommenen Szenen, basierend auf den genauen Sonnenauf- und -untergangszeiten für jeden Webcam-Standort (sunrise-and-sunset.com, 2023). Zudem wurden beschädigte Bilddateien, darunter Standbilder, leere Dateien und schwarze Bilddaten, automatisch identifiziert und entfernt. Die vorselektierten Bilder wurden anschließend weiterverarbeitet, indem Masken zur Ausblendung von Bereichen wie Parkplätzen und weit entfernten Straßenabschnitten angewendet wurden, da dort eine präzise Identifikation von Verkehrsteilnehmenden nicht mehr möglich ist.

Der **Referenzdatensatz** wurde erstellt, um die optimalen Parameter für die Anwendung von YOLOv8 mithilfe einer Grid-Search-Analyse zu bestimmen (getestete Parameter: Confidence und Intersection over Union (IoU)). Er umfasst 48 Bilder, wobei jeweils drei zufällig ausgewählte Bilder pro Webcam aus dem Basisdatensatz stammen. Die Verkehrsteilnehmenden in diesen Szenen wurden manuell gemäß der verkehrsbezogenen Objektkategorien des COCO-Datensatzes (Lin et al., 2014) annotiert, konkret: Auto, Lkw, Motorrad, Bus, Fahrrad und Person. Insgesamt wurden 662 Verkehrsobjekte in diesem Datensatz markiert. Allerdings besteht eine deutliche

Klassenungleichheit innerhalb des Datensatzes: Die Klasse „Auto“ ($n=507$) dominiert die Annotationen, gefolgt von „Lkw“ ($n=80$) und „Person“ ($n=45$), während Kategorien wie „Bus“ ($n=12$), „Fahrrad“ ($n=11$) und „Motorrad“ ($n=7$) nur in geringer Anzahl vorkommen.

Der **Fallstudien-Datensatz**, der zur Untersuchung der Auswirkungen von COVID-19 auf die Anzahl der Verkehrsteilnehmenden verwendet wurde, umfasst 493.000 Bilder, die aus dem Basisdatensatz stammen. Dieser Datensatz umfasst ausschließlich die Berliner Webcams, da nur für diese innerhalb der Datensätze Beobachtungen aus der Zeit vor COVID-19 aus dem Jahr 2018 verfügbar sind. Von den zwölf Berliner Webcams wurden lediglich zehn in die Fallstudienanalyse einbezogen, da zwei Kameras während des Studienzeitraums 2018 erhebliche Datenlücken aufwiesen. Die Bilddaten erstrecken sich vom 31. Oktober bis zum 18. Dezember für die Jahre 2018 (pre-COVID) und 2020 (während COVID) und decken somit einen identischen siebenwöchigen Zeitraum (49 Tage) mit derselben Anzahl an Werktagen (35 Tage) in beiden Zeiträumen ab. Im Jahr 2020 war dieser Zeitraum durch einen starken Anstieg der COVID-19-Infektionszahlen in Berlin gekennzeichnet, mit einer hohen Inzidenz (Abbildung 4.10). Infolgedessen wurden strengere Maßnahmen zum Infektionsschutz umgesetzt. Ab dem 2. November wurden gastronomische und kulturelle Einrichtungen zur Schließung verpflichtet. Ab dem 26. November wurden Zusammenkünfte auf maximal fünf Personen aus zwei Haushalten begrenzt und die Maskenpflicht wurde ausgeweitet. Ab dem 16. Dezember mussten zudem Einzelhandelsgeschäfte und Schulen schließen (Betschka et al., 2021).




Abbildung 4.10: Entwicklung der gemeldeten COVID-19-Fälle in Berlin im Fallstudienzeitraum von März 2020 bis Februar 2021, der Untersuchungszeitraum ist vorgehoben (adaptiert von Landesamt für Gesundheit und Soziales Berlin, 2021) (Stiller et al., eingereichtes Manuskript).

Die ausgewählten Berliner Webcams sind entlang der folgenden Straßen positioniert: Fünf Webcams befinden sich an der Heerstraße, vier am Messedamm und eine im Bezirk Alt-Moabit. Diese Standorte weisen unterschiedliche Klassifikationsstufen im Straßennetz sowie unterschiedli-

che Geschwindigkeitsbegrenzungen auf (Tabelle 4.4). Die Auswahl beschränkt sich jedoch auf die Klassifikationsstufen 1, 2 und 3, da für Stufe 0 (Autobahnen) und Stufe 4 (lokale Straßen) keine öffentlich zugänglichen Webcams verfügbar waren.

Tabelle 4.4: Übersicht der zehn ausgewählten Webcams in Berlin entlang der Straßen Heerstraße, Messedamm und Alt-Moabit mit der RIN-Straßennetzklassifikation (Richtlinien für integrierte Netzgestaltung; Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin, 2023) (nach *Stiller et al.*, eingereichtes Manuskript).

<i>Straße, Anzahl der Webcams</i>	RIN-Straßennetz- klassifikation mit Stufen 0 bis 4	Beschreibung	Geschwindigkeits- begrenzung (km/h)
<i>Heerstraße, 5 Webcams</i>	Stufe 1: Großräumige Verbindungen	Teil der Bundesstraße B2, bedeutende Pendler- und Hauptverkehrsroute (Bezirksamt Charlottenburg-Wilmersdorf, 2023)	50
<i>Messedamm, 4 Webcams</i>	Stufe 2: Überregionale Verbindungen	Nähe zu den Autobahnen 100 und 115, dem weitläufigen Messegelände (Messe Berlin, 2021) und dem Zentralen Omnibusbahnhof (Berlin.de, 2023)	50
<i>Alt-Moabit, 1 Webcam</i>	Stufe 2: Überregionale Verbindungen; Stufe 3: Regionale Verbindungen	Der Bezirk Moabit liegt näher am Stadtzentrum als die anderen Kamerastandorte und wird als zentral, jung und international beschrieben, mit einem durchschnittlichen Einkommen unterhalb anderer Stadtteile und vergleichsweise erschwinglichen Mieten (Berlin.de, 2023)	50 und 30

Methoden

Das folgende Kapitel beschreibt die methodischen Ansätze, mit denen die drei Forschungsfragen dieser Arbeit bearbeitet wurden. Die Methoden werden dabei entlang der jeweiligen Forschungsziele systematisch vorgestellt.

5.1 Experimenteller Aufbau für die großflächige Gebäudeextraktion

Für die Entwicklung der Methode für die großflächige Gebäudeextraktion, einschließlich des Fine-tunings und der Validierung, wurde Santiago de Chile als Untersuchungsgebiet gewählt. Hierfür wurden die Luftbilddaten mit einer geometrischen Auflösung von 0.35 m verwendet. Der in Santiago entwickelte Ansatz wurde auf Medellín übertragen. Für Medellín wurden dafür die zur Verfügung stehenden WorldView-Daten mittels PAN-sharpening zu einem 0.3 m RGB Bild verarbeitet (Beschreibung der verwendeten Datensätze vgl. Abschnitt 4.2.1).

Für Klassifizierungszwecke wird das Deep Neural Network Mask R-CNN eingesetzt, das im Oktober 2017 veröffentlicht wurde (He et al., 2017). Die Implementierung erfolgt auf TensorFlow, wobei ResNet-101-FPN als Backbone-Architektur und Faster R-CNN mit ResNet als Head-Architektur verwendet werden. Das Framework von Faster R-CNN gibt für jedes Objekt eine Klassenbezeichnung sowie eine Bounding-Box aus (Ren et al., 2017). Mask R-CNN ähnelt Faster R-CNN, verwendet jedoch ROI Align anstelle von ROI Pooling und erweitert das Netzwerk durch zwei zusätzliche Convolutional Layer, die eine Objektmaske ausgeben (He et al., 2017).

5.1.1 Fine-Tuning

Das Fine-tuning von Mask R-CNN wird auf einer Titan X GPU mit einer Batch-Größe von zwei Bildern durchgeführt. Der Ground-Truth-Datensatz wird in einzelne kleinere Bildkacheln aufgeteilt. Als Eingabebildgröße werden dafür 300×300 Pixel verwendet, mit einer Überlappung von 150 Pixeln (50 %). Diese Überlappung wird aus zwei Gründen gewählt: Erstens, um den Bilddatensatz für das Fine-Tuning des vortrainierten Modells zu vergrößern. Zweitens, um Randeffekte an den Bildkanten zu minimieren und so nach der Vorhersage des Modells ein gleichmäßiges Mosaik aus den einzelnen Bildkacheln zu erzeugen. Für die Lernrate, wird eine schrittweise, zweistufige Reduzierung gewählt: Lernrate LR1 = 0,001 in der ersten Stufe und Lernrate LR2 in der zweiten

Stufe. LR2 wird als LR1/10 definiert, und beide Lernraten werden auf alle Layer mit insgesamt fünf Epochen angewendet. Um Overfitting zu reduzieren, wird ein Weight Decay von 0,0001 gewählt.

Datenaugmentierung wird im Bereich des maschinellen Lernens verwendet, um die Menge an verfügbaren Trainingsdaten zu vergrößern, indem bestimmte Transformationsarten auf die Eingabedaten angewendet werden. In diesem Teil der Arbeit werden drei verschiedene Arten der Bildaugmentierung hinsichtlich ihrer Anwendbarkeit in urbanen Gebieten getestet (Abbildung 5.1): Reflexion (*reflect*), Farbtonänderung (*hue*) und Rotation (90° , 180° und 270°). Dieser Teil basiert auf einem Code für Bildaugmentierung, der für maschinelle Lernexperimente entwickelt wurde (Jung et al., 2020). Bei der Methode Reflexion (*reflect*) wird eine bestimmte Anzahl von Pixeln festgelegt, die aus dem oberen und linken Rand der Eingabebilder spiegelverkehrt reflektiert werden. Bei der Farbtonänderung (*hue*) wird der Farbtonwert so eingestellt, dass das Bild um eine zusätzliche Farbtönung ergänzt wird. Die Augmentierungsmethoden werden auf die Trainingsdaten angewendet und ihr Nutzen wird anhand der Validierungsdaten überprüft. Jeder ursprünglichen Trainingsbildkachel (mit einer Überlappung von 150 Pixeln und ohne Rotation (0°)) sowie jeder rotierten Bildversion (90° , 180° und 270°) werden die Reflexions- und Farbtonänderungsmethoden hinzugefügt. Für Reflexion wird ein Wert von 32 Pixeln gewählt, während für Farbtonänderung ein Wert von 45 verwendet wird.

Die finalen Datensätze und die Größe der Datensätze werden wie folgt definiert:

- gt: Ground-Truth-Datensatz mit Größe N, keine Rotation (0°)
- gt(refl): gt + reflektierte Ground-Truth-Daten mit Größe 2N
- gt(hue): gt + Ground-Truth-Daten mit Farbtonänderung mit Größe 2N
- gt(rot): gt + Ground-Truth-Daten mit Rotation (90° , 180° und 270°) mit Größe 4N
- gt(all): gt(rot) + gt(rot)refl + gt(rot)hue mit Größe 12N

5.1.2 Klassifikation und Mosaikerstellung

Das RGB Mosaik wird in 300×300 Pixel große Kacheln mit einer Überlappung von 200 Pixeln (67 %) unterteilt. Dadurch entstehen insgesamt etwa 930.000 Bildkacheln im gesamten ROI, die durch das Modell klassifiziert werden. Die erhöhte Überlappung wird gewählt, um Randeffekte weiter zu reduzieren, die Vorhersagegenauigkeit zu verbessern und die Nutzbarkeit für Fernerkundungsanwendungen zu erhöhen.

In der urbanen Fernerkundung ist ein zusammenhängender Datensatz von hoher Bedeutung. Der Einsatz von Deep-Learning-Techniken für hochaufgelöste Bilder führt jedoch oft zu Lücken zwischen Gebäuden an den Bildrändern. Um einen zusammenhängenden Datensatz zu erzeugen, wird eine Mosaikierungsprozedur angewendet. Nach der Klassifizierung jeder Bildkachel werden die Klassen pixelweise durch die Berechnung des Modus aus allen neun überlappenden




Abbildung 5.1: Original Bildkachel in der Größe 300x300 Pixel und die angewendeten Augmentierungen: Rotation (90°, 180° und 270°), Reflexion (*reflect*) und Farbtonänderung (*hue*).

Bildkacheln zugewiesen. Dadurch wird jeder Pixel entweder der Klasse Gebäude oder der Klasse Hintergrund zugeordnet. Die resultierenden mosaikierten Einzelkacheln werden anschließend zu einem zusammenhängenden Gebäudedatensatz für das gesamte ROI kombiniert.

5.1.3 Evaluierung

Die Leistung der Augmentierungen wird anhand folgender Metriken bewertet: Präzision, Sensitivität, IoU, Overall Accuracy (OA), Kappa-Koeffizient. Die gleichen Evaluationsmetriken werden zur Bewertung der beiden Modelle, Basismodell und angepasstes Modell, verwendet. Die Ground-Truth-Daten aus Gebiet 1 werden zur Evaluierung der getesteten Datenaugmentierungen genutzt und dienen zur Generierung des angepassten Modells mit den besten Augmentierungen. Die Ground-Truth-Daten aus Gebiet 2 werden zur Bewertung der Modellleistung des Basismodells und des finalen angepassten Modells herangezogen. Ebenso wurde die Übertragung des finalen Modells auf die Stadt Medellín anhand der genannten Metriken evaluiert.

5.2 Erstellung und Validierung des funktionalen 3D-Stadtmodells

Das Ziel dieses Teils der Doktorarbeit ist die Erstellung eines hochaufgelösten funktionalen 3D-Stadtmodells mit vier Detailebenen aus Fernerkundungsdaten und offenen Geodaten, das entscheidende Parameter für städtische Verkehrssysteme in Hinblick auf die städtische Raumstruktur abbildet (Abbildung 5.2):

- Ebene-1: 3D-Gebäude mit Gebäudehöhen
- Ebene-2: 3D-Gebäude mit geschätzter Anzahl der Stockwerke
- Ebene-3: 3D-Gebäude mit detaillierten, aus OSM-Daten abgeleiteten Landnutzungsinformationen
- Ebene-4: 3D-Gebäude mit geschätzter Einwohnerzahl auf der Ebene des einzelnen Gebäudes

In den folgenden Abschnitten dieses Kapitels wird die Methodik zur Erstellung dieses funktionalen 3D-Stadtmodells vorgestellt.




Abbildung 5.2: Steigerung der semantischen Ebene des funktionalen 3D-Stadtmodells auf der Grundlage des multimodalen Ansatzes: Überblick über die Daten und die Methoden, die zum Erreichen der Ebenen mit unterschiedlicher Informationstiefe verwendet werden (Stiller et al., 2021).

Datenfusion: 2D Gebäudegrundrisse und Höheninformationen (Ebene-1)

Die 2D Gebäudegrundrisse (vgl. Abschnitt 5.1 und 6.1) wurden für die Fusion mit den Höhendaten hinsichtlich mehrerer Kriterien optimiert. Erstens wurden die Umrissse der Gebäudeflächen durch die Erweiterung und Subtraktion im Umfang von 1 Pixel geglättet (engl. *morphological opening and closing*). Zweitens wurden Fehlklassifikationen innerhalb größerer Straßen und innerhalb von Flussläufen auf der Grundlage räumlicher Überschneidungen automatisch entfernt, indem der OSM-Straßendatensatz mit den Klassen Autobahn und der Datensatz OSM-Wasserlinien verwendet wurde. Drittens wurden andere kleinere Fehlklassifikationen automatisch durch die Verwendung eines Größenschwellenwerts von 2.5 m^2 eliminiert. Alle potenziellen Gebäude unterhalb dieser Schwelle wurden entfernt, da sie fälschlicherweise als Gebäude klassifiziert wurden, da sie eine ähnliche rechteckige Form aufwiesen.

Die nDOMs für Santiago de Chile und Medellín wurden mit den Gebäudegrundrissen kombiniert, indem die mittleren Höhen berechnet und zugewiesen wurden (Wurm et al., 2014). Auf diese Weise wurde die mittlere Gebäudehöhe für jedes einzelne Gebäude in gesamten Studiengebiets Gran Santiagos ermittelt.

Bestimmung von Gebäudeetagen mit Google Street View-Bilddaten (Ebene-2)

Um die semantische Tiefe des 3D-Modells zu erweitern, wurde die Anzahl der Stockwerke für jedes Gebäude von Gran Santiago anhand von Google Street View-Daten für 100 Gebäude ermittelt. Es kann angenommen werden, dass die mittlere Gebäudehöhe und die Anzahl der Stockwerke in einer linearen Beziehung stehen. Daher wurde eine lineare Regressionsanalyse durchgeführt, um die Anzahl der Stockwerke pro Gebäude für das Untersuchungsgebiet zu bestimmen. Die Regressionsanalyse basierte auf einer Stichprobe von 100 Gebäuden. Die mittlere Gebäudehöhe wurde als erklärende Variable und die Anzahl der Stockwerke als abhängige Variable verwendet. Aus der Stichprobe von 100 Gebäuden wurden während des Verfahrens zur Erstellung des endgültigen Modells sechs statistische Ausreißer entfernt, um den Modelfit zu verbessern.

Extraktion der Landnutzung aus OSM (Level-3)

Um die Landnutzung auf Gebäudeebene zu ermitteln, wurden OSM-Daten in die Analyse miteinbezogen und die Landnutzungskategorien in drei aufeinander folgenden Schritten bestimmt (Abbildung 5.3).

Zunächst wurden die relevanten Landnutzungskategorien definiert. Dazu wurden OSM Landnutzungspolygone verwendet, um drei Unterkategorien zu bestimmen: Wohnen, Gewerbe und Industrie. Darüber hinaus kamen OSM POIs zum Einsatz, um einen feineren Detailgrad zu erhalten (Estima und Painho, 2015). Die POIs umfassen insgesamt 114 Label-Kategorien. Diese semantisch vielfältigen Punktdaten wurden in die folgenden sechs Unterkategorien eingeteilt: Gewerbe, Bildung, Unterkunft, kommunale Einrichtungen, Kultur und Gesundheit. Zweitens wurden diese beiden Unterkategorien kombiniert, um zwölf endgültige Landnutzungsklassen

zu erstellen. Es konnte festgestellt werden, dass einigen Gebäuden keine Landnutzungsklasse zugewiesen wurde, da sie weder von den Landnutzungspolygondaten noch von den POIs erfasst wurde. Für diesen Fall wurde eine leere Landnutzungsklasse zugewiesen. Drittens wurden für die Schätzung der Bevölkerung (siehe nächster Abschnitt) die Landnutzungskategorien vereinfacht, indem sie entweder als bewohnt oder nicht bewohnt betrachtet wurden.




Abbildung 5.3: Schema zur OSM-basierten Landnutzungskategorisierung in drei Schritten, unter Nutzung der Landnutzungspolygone und der POIs von OSM (Stiller et al., 2021).

Schätzung der Bevölkerung auf der Ebene einzelner Gebäude (Ebene 4)

Im Allgemeinen können die Methoden zur Bevölkerungsabschätzung nach Wu et al., 2005 in flächenbezogene Interpolationsmethoden, auch bekannt als Disaggregation, und statistische Modellierungsmethoden unterteilt werden. In dieser Arbeit wurde die erste Methode verwendet, die die Übertragbarkeit des Ansatzes erhöht, da sie nur eine Gesamtzahl der Bevölkerung für die Studienregion erfordert. Dafür wurden fünf Experimente durchgeführt mit unterschiedlichem Detailgrad, indem nur eine Gesamtbevölkerungszahl für das gesamte Untersuchungsgebiet verwendet wurde (Tabelle 5.1, Abbildung 5.4):

- Experiment 1 beruht auf der Verwendung der Fläche der Gebäudegrundrisse. In zuvor durchgeführten Studien wurde eine hohe Übereinstimmung zwischen Gebäudegrundfläche und Bevölkerung nachgewiesen werden (Wu et al., 2008).
- Experiment 2 bezieht die 3D-Höheninformationen mit ein. Daher ist die Bevölkerungszahl eine Funktion des Volumens, einer Kombination aus Fläche und Höhe.
- Experiment 3 zielt darauf ab, die geschätzte und ganzzahlig gerundete Geschoszahl S zu verwenden. S wurde basierend aus der Höhe H (m) basierend auf den Ergebnissen der Regressionsanalyse abgeleitet.
- für die Experimente 4 und 5 wurden die vereinfachten Landnutzungsklassen und ihre Bedeutung als Wohneinheiten mit einbezogen, wobei in Experiment 4 die Gebäudehöhen in m und in Experiment 5 die ermittelte Geschoszahl aus der Regressionsanalyse verwendet wurde. Ein Gebäude der Klasse 'Wohnen' wird als vollständig bewohnt betrachtet, d.h.

jedes Stockwerk wird als Wohneinheit betrachtet. Bei der Klasse 'Wohnen gemischt' wird angenommen, dass ein Stockwerk nicht bewohnt ist, z. B. im Fall eines Geschäfts im Erdgeschoss (Biljecki et al., 2016). Die Landnutzungsklassen 'andere' und 'keine Landnutzung' werden als nicht bewohnt betrachtet, z. B. Industrie, Gewerbe oder ähnliche.

Mit diesen fünf Experimenten wurde systematisch getestet, wie die Ansätze bei der Schätzung der Bevölkerung auf Einzelgebäudeebene abschneiden, indem 1) nur Fernerkundung (Experiment 1 und 2) und 2) Fernerkundung in Kombination mit anderen Geodaten (Experiment 3, 4 und 5) verwendet wurde. Sie dienen daher als Indikator für die Genauigkeit der Bevölkerungsabschätzung, die bei der Verwendung der jeweiligen Daten mit unterschiedlichem Detailgrad zu erwarten ist, wobei auch die Verfügbarkeit der Daten sowie die Rechenleistung und -zeit eine Rolle spielen.

Tabelle 5.1: Übersicht über die fünf Experimente und die für die Bevölkerungsabschätzung auf der Ebene der einzelnen Gebäude verwendeten Daten (nach Stiller et al., 2021).

	Beschreibung	Benötigte Daten
<i>Experiment 1^{a)}</i>	2D, Fläche von Gebäudegrundrissen	Luftbilder
<i>Experiment 2^{a)}</i>	3D Gebäude (Fläche × Höhe)	Luftbilder + Stereodaten
<i>Experiment 3^{b)}</i>	Gebäudegeschosse (Fläche × geschätztes Stockwerk)	Luftbilder + Stereodaten + Google Street View
<i>Experiment 4^{b)}</i>	3D + Landnutzung	Luftbilder + Stereodaten + OSM
<i>Experiment 5^{b)}</i>	Gebäudegeschosse + Landnutzung	Luftbilder + Stereodaten + Google Street View + OSM

Hinweis: ^{a)} Experiment, das nur mit Fernerkundungsdaten durchgeführt wurde; ^{b)} Experiment, das mit Fernerkundungsdaten in Kombination mit anderen Geodaten durchgeführt wurde.

Validierung

Das sehr hoch aufgelöste DOM wurde als Referenz verwendet, um die Höhe der Merkmale des 3D-Stadtmodells zu validieren. Das DOM diente zur Erstellung eines nDOM auf der Grundlage eines Algorithmus von Pijl et al., 2020. Der Mittelwert der nDOM-Pixelwerte wurde verwendet, um die Höhe pro Gebäude zu ermitteln. Auf dieser Grundlage wurde eine objektbasierte Genauigkeitsbewertung anhand der Gesamtabweichung in Form des mittleren absoluten Fehlers (engl. *mean absolute error*, MAE) durchgeführt. Darüber hinaus wird eine detaillierte Genauigkeitsbewertung auf der Grundlage des absoluten prozentualen Fehlers (engl. *absolut percent error*, APE) vorgenommen, die das sehr hoch aufgelöste nDOM und das SPOT nDOM vergleicht. Der APE ist definiert als die objektspezifische absolute prozentuale Differenz zwischen zwei numerischen Vektoren und gibt deren Abweichung an (Frasco et al., 2018).




Abbildung 5.4: Schematische Darstellung der fünf Experimente, die zur Bevölkerungsabschätzung auf Einzelgebäudeebene durchgeführt wurden: Experiment 1) verwendete den 2D-Gebäudedatensatz mit den Gebäudegrundrissen; Experiment 2) das Volumen des 3D-Gebäudedatensatzes; Experiment 3) den 3D-Gebäudedatensatz mit der Anzahl der ermittelten Stockwerke; Experiment 4) den 3D-Gebäudedatensatz mit zusätzlichen Informationen zur Landnutzung (*) basierend auf dem Volumen; Experiment 5) den Gebäudedatensatz mit gerundeten geschätzten Stockwerken und den Landnutzungsinformationen (*) (Stiller et al., 2021).

Um die Genauigkeit der Bevölkerungsabschätzung zu bestimmen, wurden die Zensusdaten für Santiago de Chile als Referenz verwendet. Die Validierung wird auf zwei räumlichen Skalen durchgeführt: Stadtblockebene und Bezirke. Dies 1) erlaubt es, mögliche Unterschiede in der methodischen Genauigkeit für räumlich kleinere und größere Einheiten zu bestimmen, und 2) hilft, die genaueste Methode (Experiment 1, 2, 3, 4 oder 5) für zukünftige Anwendungen zu identifizieren. Die Referenz- und die geschätzten Gesamtwerte werden in Form von Streudiagrammen verglichen und stellen den MAE und den relativen absoluten Fehler (engl. Relative Absolute Error, RAE) als Genauigkeitsmetriken dar. Der RAE berechnet den relativen absoluten Fehler zwischen zwei numerischen Vektoren (Frasco et al., 2018). Für die Methode, die bei der Vorhersage der Bevölkerung am besten abschneidet, wird zudem eine vertiefte Genauigkeitsanalyse durchgeführt, in der die Fehlermetrik auf der Grundlage von Landnutzungsanteilen verglichen wird.

5.3 Routinganalyse für die Ermittlung der Erreichbarkeit öffentlicher Verkehrsmittel

Zur Analyse der Erreichbarkeit des öffentlichen Verkehrs nach dem SDG-11.2-Indikator wird ein Open-Source-Python-Paket eingesetzt, das die Distanz zur nächstgelegenen ÖV-Haltestelle per Routing auf dem Straßennetz berechnet (Nieland und Yosmaoglu, 2022). Die drei verwendeten Bevölkerungsdatensätze wurden in Punktdaten umgewandelt, indem der Schwerpunkt des entsprechenden Gebäudes oder der Zelle genutzt wurde. Diese Bevölkerungspunkte dienen als

Ausgangspunkte für die Berechnung der Gehstrecke entlang des OSM-Straßennetzes zu den ÖV-Haltestellen. Daraus resultiert eine berechnete Entfernung zur nächsten ÖV-Haltestelle pro Bevölkerungspunkt.

Um die räumliche Variation der Erreichbarkeit von Haltestellen des öffentlichen Verkehrs in der Stadt zu untersuchen, wird folgende Analyse-Strategie verfolgt: Zunächst wird die Erreichbarkeit formeller und semiformeller Haltestellen sowie deren jeweiliger Einfluss auf die Gesamterreichbarkeit verglichen. Dazu erfolgt zunächst eine Analyse ausschließlich formeller Haltestellen, also U-Bahn- und Bushaltestellen (Abschnitt 6.3.1). Anschließend wird die Untersuchung um semiformelle Minibus-Haltestellen erweitert (Abschnitt 6.3.2). Aufbauend darauf erfolgt eine Auswertung nach sozioökonomischen Gruppen, wobei insbesondere die Erreichbarkeit formeller und informeller Siedlungen zum städtischen Verkehr betrachtet wird (Abschnitt 6.3.3).

Für die verschiedenen Analysen im experimentellen Setup werden die berechneten Gehdistanzen zu den ÖV-Haltestellen basierend auf den drei Bevölkerungsdatensätzen auf drei verschiedenen räumlichen Ebenen verglichen: 1) Die gesamte Erreichbarkeit des Stadtgebiets von ROI 1, das das Maß gemäß dem SDG 11.2 Indikator darstellt, 2) die Erreichbarkeit innerhalb der Verwaltungseinheiten der Stadt (Sektoren), und 3) die Erreichbarkeit innerhalb eines Rasters mit einer Zellgröße von 1.000 m.

5.4 YOLOv8 für die Erkennung von Verkehrsobjekten

Das Modell YOLOv8 wurde für die Detektion von verkehrsrelevanten Objekten in den zur Verfügung stehenden offenen Webcam-Daten genutzt. YOLOv8 wurde im Januar 2023 veröffentlicht. Die zugrundeliegenden Modelle bieten eine leistungsstarke Kombination aus Genauigkeit und Geschwindigkeit, mit Verbesserungen in der Präzision und der Echtzeit-Inferenz (Ultralytics, 2025). YOLOv8 umfasst Modellvarianten mit zunehmender Komplexität: n, s, m, l und x. Mit steigender Modellkomplexität verbessert sich in der Regel die Erkennungsgenauigkeit, allerdings gehen diese Verbesserungen mit höheren Rechenanforderungen und längeren Verarbeitungszeiten einher.

In dieser Doktorarbeit wurde YOLOv8 ohne Anpassungen verwendet, da bereits nachgewiesen wurde, dass YOLO-Modelle ohne Fine-Tuning („out-of-the-box“) vielversprechende Ergebnisse liefern (Witte und Gómez, 2022). Die Zielsetzung war dabei zweigeteilt:

1. Die out-of-the-box-Leistung von YOLO auf dem Referenzdatensatz zu bewerten, einschließlich der Untersuchung der Confidence- und IoU-Parameter, um die optimale Kombination für die beste Leistung zu bestimmen.
2. Die Fähigkeit von YOLO zu untersuchen, relative Veränderungen zwischen zwei Zeiträumen festzustellen, vor und während COVID-19.

Durch die Verwendung der vortrainierten Modelle von YOLOv8 wurde der für das Training und das Fine-Tuning mit domänenspezifischen Daten üblicherweise erforderliche Zeit- und Arbeitsaufwand erheblich reduziert. YOLOv8 wurde mittels COCO-2017-Datensatz trainiert, der über 120.000 annotierte Bilder umfasst (Lin et al., 2014) und kann daher direkt in verschiedene Workflows integriert werden, ohne dass umfangreiche domänenspezifische Trainingsdatensätze erforderlich sind. Zudem ist YOLOv8 besonders effizient für die Anwendung auf große Datensätze, was es besonders geeignet für die Verarbeitung umfangreicher Webcam-Bilddaten macht.

Für die Anwendung des vortrainierten YOLOv8-Modells auf den Fallstudien-Datensatz wurden die IoU- und die Confidence-Werte schrittweise verändert, um die Erkennungsleistung von YOLO bei der Identifikation von Verkehrsteilnehmenden in Webcam-Bildern zu optimieren. Der Confidence-Wert $[0;1]$ gibt die Wahrscheinlichkeit an, mit der ein erkanntes Objekt einer bestimmten Klasse zugeordnet wird. Der IoU-Wert $[0;1]$ beschreibt den Überlappingsgrad zwischen der vorhergesagten Bounding Box eines Objekts und der entsprechenden Bounding Box aus der Referenz. Aufgrund des Funktionsprinzips von YOLO werden häufig mehrere Bounding Boxes für dasselbe erkannte Objekt vorgeschlagen. Durch die Nutzung des IoU-Wertes wurde mittels Non-Maximum Suppression nur die wahrscheinlichste Bounding Box beibehalten.

Mithilfe einer Grid-Search-Methode wurden beide Parameter in Schritten von 0,1 systematisch gegeneinander getestet, was zu insgesamt 110 Experimenten für jede der verfügbaren YOLO-Modellvarianten (n, s, m, l, x) führte. Nach der YOLO-Vorhersage wurde ein IoU-Schwellenwert von 0,5 verwendet, um ein erkanntes Objekt als korrekt oder inkorrekt zu klassifizieren. Die Wahl des IoU-Wertes von 0,5 basiert auf vorherigen Studien (Al-qaness et al., 2021; Wu et al., 2020; Zhu et al., 2021).

Zur Bewertung der Modellleistung wurde die F1-Score-Metrik verwendet, da sie sich für Objekterkennungsaufgaben bewährt hat (Guney et al., 2022). Anhand dieses Vorgehens wurde die beste Kombination aus Confidence- und IoU-Werten bestimmt.

Die Anwendung von YOLO auf die Bilder des Fallstudien-Datensatzes (493.715 Bilder) führte zu erfassten Detektionen pro Bild und Objektklasse. Da YOLO üblicherweise sowohl ein Fahrrad bzw. Motorrad als auch die Person darauf erkennt, wurde die Anzahl der Personen von den erkannten Fahrrädern und Motorrädern subtrahiert (negative Werte wurden dabei nicht zugelassen). Aufgrund dieser Anpassung werden die drei betroffenen Klassen in den weiteren Ausführungen als Fußgänger, Radfahrende und Motorradfahrende bezeichnet.

Ergebnisse

In diesem Kapitel werden die zentralen Ergebnisse der empirischen Analysen vorgestellt. Die Darstellung folgt der Struktur der drei Forschungsfragen und gibt Einblick in die jeweiligen Ergebnisse zur Ableitung der räumlichen Stadtstruktur, zur Erreichbarkeit von öffentlichem Verkehr und zum Verkehrsmonitoring mithilfe offener Webcam-Daten.

6.1 Evaluierung von Mask-RCNN für die Gebäudeextraktion

Ein Vergleich der Augmentierungsexperimente (Tabelle 6.1) zeigt, dass alle Bildaugmentierungen die für das Fine-Tuning eingesetzt werden, zu einer signifikanten Steigerung von Sensitivität, IoU und Kappa führen und den ursprünglichen Ground-Truth-Datensatz (gt) übertreffen. Die Präzision nimmt ab, da mehr Pixel der Klasse Gebäude zugewiesen werden, obwohl sie laut Ground-Truth-Daten zum Hintergrund gehören. Dies geschieht jedoch in Kombination mit einer erhöhten Sensitivitäts-Rate (mehr Pixel werden korrekt als Gebäude erkannt). Die Evaluierung von gt(all) zeigt die ausgeglichensten Ergebnisse für alle Kriterien, da es die höchste Genauigkeit bei der Sensitivität aufweist. Dadurch wird eine präzisere Identifikation der Gebäude-Pixel erreicht, ohne eine Überschätzung zu verursachen. Aus diesem Grund wird das Modell auf Basis von gt(all) als finales angepasstes Modell definiert, unter Verwendung eines Trainingsdatensatzes gt(all) mit der Größe 12N.

Das Basismodell und das angepasste Modell wurden hinsichtlich ihrer Leistung in Gebiet 2 verglichen (Tabelle 6.2 a). Das angepasste Modell übertrifft das Basismodell deutlich in allen Evaluationsmetriken und zeigt eine Steigerung der OA um ca. 7.5 %. Daher wird das angepasste Modell für die weitere Analyse verwendet. Darüber hinaus wurde das angepasste Modell auf Medellín übertragen, sowie anhand von Katasterdaten evaluiert. Dabei ergab die Evaluierung, dass es eine robuste OA von 89.2 % erreicht (Tabelle 6.2 b).

In Abbildung 6.1 wird der Ground-Truth-Datensatz für Gebiet 1 und Gebiet 2 sowie die Vorhersagen des angepassten Modells für beide Gebiete dargestellt. Es ist ersichtlich, dass die Vorhersagen des angepassten Modells nur in wenigen Fällen von den Ground-Truth-Daten abweichen, was die hohe OA bestätigt.

Tabelle 6.1: Evaluierung der getesteten Augmentierungen für Mask R-CNN zur Gebäudeextraktion, um das leistungsstärkste angepasste Modell zu generieren (nach Stiller et al., 2019b).

<i>Datensatz</i>	<i>Datensatzgröße</i>	<i>Präzision</i>	<i>Sensitivität</i>	<i>IoU</i>	<i>OA</i>	<i>Kappa</i>
<i>gt</i>	N	86,71	73,28	65,71	86,62	0,70
<i>gt(refl)</i>	2N	89,33	79,60	72,68	87,95	0,76
<i>gt(hue)</i>	2N	88,90	79,89	72,64	88,80	0,77
<i>gt(rot)</i>	4N	87,84	80,64	72,54	87,38	0,77
<i>gt(all)</i>	12N	85,81	82,13	72,31	86,61	0,76

Tabelle 6.2: Mask R-CNN Modellbewertung des ursprünglichen Basismodells und des angepassten Modells, welches mit *gt(all)* verfeinert wurde (sog. Fine-Tuning). Für die Untersuchungsregion a) Santiago de Chile und b) Medellín (nach Stiller et al., 2019b).

<i>Untersuchungsregion</i>	<i>Verwendetes Modell</i>	<i>Präzision</i>	<i>Sensitivität</i>	<i>IoU</i>	<i>OA</i>	<i>Kappa</i>
a) <i>Santiago de Chile</i>	Basismodell	84,63	76,46	67,14	85,51	0,69
	Angepasstes Modell	93,18	85,41	80,38	91,92	0,83
b) <i>Medellín</i>	Angepasstes Modell	97,29	65,47	64,84	89,23	0,71

In Abbildung 6.2 werden verschiedene urbane Strukturen verglichen (a-d in Santiago, e in Medellín):

- (a) Mittelhochgroße, freistehende Gebäude in einem Stadtgebiet mit Wohn-Mischnutzung
- (b) Dicht bebaute Blöcke im Central Business District (CBD) von Santiago de Chile
- (c) Große Gebäude mit komplexen Dachstrukturen in einem Industriegebiet
- (d) Niedrig gebaute Wohngebiete am Stadtrand
- (e) Wohnsiedlung am Stadtrand mit informellen Siedlungen im Westen

In (a) werden einzelne Gebäude präzise identifiziert und durch klare, gerade Grenzen voneinander abgegrenzt. In (b) werden einzelne Gebäude nicht mehr separat erkannt, sondern als zusammenhängende Gebäudeblöcke klassifiziert, was mit der dichten Bebauung in diesem Bereich übereinstimmt. In (c) variiert die Klassifizierung innerhalb des Gebiets. Große Gebäude werden zuverlässig erkannt, während Gebäude mit komplexen Dachstrukturen schwer zu identifizieren sind. In (d) werden niedrig und dicht bebaute Siedlungen nicht als einzelne Gebäude, sondern als zusammenhängende Gebäudecluster klassifiziert. In (e) sind größere Einzelgebäude erkennbar und voneinander getrennt extrahiert worden, selbst Gebäude in informellen Siedlungen werden als Einzelgebäude identifiziert.



Abbildung 6.1: Vergleich der originalen RGB-Daten (links), der Ground-Truth-Daten (mittig) und der Klassifikationsergebnisse der Gebäudeextraktion des angepassten Modells (rechts) für Gebiet 1 (oben) und Gebiet 2 (unten) (Stiller et al., 2019b).

6.2 Funktionales 3D-Stadtmodell

6.2.1 Gebäudemodell

In Abbildung 6.3 ist ein exemplarischer Ausschnitt des Gebäudemodells bzw. des erstellten 3D-Stadtmodells abgebildet und zeigt den CBD des Stadtzentrums von Santiago. Das resultierende 3D-Stadtmodell zeigt die verschiedenen Strukturen in diesem Gebiet, wobei die höchsten Gebäude innerhalb des CBDs liegen und umgeben sind von mittelhohen und niedrigeren Gebäuden.

Um die Höheninformationen des 3D-Modells zu validieren, wurden die Genauigkeit des flächendeckenden hochaufgelösten SPOT-7 nDOM mit dem luftgestützten sehr hoch aufgelösten nDOM verglichen, das für einen Teil von Santiago verfügbar war. Der mittlere absolute Fehler zeigt, dass die Höhe der Gebäude im Durchschnitt um 2,90 m von den sehr hoch aufgelösten Referenzdaten abweicht ($MAE=2,90$). Eine vertiefte Genauigkeitsanalyse offenbart, dass der APE mit zunehmender Gebäudehöhe und Gebäudefläche abnimmt (Abbildung 6.4). Dies weist darauf hin, dass die geschätzte Gebäudehöhe aus dem hoch aufgelösten SPOT nDOM für höhere und größere Gebäude genauer war.




Abbildung 6.2: Gebäudeextraktion für verschiedene Gebäudetypen (a-d in Santiago, e in Medellín). a) einzelne, freistehende Gebäude; b) Gebäude des CBD; c) Gebäude in einem Industriegebiet; d) Wohngebäude in den außerhalb gelegenen Stadtgebieten; e) Gebäude in formellen und informellen Gebieten am Stadtrand (Stiller et al., 2019b).




Abbildung 6.3: Beispielhafte Illustration des 3D-Stadtmodells mit Fokus auf dem CBD im Stadtzentrum von Santiago de Chile (Stiller et al., 2021).




Abbildung 6.4: Boxplots, die den Average Precision Error (APE) für verschiedene Gruppen (x-Achse) von Gebäudehöhe in m (links) und Gebäudefläche in m² (rechts) zeigen. Die y-Achse repräsentiert den APE (Stiller et al., 2021).

6.2.2 Ableitung von Gebäudegeschossen

Mit Hilfe der Google Street View-Szenen konnten von 100 Gebäuden die dazugehörige Geschosshöhe ermittelt und so ein robustes lineares Regressionsmodell erstellt werden (adj. R^2 : 0,88, p-Wert: $2,2e-16$) (Abbildung 6.5). Bei einem Achsenabschnitt von 0,69 ergab die lineare Regression, dass eine Höhe von 2 m im Höhenmodell im Durchschnitt einem Gebäudestockwerk entspricht (Steigung=0,50; 1 m Gebäudehöhe=0,50 Stockwerke). Die daraus resultierende Steigung des linearen Modells kann als die Anzahl der Stockwerke interpretiert werden, die 1 m Gebäudehöhe entsprechen. Der Wert von 2 m kann als relative Geschosshöhe innerhalb der Modells verstanden werden, aber nicht als die absolute durchschnittliche Höhe der Geschosse in Santiago de Chile.

6.2.3 Innerstädtische Landnutzung

Die erfasste Landnutzung auf Ebene der einzelnen Gebäude ist in Abbildung 6.6 veranschaulicht. Zuvor wurden zwölf Landnutzungsklassen für das Untersuchungsgebiet definiert. Zur Vereinfachung auf die wichtigsten Landnutzungsarten wurde die Landnutzungskartierung auf fünf Klassen reduziert.

Die räumliche Verteilung der Landnutzungsklassen im Stadtgebiet ist äußerst heterogen. Im Stadtzentrum wurde eine hohe Dichte des Flächennutzungstyps 'Wohnen gemischt' festgestellt, während in den Außenbezirken von Santiago die Flächennutzungsart 'Wohnen' dominierte. Mit einem Anteil von etwa 83 % aller Gebäude (Abbildung 6.6 a) und 75 % der gesamten bebauten Fläche (Abbildung 6.6 b) wurde 'Wohnen' als die häufigste Landnutzungsart in der Analyse identifiziert.




Abbildung 6.5: Ergebnisse der Regressionsanalyse, in der der Zusammenhang zwischen der Anzahl der Gebäudegeschosse und der mittleren Gebäudehöhe (m) der untersuchten Gebäuestichprobe dargestellt wird (adj. R^2 : 0,88, p-Wert: 2,2e-16) (Stiller et al., 2021).




Abbildung 6.6: Karte mit der identifizierten Landnutzung auf Einzelgebäudeebene für Santiago de Chile, basierend auf dem angewandten OSM-Datenworkflow. Die Balkendiagramme zeigen die klassifizierte Landnutzungsanteile in Bezug auf a) die Gesamtzahl der Gebäude und b) die Gesamtfläche der Gebäude. Die Klasse 'Sonstige' bezieht sich auf 'Gewerbe-gemischt', 'Industrie-gemischt', 'Beherbergung', 'Bildung', 'Kultur', 'Gesundheit' und 'keine Landnutzung' (Stiller et al., 2021).

6.2.4 Schätzung der Bevölkerung

Für die Bestimmung der Genauigkeit wurde der MAE und der RAE für die beiden Raumeinheiten, Stadtblockebene und Bezirke, herangezogen (Tabelle 6.3). Der MAE gibt die durchschnittliche absolute Abweichung als Anzahl der Personen zwischen der vorhergesagten Bevölkerung und der Bevölkerung aus den Zensusdaten an. Der RAE vergleicht die mittleren Residuen des getesteten Modells mit den mittleren Residuen eines naiven Modells. Ein robustes Modell führt zu einem RAE von weniger als 1 (Cichosz, 2015). Die erzielten Ergebnisse zeigen, dass Experiment 5 von allen getesteten Ansätzen für beide Raumeinheiten die Bevölkerung am besten vorhersagen kann. Auf Bezirksebene schnitt Experiment 1 jedoch in Bezug auf den RAE gleich gut ab (RAE=0,74). Dennoch schnitt Experiment 5 in Bezug auf den MAE besser ab. Die geringste Genauigkeit wurde von Experiment 2 erzielt.

Die Bewertung der Genauigkeit der fünf Experimente zur Bevölkerungsschätzung ergab ein gegensätzliches Bild für die beiden Raumeinheiten, wenn man die geschätzte Bevölkerung mit den Referenzdaten der Zensuserhebung vergleicht (Abbildung 6.7). Auf der kleinräumigen Ebene der Stadtblöcke zeigten die flächenbasierten (Experiment 1), 3D- (Experiment 2) und geschossflächenbasierten (Experiment 3) Ansätze eine unzureichende Abbildung der Bevölkerung (adj. R^2 : 0,09-0,11). Diese drei Ansätze unterschätzten die tatsächliche Bevölkerungszahl deutlich. Die Übereinstimmung nahm deutlich zu, als Informationen zur Landnutzung hinzugefügt wurden (Experiment 4 und 5; adj. R^2 : 0,38 bzw. 0,40). Auf der Ebene der Bezirke schnitt Experiment 5 am besten ab (adj. R^2 : 0,52), dicht gefolgt von Experiment 1 (adj. R^2 : 0,50). Experiment 4 schnitt ebenfalls gut ab (adj. R^2 : 0,40). Am wenigsten repräsentativ waren Experiment 2 und 3 (adj. R^2 : 0,26 bzw. 0,32).

Abbildung 6.8 zeigt die Auswirkungen der verschiedenen Landnutzungsarten auf die Genauigkeit der Bevölkerungsabschätzung. Der APE verringerte sich mit zunehmendem Anteil der Landnutzungsart 'Wohnen', sowohl für die Ebene der Stadtblöcke als auch für Bezirke. Andererseits stieg der Fehler bei der Klasse 'Wohnen gemischt', ähnlich wie bei den Klassen 'Sonstige' und 'Keine Landnutzung'.

Tabelle 6.3: Mittlerer absoluter Fehler (MAE) und relativer absoluter Fehler (RAE) für die Ergebnisse der Bevölkerungsabschätzung für alle fünf Experimente. Der MAE wird in Anzahl der Personen angegeben (nach Stiller et al., 2021).

	MAE		RAE	
	Stadtblöcke	Bezirke	Stadtblöcke	Bezirke
<i>Experiment 1</i>	87,2	4929,9	0,84	0,74
<i>Experiment 2</i>	110,8	7772,2	1,07	1,18
<i>Experiment 3</i>	101,7	6638,8	0,98	1,00
<i>Experiment 4</i>	85,3	6070,1	0,83	0,92
<i>Experiment 5</i>	78,9	4888,4	0,76	0,74




Abbildung 6.7: Streudiagramme mit den geschätzten Bevölkerungswerten (y-Achse) im Vergleich zu den Referenzdaten des Zensus (x-Achse), getrennt nach Stadtblöcken (oben) und Bezirken (unten), jeweils für alle fünf Experimente. Angegeben ist zudem das zugehörige adjustierte Bestimmtheitsmaß ($\text{adj. } R^2$) (Stiller et al., 2021).




Abbildung 6.8: Boxplots, die den absoluten prozentualen Fehler (APE) in Relation zu den Landnutzungsanteilen (%) für die Klassen 'Wohnen', 'Wohnen gemischt', 'andere' und 'keine Landnutzung' in zwei verschiedenen Raumeinheiten (Stadtblockebene 'Manzanas' und Bezirke 'Districts') zeigen. Die Fehlermetriken wurden aus der Bevölkerungsabschätzung auf der Grundlage von Experiment 5 abgeleitet (Stiller et al., 2021).

6.3 Erreichbarkeit des öffentlichen Verkehrs am Beispiel Medellín

6.3.1 Erreichbarkeit basierend auf dem formellen öffentlichen Verkehr

Das formelle öffentliche Verkehrssystem in Medellín umfasst die U-Bahn- und Bushaltestellen. Grundlage für die Messung der Erreichbarkeit im Sinne von SDG 11.2 ist eine definierte Gehdistanz von 1.000 m zu U-Bahnstationen als Verkehrsmittel mit hoher, und 500 m zu Bushaltestellen als Verkehrsmittel mit geringer Kapazität (Tabelle 6.4 a).

Bei der Analyse der berechneten Erreichbarkeiten, die ausschließlich auf dem Bevölkerungsdatensatz 1 (Tabelle 6.4, Tabellenabschnitt 1) basieren, kann festgestellt werden, dass das Bussystem die niedrigste Erreichbarkeit aufweist, mit einem erreichten Anteil von 32.4 % der Bevölkerung. Das bedeutet, rund 570.000 Personen haben Bushaltestellen in fußläufiger Entfernung von maximal 1.000 m. Demgegenüber beträgt die Erreichbarkeit von U-Bahn-Stationen 36.7 % und erhöht sich infolge des Netzausbaus bis 2021 auf 48.6 %. Folglich hat nun zusätzlich 11.9 % der Gesamtbevölkerung Zugang zu Verkehrsmitteln mit hoher Kapazität im Vergleich zur Ausgangslage im Jahr 2016, was einer geschätzten Zunahme von fast 210.000 Personen entspricht, die Zugang zum formellen öffentlichen Verkehr erhalten haben. Dieser Effekt einer erhöhten Erreichbarkeit kann auch für die kombinierte Erreichbarkeit von U-Bahn- und Bushaltestellen im Jahr 2021 beobachtet werden, wo dieser positive Trend ebenfalls zu einem Gesamtanstieg der Erreichbarkeit um 9.3 % führt, was 1,1 Millionen Einwohnern entspricht (basierend auf Datensatz 1). Dies unterstreicht eine erhebliche Verbesserung der Erreichbarkeit zum öffentlichen Verkehr in Medellín seit der Einführung der neuen U-Bahn-Linien, die eine entscheidende Rolle bei der Steigerung der Gesamt-Erreichbarkeit innerhalb des formellen Verkehrssystems spielen. Einen entscheidenden Beitrag leisten auch die Bushaltestellen, da sie ab 2021 erheblich zur kombinierten Erreichbarkeit von U-Bahn- und Bushaltestellen beitragen, die bei 62.8 % liegt. Dies übertrifft die 48.6 % Erreichbarkeit, die nur durch U-Bahn-Stationen erzielt wird.

Bei der Verwendung unterschiedlicher Bevölkerungsdatensätze wird Datensatz 1 als Referenzdatensatz für den Vergleich mit den Datensätzen 2 und 3 eingesetzt (Tabelle 6.4, Tabellenabschnitte 2 und 3). Bei der Untersuchung der relativen Ergebnisse dieser Datensätze werden nur geringe Abweichungen beobachtet, abhängig von der Art des betrachteten Transportmittels. Im absoluten Vergleich zu Bevölkerungsdatensatz 1 wird unter Verwendung des globalen Bevölkerungsdatensatzes 3 jedoch die Gesamtzahl der Personen, die Zugang zum öffentlichen Verkehr haben, besonders überschätzt. Im Gegensatz zu Datensatz 3 ist Bevölkerungsdatensatz 2 genauer bei der Schätzung der Gesamtzahl der Personen mit Zugang zum

Der Indikator für das SDG 11.2 wird in der Regel auf Stadtebene berechnet. Dieser Ansatz berücksichtigt jedoch häufig nicht die geographischen und räumlichen Unterschiede in der Erreichbarkeit innerhalb des heterogenen urbanen Raums. Um diese intra-urbanen Unterschiede hervorzuheben, wird eine vergleichende Analyse durchgeführt. Konkret wird die durchschnittliche Gehstrecke zu den nächstgelegenen ÖV-Haltestellen über das gesamte Gebiet von ROI 1 unter

Tabelle 6.4: Erreichbarkeit in Prozent nach dem UN Indikator und die Gesamtzahl der Personen mit Zugang zum öffentlichen Verkehr aufgeschlüsselt nach Transporttyp in ROI 1 für a) formellen und b) semiformalen Verkehr. Die Analyse wird unter Verwendung von Bevölkerungsdaten aus drei verschiedenen Datensätzen durchgeführt: 1) Kataster, 2) Fernerkundung: regionaler Datensatz und 3) Fernerkundung: global verfügbarer Datensatz (nach Stiller et al., 2025).

Bevölkerungsdensätze	1) Datensatz 1		2) Datensatz 2		3) Datensatz 3	
<i>Gesamtbevölkerung in Untersuchungsgebiet ROI 1</i>	1.770.534		1.762.586		2.441.854	
	in %	insgesamt	in %	insgesamt	in %	insgesamt
a) Formell						
<i>U-Bahn (bis 2016)</i>	36,7	650.494	40,2	708.207	39,8	972.835
<i>U-Bahn (bis 2021)</i>	48,6	860.480	52,1	919.012	51,7	1.262.683
<i>Bus</i>	32,4	574.124	40,3	709.850	41,6	1.015.789
<i>U-Bahn & Bus (bis 2016)</i>	53,5	947.590	58,8	1.036.224	60,5	1.476.101
<i>U-Bahn & Bus (bis 2021)</i>	62,8	1.112.427	67,6	1.191.332	68,9	1.681.217
b) Semiformell						
<i>Minibus</i>	98,9	1.750.881	98,2	1.731.564	96,8	2.363.715

Verwendung des Bevölkerungsdatensatzes 1 bewertet (Abbildung 6.9 a). Zur weiteren Unterscheidung werden die Distanzen sowohl auf der Ebene der administrativen Sektoren (Abbildung 6.9 b) als auch auf der Rasterebene mit einer Zellgröße von 1.000 m (Abbildung 6.9 c) verglichen.

Die Untersuchung auf gesamtstädtischer Ebene zeigt, dass sich die nach 2016 durchgeführten Erweiterungen des U-Bahn-Netzes deutlich in einer verkürzten durchschnittlichen Gehstrecke zur nächstgelegenen U-Bahn-Station widerspiegeln (Abbildung 6.9.I.a). Die neuen U-Bahn-Linien verkürzten den durchschnittlichen Weg zur nächstgelegenen U-Bahn-Station um 288 m, von 1.571 m im Jahr 2016 auf 1.283 m im Jahr 2021. Dennoch ist die durchschnittliche Gehstrecke zur nächsten Bushaltestelle kürzer und beträgt nur 801 m. Insgesamt ergibt die Kombination von U-Bahn- und Bushaltestellen die kürzeste durchschnittliche Entfernung zu formellen ÖV-Haltestellen, die im Jahr 2016 bei 741 m lag und 2021 auf nur noch 699 m reduziert wurde. Die nach 2016 eröffneten U-Bahn-Haltestellen führten damit zu einer durchschnittlichen Reduktion der Gehdistanz zu formellen Verkehrshaltestellen um 42 Meter, wodurch sich der Zugang der Bevölkerung zum öffentlichen Verkehr insgesamt verbessert hat.

Im Gegensatz zur Analyse auf der Ebene des gesamten Stadtgebiets zeigen die detaillierteren räumlichen Analysen auf Sektor- und Rasterebene signifikante Unterschiede in den durchschnittlichen Gehstrecken zu den nächstgelegenen formellen ÖV-Haltestellen im Untersuchungsgebiet von Medellín (Abbildung 6.9.I.b und Abbildung 6.9.I.c). Das Muster zeigt eine klare Zentrum-




Abbildung 6.9: Durchschnittliche Entfernung zu Fuß zur nächsten ÖV-Haltestelle in ROI 1. Durchschnittliche Gehdistanzen (m) zu I) formellen und II) semiformalen Transportarten nach Transporttyp auf a) der gesamten Studiengbietsebene, b) der administrativen Ebene und c) der 1.000 m Rasterebene unter Verwendung des Bevölkerungsdatensatzes 1 (Stiller et al., 2025).

Peripherie-Dynamik: Kürzere Distanzen in zentralen, längere in peripheren Lagen. Eine detaillierte qualitative Untersuchung der U-Bahn-Haltestellen für die Jahre 2016 und 2021 auf Sektor- und Rasterebene zeigt eine erhebliche Verbesserung in der Erreichbarkeit, besonders in den nördlichen und zentral-westlichen Teilen von Medellín. Diese Gebiete profitieren am meisten von der Erweiterung des U-Bahn-Systems nach 2016. Dieser Effekt ist auch bei der Kombination von U-Bahn- und Bushaltestellen sichtbar, was zu einer weiteren Verringerung der Laufdistanzen führt. Darüber hinaus ist das Bussystem in der Lage, einige Erreichbarkeitslücken zwischen den U-Bahn-Stationen zu schließen, wodurch die Gehstrecken zwischen den U-Bahn-Stationen, insbesondere im Bereich des zentralen Bereichs des Untersuchungsgebiets, effektiv reduziert werden können.

6.3.2 Erreichbarkeit des semiformalen Verkehrs

Ein wesentlicher Bestandteil des öffentlichen Verkehrs in Medellín ist das semiformelle Netz, das vor allem von Minibussen geprägt ist. Das umfangreiche Netzwerk der Minibus-Haltestellen bildet eine dichte Abdeckung der Verkehrsmöglichkeiten im gesamten Untersuchungsgebiet, mit insgesamt 3.852 Stationen (laut der verwendeten Minibus-Haltestellendaten der lokalen Behörden

in Medellín, siehe auch Abbildung 4.7). Um den Einfluss auf die Erreichbarkeit zu bewerten, wurden für den semiformalen Minibus die selben Analysen durchgeführt, analog zu jenen, die für den formellen öffentlichen Verkehr vorgenommen wurden.

Die Erreichbarkeit der Minibus-Haltestellen liegt bei 98.9 % (Tabelle 6.4 b). Das bedeutet, dass mehr als 1,75 Millionen Personen im Untersuchungsgebiet Zugang zu den Haltestellen innerhalb eines 500-Meter-Laufweges haben, basierend auf Bevölkerungsdatensatz 1. Darüber hinaus wurde die durchschnittliche Gehstrecke zur nächsten informellen Haltestelle über verschiedene räumliche Einheiten hinweg berechnet (Abbildung 6.9.II). Mit einer durchschnittlichen Entfernung von 156 m sind die Minibus-Haltestellen auf der Ebene des gesamten Untersuchungsgebiets erreichbar (Abbildung 6.9.II.a). Dieses Muster, basierend auf einer qualitativen Untersuchung von Abbildung 6.9.II.b und Abbildung 6.9.II.c, bleibt über die untersuchten administrativen und Rastereinheiten hinweg bestehen, wobei die durchschnittliche Gehstrecke im Vergleich zu formellen Verkehrstypen entscheidend kürzer ist. Auf der Sektorebene sticht der zentral-östliche Teil des Untersuchungsgebiets mit der kürzesten durchschnittlichen Gehstrecke hervor – weniger als 100 m bis zur nächsten ÖV-Haltestelle, was die hohe Erreichbarkeit der Minibusse in dieser Region unterstreicht (Abbildung 6.9.II.b).

6.3.3 Erreichbarkeit basierend auf sozioökonomischem Status und Informalität

Basierend auf Bevölkerungsdatensatz 1 und dem erweiterten ROI 2 wurde weiter der Einfluss des sozioökonomischen Status und der Art der Siedlung (formell vs. informell) auf den Median der durchschnittlichen Gehstrecke analysiert. Dies wurde pro Sektor zur nächsten ÖV-Haltestelle pro Verkehrstyp durchgeführt, dargestellt als Boxplots. Daher wird im Folgenden der Median der durchschnittlichen Gehstrecken pro Sektor angegeben.

Abbildung 6.10 zeigt den Zusammenhang zwischen dem sozioökonomischen Status und der Entfernung zur nächsten ÖV-Haltestelle. Die Analyse offenbart, dass die höchste sozioökonomische Gruppe in der Regel längere Distanzen zurücklegt, außer beim Verkehrsmittel Bus, bei dem der Median bei 848 m liegt. Die größte Entfernung beim Busverkehr betrifft hingegen die niedrigste sozioökonomische Gruppe, mit einem medianen Abstand von 905 m. Die bis 2021 neu installierten U-Bahn-Stationen zeigen eine allgemeine Verbesserung der Erreichbarkeit. Für alle sozioökonomischen Klassen, mit Ausnahme der höchsten Klasse (Werte bleiben unverändert), werden kürzere mediane Entfernungen gemessen. Im Hinblick auf die formellen Verkehrstypen ist das offizielle Bussystem eine sinnvolle Ergänzung zum U-Bahn-System, da es in der Lage ist, die Entfernung zu den nächstgelegenen ÖV-Haltestellen weiter zu verringern. Die Entfernung aller Verkehrshaltestellen (formell und informell) ändert sich über die Zeit nur geringfügig (siehe Abbildung 6.10, untere Boxplot-Reihe). Dies unterstreicht die Bedeutung des Minibus-Systems für die Erreichbarkeit des öffentlichen Verkehrs in Medellín. Die neuen U-Bahn-Stationen verkürzten die Laufdistanz im Vergleich zu 2016 um 243 m für alle sozioökonomischen Gruppen.

Tabelle 6.5 a bietet eine detaillierte Analyse der Auswirkungen der bis 2021 neu installierten U-Bahn-Stationen auf die Laufentfernung in den untersuchten sozioökonomischen Gruppen. Für Gruppe 4, mit einem hohen sozioökonomischen Index, konnten die größten Vorteile durch die Erweiterung des U-Bahn-Systems zwischen 2016 und 2021 festgestellt werden und verzeichnete dabei einen erheblichen Rückgang der Entfernung zur nächsten U-Bahn-Station um 41.5 %. Die anderen sozioökonomischen Gruppen weisen unterschiedliche Reduzierungen der Distanz auf: Gruppe 3 zeigte eine Verringerung um 23.6 %, Gruppe 1 eine Reduktion von 15.3 %, Gruppe 2 verzeichnete einen Rückgang von 14.3 % und Gruppe 5 wies keine Veränderung der Entfernung zur nächsten U-Bahn-Station auf (Erklärung: Es gab keine Erweiterung des U-Bahn-Systems in den Sektoren der sozioökonomischen Gruppe 5 zwischen 2016 und 2021). Unterschiedliche Muster traten auf, wenn die Ergebnisse für alle formellen ÖV-Haltestellen, die sowohl U-Bahn- als auch Busstationen umfassen, betrachtet wurden. Unter den niedrigeren sozioökonomischen Gruppen konnte für Gruppe 1 und Gruppe 2 die größten Vorteile verzeichnet werden, mit einer Verringerung der Gehstrecke um 10.1 %, gefolgt von Gruppe 3 mit 8.5 % und Gruppe 4 mit 5.8 %.




Abbildung 6.10: Durchschnittliche Entfernung zu Fuß zur nächsten ÖV-Haltestelle nach sozioökonomischem Status in ROI 2. Vergleich der Gehstrecken (y-Achse) von Wohneinheiten zur nächstgelegenen Verkehrshaltestelle nach durchschnittlichem sozioökonomischen Status (x-Achse) pro Sektor, von sehr niedrig (<2) bis sehr hoch (5–6). Die medianen Entfernungswerte sind über jedem Boxplot angegeben. Zu beachten: Angepasste y-Achsen-Grenzwerte; obere Reihe: 4.200 m, untere Reihe: 420 m (Stiller et al., 2025).

Zusätzlich wurde untersucht, ob der Siedlungstyp die mittlere Laufentfernung zur nächsten ÖV-Haltestelle beeinflusst (Tabelle 6.6). Eine wichtige Erkenntnis ist, dass für die kombinierten formellen ÖV-Haltestellen (U-Bahn und Bus) die Entfernung zur nächsten Haltestelle in den Sektoren mit informellen Siedlungen größer ist. Im Gegensatz dazu sind die Entfernungen zu Minibus-Haltestellen und zu allen Haltestellen kombiniert (formell und semiformal) für informelle Siedlungstypen etwas kürzer, zugleich diese Unterschiede gering sind. Die neuen U-Bahn-Linien verringerten die Entfernungen sowohl für formelle als auch für informelle Siedlungstypen. Formelle

Tabelle 6.5: Übersicht der Unterschiede in der medianen Distanz in Prozent pro Kategorie/Gruppe zur nächsten ÖV-Haltestelle, die sich aus der Erweiterung des U-Bahn-Netzes nach 2016 ergeben. Negative Werte zeigen eine Verringerung der medianen Gehstrecke pro Sektor pro Kategorie an. Kategorien: a) durchschnittlicher sozioökonomischer Index pro Sektor; b) Siedlungstyp pro Sektor; c) Prozentsatz der Informalität pro Sektor (nach Stiller et al., 2025).

Kategorie/Gruppe	Veränderung der Laufdistanz 2016 vs. 2021 [%]	
	U-Bahn	Formeller Verkehr
a) Durchschnittlicher sozioökonomischer Index pro Sektor		
Gruppe 1 (<2)	-15,3	-10,1
Gruppe 2 (2–3)	-14,3	-10,1
Gruppe 3 (3–4)	-23,6	-8,5
Gruppe 4 (4–5)	-41,5	-5,8
Gruppe 5 (5–6)	0,0	0,0
b) Siedlungstyp pro Sektor		
formell	-28,8	-11,5
informell	-6,1	-6,3
c) Prozentsatz der Informalität pro Sektor		
<2%, nicht informell	-28,8	-11,5
2–25%	-14,4	-7,5
25–50%	-31,6	-10,5
50–75%	-7,0	-2,0
75–100%	-7,4	0,0

Hinweis: Die höchste Zahl pro U-Bahn- oder formellen Haltestellen ist fett formatiert.

Siedlungstypen profitierten jedoch deutlich mehr von den zusätzlichen U-Bahn-Linien, bei denen die mediane Entfernung von 940 m im Jahr 2016 auf 698 m im Jahr 2021 sank, was eine Verringerung der Entfernung um 242 m darstellt. Im Gegensatz dazu ist in informellen Siedlungen nur eine Reduktion von 61 m zu beobachten. Tabelle 6.5 b zeigt, dass Bewohner formeller Siedlungen einen stärkeren Rückgang der Laufentfernung erfahren haben: 28.8 % weniger zur nächsten U-Bahn-Station und 11.5 % weniger zur nächsten formellen ÖV-Haltestelle. Im Vergleich dazu ist der Rückgang für Bewohner informeller Siedlungen deutlich geringer, mit 6.1 % zur nächsten U-Bahn-Station und 6.3 % zur nächsten formellen ÖV-Haltestelle.

Um ein detailliertes Bild zu erhalten, wurde der Grad der Informalität innerhalb eines Sektors bestimmt, wobei fünf verschiedene Sektorgruppen gebildet wurden, die von formell bis informell reichen, basierend auf dem Prozentsatz der informellen Siedlungen (Abbildung 6.11). Die zusätzlichen U-Bahn-Stationen im Jahr 2021 führten im Vergleich zu 2016 zu einer Reduzierung der Entfernung, am stärksten in Sektoren mit 25 % bis 50 % Informalität (393 m), gefolgt von formellen Sektoren (282 m), Sektoren mit 2 % bis 25 % Informalität (165 m), 50 % bis 75 % Informalität (75 m) sowie 75 % bis 100 % Informalität (68 m). Daher profitieren die Sektoren mit einem höheren Anteil an informellen Siedlungen am wenigsten von der U-Bahn-Erweiterung. Die

Tabelle 6.6: Vergleich der medianen Entfernungen in m zu den ÖV-Haltestellen in Bezug auf formellen oder informellen Siedlungstyp, aufgeschlüsselt nach Transporttyp (nach Stiller et al., 2025).

<i>Transporttyp</i>	<i>Formeller Siedlungstyp</i>	<i>Informeller Siedlungstyp</i>
<i>U-Bahn (bis 2016)</i>	980 m	997 m
<i>U-Bahn (bis 2021)</i>	698 m	936 m
<i>Bus</i>	514 m	752 m
<i>Formeller Transport (Bus und U-Bahn bis 2016)</i>	479 m	650 m
<i>Formeller Transport (Bus und U-Bahn bis 2021)</i>	424 m	609 m
<i>Minibus (semiformeller Transport)</i>	128 m	115 m
<i>Alle Haltestellen (formell und semi-formell bis 2016)</i>	127 m	114 m
<i>Alle Haltestellen (formell und semi-formell bis 2021)</i>	127 m	114 m

formellen Verkehrstypen sind für Menschen, die in formellen Sektoren leben, besser zugänglich. Im Gegensatz dazu ist das semiformelle Minibus-System für Menschen, die in Sektoren mit einem Anteil von 75 % bis 100 % informellen Siedlungen leben, besser zugänglich (kürzeste Entfernung zu den Minibus-Haltestellen), was die Bedeutung dieses semiformellen Verkehrstyps für diese Sektoren unterstreicht.

6.4 Detektion von Verkehrsteilnehmenden in Webcam-Bilddaten

6.4.1 Test der YOLOv8-Parameter

Für die Detektion von Verkehrsobjekten in offenen Webcam-Daten wurde YOLOv8 eingesetzt. Zur Ermittlung optimaler IoU- und Confidence-Parameter wurden 110 Experimente durchgeführt, in denen verschiedene Kombinationen von IoU- und Confidence-Werten getestet wurden. Die Bewertung der Parameterkombinationen erfolgte anhand des F1-Scores, und eine Übersicht der Ergebnisse für YOLOv8x ist in Tabelle 6.7.

Der höchste F1-Score von 0,75 wurde mit einem Confidence-Wert von 0,1 und einer IoU von 0,4 erreicht. Das bedeutet, dass diese Parameterkombination die höchste Übereinstimmung mit dem Referenzdatensatz der sechzehn ausgewählten Webcams erzielte. Mit steigenden Confidence-Werten kann ein Rückgang der F1-Scores beobachtet werden. Zudem ergab eine ausgewogene Auswahl von Confidence-Werten zwischen 0,1 und 0,3 in Kombination mit IoU-Werten zwischen 0,1 und 0,9 durchgehend F1-Scores um 0,7.




Abbildung 6.11: Boxplots der Entfernungen zu Fuß (m) zur nächsten ÖV-Haltestelle in Abhängigkeit vom Anteil informeller Siedlungen pro Sektor (fünf Klassen). Die medianen Entfernungswerte sind über jedem Diagramm angegeben. Sektoren mit weniger als 2 % informellen Siedlungen gelten als formell. Zu beachten: Angepasste y-Achsen-Grenzwerte; obere Reihe: 4.050 m, untere Reihe: 250 m (Stiller et al., 2025).

Neben YOLOv8x wurde der F1-Score auch für die vier weniger komplexen Varianten von YOLOv8 (n, s, m, l) für alle Parameterkombinationen berechnet. Erwartungsgemäß nahm der höchste F1-Score mit zunehmender Modellkomplexität zu oder blieb gleich (F1-Scores für YOLOv8-Varianten: n=0,63, s=0,70, m=0,72, l=0,75). Folglich wurde YOLOv8x für die COVID-19-Fallstudie ausgewählt.

6.4.2 Langfristige Trendanalyse: COVID-19 Fallstudie

Die relativen Anteile der erkannten Objekte verdeutlichen die Dominanz der Klasse „Auto“ und das Ungleichgewicht zwischen den verschiedenen Klassen der Verkehrsteilnehmenden (Tabelle 6.8). Dennoch zeigen sich deutliche Unterschiede zwischen den Webcams und den einzelnen Straßen.

In der Heerstraße liegt der Anteil der Auto-Detektionen an allen erfassten Verkehrsteilnehmenden über alle Kameras und Jahre hinweg zwischen 81.3 % und 85.2 %. Am Messedamm ist dieser Wert etwas niedriger und reicht von 71.9 % bis 79.0 %. Für die Kamera in Alt-Moabit fällt der Anteil der Autos deutlich geringer aus und bewegt sich zwischen 60.6 % und 61.8 %. Auffällig ist, dass die Kamera „038 Heerstraße“ einen vergleichsweise hohen Anteil an Fußgängern aufweist, die 2018 mit 12.6 % und 2020 mit 12.7 % der Detektionen vertreten sind.

Tabelle 6.7: Zusammenfassung der F1-Scores für alle 110 getesteten Confidence- und IoU-Parameterkombinationen für die Verkehrsobjekterkennung von YOLOv8x. Der höchste F1-Score von **0,7512** bei Conf=0,1 und IoU=0,4 ist hervorgehoben (nach Stiller et al., eingereichtes Manuskript).

IoU \ Conf	0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0,0	0,0718	0,6464	0,6364	0,6161	0,5973	0,5620	0,5039	0,4444	0,3667	0,1401
0,1	0,0663	0,7069	0,6981	0,6710	0,6485	0,6146	0,5559	0,4928	0,4128	0,1478
0,2	0,0718	0,7377	0,7288	0,6983	0,6730	0,6341	0,5750	0,5121	0,4179	0,1478
0,3	0,0744	0,7506	0,7402	0,7071	0,6799	0,6416	0,5795	0,5137	0,4179	0,1478
0,4	0,0760	0,7512	0,7411	0,7087	0,6824	0,6443	0,5825	0,5137	0,4179	0,1478
0,5	0,0770	0,7494	0,7398	0,7081	0,6817	0,6443	0,5825	0,5137	0,4179	0,1478
0,6	0,0779	0,7445	0,7385	0,7081	0,6817	0,6443	0,5825	0,5137	0,4179	0,1478
0,7	0,0775	0,7405	0,7365	0,7075	0,6811	0,6443	0,5825	0,5137	0,4179	0,1478
0,8	0,0782	0,7269	0,7331	0,7055	0,6811	0,6443	0,5825	0,5137	0,4179	0,1478
0,9	0,0781	0,6704	0,7041	0,6924	0,6798	0,6436	0,5825	0,5137	0,4179	0,1478
1,0	0,0749	0,1754	0,1806	0,1803	0,1790	0,1784	0,1692	0,1638	0,1613	0,1058

In Alt-Moabit wurde ein deutlicher Anstieg des Anteils an Radfahrenden zwischen der Vor-COVID-19- und der COVID-19-Periode beobachtet: Der Wert stieg von 5.9 % im Jahr 2018 auf 8.5 % im Jahr 2020, was einer Zunahme von 2.6 % entspricht.

YOLO-Detektionen für **alle motorisierten Verkehrsteilnehmenden** während der Untersuchungszeiträume 2018 und 2020 sind in Abbildung 6.12 a dargestellt. Dabei werden sowohl absolute als auch relative Änderungen für jede Webcam aufgezeigt. Die Gesamtzahl der erkannten motorisierten Verkehrsteilnehmenden variiert über die zehn Webcams und die beiden Zeiträume hinweg zwischen knapp 150.000 und etwas über 400.000. Mit etwa 25.000 Bildern pro Kamera entspricht dies durchschnittlich 6 bis 16 motorisierten Fahrzeugen pro Bild. Unter den vier Webcams in der Heerstraße fällt die Kamera „Heerstraße 011“ durch eine auffallend niedrigere Anzahl an motorisierten Verkehrsteilnehmenden auf. Am Messedamm wurden die höchsten Werte an den Kameras „038“ und „032“ verzeichnet, gefolgt von „036“, während „040“ deutlich niedrigere Zählungen aufweist. Die Webcam in Alt-Moabit erfasste vergleichsweise geringe Werte für den motorisierten Verkehr. Ein Vergleich der Daten aus 2018 und 2020 zeigt für neun der zehn Kameras eine Abnahme der Anzahl motorisierter Verkehrsteilnehmender. Die einzige Ausnahme stellt die Webcam „007 Heerstraße“ dar, die einen leichten Anstieg aufweist. Die Rückgänge in der Heerstraße fallen dabei relativ gering aus und bleiben unter 5 %. Im Gegensatz dazu wurden an den anderen Webcams deutlich stärkere Rückgänge beobachtet, die zwischen 14 % und 32 % liegen.

Tabelle 6.8: Prozentuale Anteile der Detektionen einzelner Verkehrsklassen (Modal Split) an den Gesamtdetektionen pro Webcam im Vergleich der Jahre 2018 (vor COVID-19) und 2020 (während COVID-19) für alle zehn Webcams der COVID-19 Fallstudie. Kameras in der Heerstraße: 002, 004, 005, 007, 011; Kameras am Messedamm: 032, 036, 038, 040; Kamera in Alt-Moabit: 019 (nach *Stiller et al.*, eingereichtes Manuskript).

Klasse, Jahr	002	004	005	007	011	032	036	038	040	019
Auto, 2018	85,2%	82,2%	82,6%	84,3%	83,6%	79,0%	76,3%	71,9%	78,0%	61,8%
Auto, 2020	83,7%	81,3%	81,4%	83,6%	82,4%	78,8%	77,4%	73,2%	78,5%	60,6%
Lkw, 2018	11,4%	12,6%	13,0%	9,9%	10,7%	15,1%	14,8%	12,2%	16,4%	12,6%
Lkw, 2020	12,5%	13,6%	13,7%	10,5%	11,7%	15,7%	15,4%	11,1%	16,4%	11,7%
Bus, 2018	1,3%	2,0%	1,8%	2,0%	1,5%	2,1%	5,8%	2,0%	0,7%	1,5%
Bus, 2020	1,5%	2,2%	2,2%	2,2%	1,8%	1,3%	4,6%	1,3%	0,8%	1,0%
Motorradfahrende, 2018	0,3%	0,3%	0,3%	0,6%	0,3%	0,4%	0,4%	0,6%	0,3%	1,1%
Motorradfahrende, 2020	0,4%	0,4%	0,3%	0,5%	0,3%	0,5%	0,4%	0,6%	0,4%	1,4%
Fußgänger, 2018	1,8%	2,7%	2,2%	2,4%	3,5%	2,6%	2,6%	12,6%	4,4%	17,1%
Fußgänger, 2020	1,9%	2,3%	2,2%	2,3%	3,4%	2,4%	2,0%	12,7%	3,4%	16,9%
Fahrradfahrende, 2018	0,1%	0,2%	0,2%	0,9%	0,4%	0,8%	0,1%	0,7%	0,2%	5,9%
Fahrradfahrende, 2020	0,1%	0,3%	0,2%	0,9%	0,5%	1,3%	0,2%	1,1%	0,4%	8,5%

Die Detektionsergebnisse für **nicht-motorisierte Verkehrsteilnehmende**, bestehend aus Fußgängern und Radfahrenden, zeigen, dass diese Klassen besonders häufig an den Webcams „038 Messedamm“ und „019 Alt-Moabit“ erfasst wurden (Abbildung 6.12 b). An diesen Standorten machen **Fußgängerinnen und Fußgänger** etwa 13 % („038“) bzw. 17 % („019“) aller erfassten Verkehrsteilnehmenden aus. Im Vergleich dazu liegt der Anteil von Fußgängern an den anderen Webcams zwischen 1,8 % und 4,4 %. Der beobachtete Rückgang im nicht-motorisierten Verkehr ist vollständig auf eine Abnahme der Fußgängerzahlen zurückzuführen. Im Gegensatz dazu nahm der **Fahrradverkehr** an allen Webcam-Standorten im Jahr 2020 zu (Abbildung 6.12 c). Der stärkste Anstieg wurde an der Webcam „032 Messedamm“ festgestellt, die u.a. einen Radweg erfasst (Abbildung 4.9), mit einem Zuwachs von 45,4 %.

Abbildung 6.12 d fasst die Veränderungen in den Zahlen der Verkehrsteilnehmenden im Jahr 2020 im Vergleich zu 2018 **über alle Webcams und Nutzerklassen** zusammen. Deutliche Rückgänge sind für nahezu alle Kategorien von Verkehrsteilnehmenden erkennbar. Im Gegenteil zum Radverkehr, der einen Anstieg von über 25 % im Jahr 2020 verzeichnete. Zudem wurde eine leichte Zunahme von 2,5 % für Motorräder festgestellt.




Abbildung 6.12: Absolute und relative Veränderungen der Langzeit-Verkehrszählung mit YOLOv8 während COVID-19 in den Untersuchungszeiträumen 2018 und 2020 über alle zehn Webcams für a) motorisierte Verkehrsteilnehmende, b) nicht-motorisierte Verkehrsteilnehmende, c) Radfahrende und d) alle Verkehrsteilnehmenden (*Stiller et al.*, eingereichtes Manuskript).

Diskussion

In diesem Kapitel werden die wesentlichen Ergebnisse dieser Arbeit in Bezug auf die eingangs gestellten Forschungsfragen analysiert und interpretiert. Dabei wird auch auf die Implikationen der Ergebnisse für die bestehende Forschung eingegangen. Ziel ist es, die Erkenntnisse in einen größeren Kontext einzuordnen und mögliche Limitationen der Untersuchung zu reflektieren.

7.1 Funktionales 3D Stadtmodell für grundlegende Verkehrsparameter der urbanen Raumstruktur

In diesem Teil der Doktorarbeit wurde das Ziel gesetzt, drei Schlüsselparameter für Verkehr in Städten abzuleiten: 1) Gebäude als minimale räumliche Einheit, die als Quelle und Ziel von Wegen dienen, 2) detaillierte Landnutzungsinformationen, z. B. zur Vorhersage des Mobilitätsverhaltens, und 3) die innerstädtische Bevölkerungsverteilung, z. B. zur Schätzung der Verkehrsnachfrage. Es konnte gezeigt werden, dass diese entscheidenden, grundlegenden Parameter unabhängig generiert werden können:

- Flächendeckende Extraktion von Gebäudegrundrissen mit Hilfe eines Deep-Learning-Klassifizierungsverfahrens unter Verwendung von frei verfügbaren RGB-Bildern (siehe Abschnitt [7.1.1](#)),
- Hinzufügen von Gebäudeattributen, in diesem Fall, Höheninformationen aus hochauflösenden Tri-Stereo-Bildern, um 3D-Merkmale zu erhalten, damit das Volumen, und Anzahl der Stockwerke aus Google Street View (siehe Abschnitt [7.1.2](#)),
- Ableitung der detaillierten Landnutzung auf Einzelgebäudeebene, aus OSM-Daten, die in großem Maßstab zur Verfügung stehen (siehe Abschnitt [7.1.2](#)),
- Schätzung der Bevölkerung auf Einzelgebäudeebene mit Hilfe eines Top-Down-Ansatzes, der nur eine Gesamtbevölkerungszahl auf Gemeindeebene für das Untersuchungsgebiet benötigt, um die innerstädtische Bevölkerungsverteilung zu ermitteln (siehe Abschnitt [7.1.2](#)).

Der vorgestellte Ansatz ist übertragbar und kann flächendeckend angewandt werden, um Basisdaten der städtischen Raumstruktur, einschließlich 3D-Gebäude mit der Anzahl der Stockwerke, Landnutzung und Bevölkerung abzuleiten. Der Einsatz von Fernerkundungsdaten und -methoden

hat den Vorteil, objektive Erkenntnisse und Daten für die Verkehrsforschung zu liefern. Für viele Orte weltweit, insbesondere in Regionen des Globalen Südens, mangelt es dort oft an einer umfassenden und qualitativ hochwertigen Datengrundlage (Yuan et al., 2018). Der vorgestellte Ansatz kann dazu beitragen, diese Ungleichgewichte bei der Datenverfügbarkeit für die Verkehrsforschung zu überwinden. Dies ist ein wichtiger Aspekt, da Urbanisierung und Bevölkerungswachstum insbesondere in Ländern des Globalen Südens ausgeprägt sind (Taubenböck et al., 2024), zwei wichtige Faktoren für den Anstieg der städtischen Verkehrsnachfrage.

7.1.1 Großflächige Gebäudeextraktion mit Mask R-CNN

Am Beispiel der Megastadt Santiago de Chile wurde eine robuste Methode zur Extraktion von Gebäuden entwickelt, sowie auf den Gesamttraum von Santiago und Medellín übertragen (Abbildung 7.1). Obwohl nur eine geringe Menge an Trainingsdaten zur Verfügung stand, konnte durch Datenaugmentierungen eine OA von 92 % für Santiago und 89 % für Medellín erreicht werden. Für freistehende Einzelgebäude werden hochgenaue Gebäudeumrisse erzielt, wodurch ein fein-granularer Gebäudedatensatz erzeugt werden konnte. In komplexeren urbanen Strukturen, konnte die Klassifikationsgenauigkeit durch die angewendeten Augmentierungen erhöht werden.

Trotz der Vorteile dieser Methode gibt es einige Limitationen: So weisen die extrahierten Gebäude häufig unregelmäßige Konturen auf. Dieses Problem wurde bereits in vorangegangenen Studien dokumentiert (Zhao et al., 2018). Um dennoch klar definierte, geradlinige Außenkanten zu erzielen, kann die Klassifikation nachträglich durch eine Glättung oder Korrektur verbessert werden (Zhao et al., 2018).

Weiter zeigt die Analyse in verschiedenen Stadtregionen, dass die Klassifikationsgenauigkeit stark von der Gebäudestruktur abhängt. Geringfügige Fehlklassifikationen treten insbesondere bei großflächigeren Gebäuden mit komplexen Dachstrukturen (z. B. in Industriegebieten), sowie in dicht bebauten Wohngebieten mit niedrigen Gebäuden auf. Um diese Strukturen besser erfassen zu können, könnte das zu trainierende Netzwerk mit Daten unterschiedlicher Stadtstrukturen erweitert werden, sodass alle Gebäudetypen innerhalb einer Stadt abgedeckt sind (Stiller et al., 2019b). Es ist denkbar, bereits vor dem Training unterschiedliche Gebäudetypen innerhalb der Untersuchungsregion zu definieren (z. B. Einzelgebäude, Gebäudeblöcke, Industriegebäude), um dieses Problem gezielt zu verhindern. Dennoch bleibt zu konstatieren, dass die Extraktion einzelner Gebäude in dicht besiedelten Gebieten eine herausfordernde Aufgabe ist, selbst unter Verwendung höchstau aufgelöster Fernerkundungsbilder (Schuegraf et al., 2024; Hertrich et al., 2025).

Der vorgestellte Ansatz zur Gebäudeextraktion kann auf andere Städte übertragen werden, da es sich um eine generische Methode handelt, die lediglich auf RGB-Daten zurückgreift und nur eine geringe Menge an Trainingsdaten benötigt. Dadurch lassen sich Lücken in offenen Geodaten schließen, vor allem dort, wo es an flächendeckender Verfügbarkeit und zeitlicher Aktualität mangelt. Im Kontext des globalen urbanen Wachstums zeigt der vorgestellte Ansatz, dass sich Deep-Learning-Methoden in Kombination mit hochau aufgelösten Luftbildern effektiv zur




Abbildung 7.1: Ergebnisse der großflächigen Gebäudeextraktion mit Mask R-CNN. Oben: Beispielhafter Ausschnitt der extrahierten Gebäude (rot) im Vergleich zu den Gebäuden von OSM (blau) in Santiago de Chile; unten: Großflächiger Ausschnitt der Gebäudeextraktion in Medellín.

Entwicklung großflächiger Gebäudemodelle einsetzen lassen. Dies ist insbesondere für datenarme Megastädte des Globalen Südens relevant, in denen verlässliche Geodaten oft fehlen. Semantische Anreicherung des Gebäudemodells

7.1.2 Semantische Anreicherung des Gebäudemodells

Fusion der 2D-Gebäudedaten mit Höheninformationen: Erstellung von Level-1- und Level-2-Daten

Es wurden 2D-Gebäudegrundrissdaten mit einer Auflösung von 0.35 m mit vergleichsweise groben SPOT-7-Daten mit einer Auflösung von 2 m kombiniert. Der Vorteil dieses Verfahrens garantiert eine exakte Lokalisierung von Gebäuden, sowie die zusätzliche Information über Gebäudehöhen und -volumina für das gesamte Untersuchungsgebiet. Die relativ grobe Auflösung der SPOT-7-Daten führte zu Ungenauigkeiten bei der Ableitung der Gebäudehöhen. Die Validierung mit dem sehr hoch aufgelösten nDOM ergab einen durchschnittlichen absoluten Fehler von 2.90 m, was näherungsweise einer Abweichung von weniger als 1,5 Gebäudegeschossen entspricht. Die Analyse der vertikalen Genauigkeiten ergab weiterhin, dass der Höhenfehler umso geringer ist, je höher oder größer ein Gebäude ist. Dieses Muster deckt sich mit Erkenntnissen aus früheren Arbeiten, die satellitengestützte digitale Oberflächenmodelle mit hochaufgelösten Referenzdaten validierten (Wurm et al., 2014). Als weitere Limitierung wurde das Orthophoto-Mosaik nicht im Nadir aufgenommen, aus dem die Gebäudegrundrisse gewonnen wurden, sodass auch Gebäudefassaden aus verschiedenen Perspektiven enthalten waren. Dies führte dazu, dass Fassaden von Gebäuden fälschlicherweise in den Gebäudefootprint-Bereich einbezogen wurden und damit die Gebäudegrundfläche überschätzt wurde. Generell, stellt die Fusion von Daten aus verschiedenen Sensoren in Verbindung mit unterschiedlichen geometrischen Auflösungen eine Herausforderung dar (Stiller et al., 2019a). Das Überlagern der verwendeten Gebäudedaten (0.35 m) mit dem SPOT-nDOM (2 m) zeigte, dass die allgemeinen Gebäudeflächen weitgehend übereinstimmen, jedoch auch räumliche Verschiebungen bzw. Abweichungen aufweisen, die wiederum zu weiteren Verzerrungen im Modell führten. Trotz dieser räumlichen Inkonsistenzen konnte ein stadtweites 3D-Modell mit geringen Höhenabweichungen innerhalb eines akzeptablen Toleranzbereichs generiert werden, das beispielsweise als Grundlage für Quelle-Ziel-Analysen dienen (Sevtsuk und Mekonnen, 2012).

Innerhalb des multimodalen Ansatzes wurden Bilder aus Google Street View zur Schätzung der Anzahl der Stockwerke verwendet. Zu diesem Zweck wurde die Anzahl der Stockwerke aus den Google Street View-Bildern von insgesamt 100 Gebäuden bestimmt und ein lineares Regressionsmodell erstellt. Obwohl die in der Stichprobe erfassten Gebäude auf verschiedene Gebäudetypen und Gebiete im gesamten Untersuchungsgebiet verteilt wurden, wird bei dieser verallgemeinerten Annahme nicht zwischen den lokalen Baustilen oder der Art der Landnutzung unterschieden. In der Realität unterscheiden sich die Geschosshöhen innerhalb der Landnutzungsarten, z. B. wird in den USA für Wohngebäude eine Deckenhöhe von 2.40 m angenommen und für gewerbliche und industrielle Gebäude beträgt diese etwa 3.40 m (Zhang et al., 2013).

Eine mögliche Weiterentwicklung des Ansatzes bestünde darin, differenzierte Stichproben nach Landnutzungskategorien zu erheben und jeweils spezifische Regressionsmodelle zu entwickeln, um diesen Unterschieden Rechnung zu tragen.

Landnutzungszuordnung: Erstellung von Level-3-Daten

Für die Bestimmung der Landnutzung wurde auf offene Crowdsourcing-Daten von OSM zurückgegriffen. Crowdsourcing-Daten weisen allerdings unterschiedliche Genauigkeits- und Vollständigkeitsgrade auf (Senaratne et al., 2016). OSM-Daten haben jedoch den Vorteil, dass sie einen höheren Detailgrad in der Ableitung der Landnutzung zulassen, der z. B. bei der alleinigen Verwendung von Fernerkundungsdaten nicht möglich wäre (Fonte et al., 2017; Schultz et al., 2017). Zudem konnte festgestellt werden, dass OSM-Daten eine verlässliche Alternative für die Identifizierung der Landnutzung darstellen (Arsanjani et al., 2015). Durch die Kombination der Landnutzungspolygone und der detaillierteren POIs war innerhalb dieser Studie eine detaillierte und flächendeckende Landnutzungsklassifizierung für ganz Santiago und Medellín möglich. Darüber hinaus sind die verwendeten OSM-Datensätze für viele Orte weltweit verfügbar, was die Übertragbarkeit des Ansatzes auf andere Städte ermöglicht. Durch das Hinzufügen von Landnutzungsinformationen konnte festgestellt werden, dass die Genauigkeit der Bevölkerungsverteilung zunahm, was auch von Biljecki et al., 2016 in einer Studie zu einer landesweiten Bevölkerungsabschätzung in dieser Form bestätigt wurde und im nächsten Abschnitt ausführlicher behandelt wird.

Schätzung der Bevölkerung: Erstellung von Level-4-Daten

In diesem Abschnitt werden die Ergebnisse zur Bevölkerungsabschätzung auf der Grundlage der beiden verwendeten Raumeinheiten betrachtet: „Stadtblockebene“ und „Bezirke“. Die Hinzunahme von Landnutzungsinformationen war ein entscheidender Parameter auf der Ebene der Wohnblöcke, da sich dadurch die Modellgüte der Bevölkerungsabschätzung deutlich erhöhte (Experiment 1, alleinig auf Basis der Fläche: $R^2 = 0,11$; Experiment 5, durch Hinzunahme der Landnutzung: $R^2 = 0,41$). Bei der Verwendung von Daten mit einer geringen Informationstiefe, beispielsweise ohne Informationen zur Landnutzung, schnitten die Experimente weniger gut ab. Wenn also eine kleinräumige innerstädtische Bevölkerungsverteilung für die Zwecke der Verkehrsplanung oder -modellierung benötigt wird, so die hier erzielten Ergebnisse, dann ist die Landnutzung eine unverzichtbare Information. Bei diesen sehr kleinräumigen Einheiten mit einer durchschnittlichen Größe von $120 \times 120 \text{m}$ stoßen Ansätze, die sich ausschließlich auf Fernerkundungsdaten stützen an ihre Grenzen (Experiment 1 und 2). Ohne Landnutzungsinformationen wurde die Bevölkerung deutlich unterschätzt. TAZs sind zum Beispiel gängige Einheiten für Verkehrsmodelle (Nordenholz et al., 2019). Ihre Größe ist nicht einheitlich und ist sehr variabel, da sie durch Bevölkerungszahlen definiert wird. Dabei variieren die TAZ-Größen stark und können von der Gebäudeebene im Stadtzentrum bis hin zur Blockebene oder sogar zur Stadtteilebene in den Außenbezirken reichen (Harvey, 2002). Im Rahmen dieser Dissertation wurde die Bevölkerung auf der Ebene der einzelnen

Gebäude ermittelt. Daher kann sie räumlich flexibel auf alle größeren Einheiten aggregiert werden, z. B. auf administrative Einheiten, TAZs oder jede beliebige Rasterzellengröße. Gerade in der Verkehrsforschung ist dieser Aspekt relevant, da die zugrunde liegenden Eingangsdaten oft uneinheitlich abgegrenzt sind, etwa im Fall der TAZs, die selten standardisierte räumliche Strukturen aufweisen (Martínez et al., 2009).

Auf der Ebene größerer Raumeinheiten (z. B. Bezirke) lieferte Experiment 5 die genauesten Ergebnisse bei der Bevölkerungsabschätzung. Experiment 1, bei dem nur auf Fernerkundungsdaten basierende 2D-Daten verwendet wurden, schnitt bei der Vorhersage der Bevölkerungszahl jedoch ähnlich gut ab. Dieses Ergebnis steht im Einklang mit anderen Studien, die einen starken Zusammenhang zwischen Gebäudefläche und Bevölkerungszahl festgestellt haben (Harvey, 2002; Lu et al., 2010). Daher ist die ausschließliche Verwendung von Fernerkundungsdaten auf Bezirksebene eine durchaus gute Alternative, da sie weniger Daten, Rechenaufwand und Zeit erfordert. Die Anzahl der Stockwerke jedes Einzelgebäudes konnte auf Basis eines Regressionsmodells stadtweit approximiert werden. Die Verwendung von 3D- und Stockwerksdaten (Experiment 2 und Experiment 3) zeigte jedoch eine geringe Aussagekraft und blieb auch hinter Experiment 1 zurück, wofür ausschließlich 2D-Daten verwendet wurden. Vor diesem Hintergrund erscheint es sinnvoll, die Anzahl der in die Analyse einbezogenen Gebäude mit Stockwerksanzahl zu erhöhen, um die Schätzung der Bevölkerungsverteilung weiter zu präzisieren. Zusammenfassend lässt sich sagen, dass die ausschließliche Verwendung von Fernerkundungsdaten als angemessene Proxyvariable für die Schätzung der Bevölkerung auf Bezirksebene genutzt werden kann. Unter Verwendung weiterer Geodaten können v.a. auf der Ebene der Gebäudeblöcke bessere Ergebnisse erzielt werden, die aber auch nicht immer für jede Region verfügbar sind.

Das Validierungsverfahren der Experimente zur Bevölkerungsabschätzung ergab, dass einige der räumlichen Einheiten als statistische Ausreißer angesehen werden können. Dies hatte starke Auswirkungen auf die Gesamtgenauigkeit der Regressionsanalyse. In den Experimenten 4 und 5 konnte der CBD als starker Ausreißer für die Bevölkerungsabschätzung auf Bezirksebene identifiziert werden. Dieser Ausreißer hatte eine starke Auswirkung auf die Gesamtgenauigkeit des Endergebnisses, da die Bevölkerung massiv überschätzt wurde und sich eine Bevölkerungszahl von etwa 120.000 (Experiment 4) und 90.000 (Experiment 5) ergab, während die Zensus-Referenzdaten eine Bevölkerungszahl von etwa 20.000 ergaben. Experiment 1, das ausschließlich auf Fernerkundungsdaten basierte, lieferte mit einer geschätzten Bevölkerungszahl von etwa 17.000 eine gute Annäherung an die tatsächliche Bevölkerung. Dies stimmt mit anderen Studien überein, die eine gute Übereinstimmung von Fläche und Bevölkerung in relativ homogenen Gebieten mit ähnlicher Gebäudehöhe festgestellt haben (Wu et al., 2008). Das Stadtzentrum von Santiago ist außerdem durch relativ konstante Gebäudehöhen gekennzeichnet. Daher war die ausschließliche Verwendung von Fernerkundungsdaten zur Schätzung der Bevölkerung in diesen bebauten Gebieten eine Alternative zu detaillierteren Daten (Experiment 4 und 5). Ein möglicher Grund für die Überschätzung durch Experiment 4 und 5 im CBD ist, dass es dort relativ große und hohe Gebäude gibt, was zu einer hohen potenziellen Wohnfläche führt, obwohl anzunehmen ist, dass es

einen hohen Anteil an Gewerbe gibt. Außerdem wurden gemäß des OSM-Workflows die Klassen 'Wohnen' und 'Wohnen gemischt' ermittelt, was zu einer hohen geschätzten Bevölkerungszahl führte (Abbildung 7.2 a). Die vorgestellten Ergebnisse zeigten, dass die Fehlerquote mit dem Anteil der Landnutzung 'Wohnen gemischt' sowohl auf Stadtblock- als auch auf Bezirksebene anstieg. Steinnocher et al., 2019 stellten fest, dass eine präzise Abgrenzung zwischen Wohn- und Nicht-Wohngebieten für eine genaue Bevölkerungsabschätzung von Bedeutung ist. Der CBD war ein extremes Beispiel für dieses Phänomen im Untersuchungsgebiet. Die Eliminierung dieses Ausreißers erhöhte die Modellgüte auf der Grundlage von Experiment 5 erheblich (Abbildung 7.2 b; R^2 : 0,61; p-Wert: $<2,2e-16$). Daher wird empfohlen, den Faktor für die Verteilung der Bevölkerung für die Klasse 'Wohnen gemischt' anzupassen, um ihren Einfluss als Wohneinheiten zu verringern und damit die Gesamtgenauigkeit der Bevölkerungsabschätzung auf der Ebene der einzelnen Gebäude zu erhöhen.




Abbildung 7.2: Klassifizierte Gebäude mit Landnutzung in Santiago de Chile. (a) Karte des CBD und klassifizierte Gebäude mit zugewiesener Landnutzung; (b) Streudiagramm von Experiment 5 auf Bezirksebene nach Entfernung des 'Ausreißers' CBD (R^2 : 0,61; p-Wert: $<2,2e-16$) (Stiller et al., 2021).

7.2 Erreichbarkeit von öffentlichem Verkehr in Medellín

In diesem Abschnitt der Dissertation liegt der Fokus auf der Analyse der Erreichbarkeit öffentlicher Verkehrsmittel in Medellín. Die Erreichbarkeit wird dabei im Hinblick auf die fußläufige Distanz zur nächsten Haltestelle gemessen, wie sie im Indikator 11.2 der UN definiert ist. Im Folgenden werden die zentralen Ergebnisse zusammengefasst und entlang der formulierten Teilfragen dargestellt. Zudem werden Verbindungen zwischen den Ergebnissen und der bestehenden Literatur gezogen, um die Stärken und Schwächen zu erörtern. Abschließend wird dieser Teil der Dissertation zusammengefasst und die grundlegenden Aspekte hervorgehoben.

Teilfrage 1: *Wie variiert die Erreichbarkeit innerhalb des Stadtgebiets?*

Für **Teilfrage 1** wurde eine erhebliche geographische Ungleichheit in der Erreichbarkeit in Medellín festgestellt. Die Ergebnisse zeigten, dass der zentrale städtische Kern durchgehend die höchsten Erreichbarkeiten für alle untersuchten Verkehrsträger aufwies. Im Gegensatz dazu wiesen Regionen am Rande des Stadtgebiets niedrigere Erreichbarkeiten auf, was für eine ausgeprägte ungleiche Verteilung der Erreichbarkeit in Medellín spricht. Zentrale Stadtgebiete verfügen typischerweise über eine bessere Erreichbarkeit. Dies zeigt sich beispielsweise in Melbourne, wo Gebiete mit einer besseren ÖV-Erreichbarkeit auch eine intensivere Nutzung des öffentlichen Verkehrs aufweisen (Saghapour et al., 2016). Ähnlich ist die Situation in Santiago de Chile, wo zentrale Bereiche einen besseren Zugang zu Bildungseinrichtungen bieten als periphere Gebiete (Tiznado-Aitken et al., 2018). Im Gegensatz dazu ist die Erreichbarkeit öffentlicher Verkehrsmittel in peripheren Stadtteilen häufig schlechter. In Dar es Salaam etwa sind Einwohner peripherer Siedlungen auf den öffentlichen Verkehr angewiesen, nehmen jedoch lange Reisezeiten in Kauf, bedingt durch schlechte Straßeninfrastruktur und Verkehrsbedingungen (Andreasen und Møller-Jensen, 2017). In Shanghai berichten Fahrgäste aus den Randbereichen der Stadt, dass sie aufgrund langer Wartezeiten und begrenzter Angebotsvielfalt mit dem öffentlichen Nahverkehr unzufrieden sind (Guan et al., 2020). Auch in brasilianischen Städten zeigen sich in peripheren Lagen geringere Erreichbarkeiten von Arbeitsplätzen und Dienstleistungen, was soziale Ungleichheiten zusätzlich verstärkt (Bittencourt et al., 2020).

Teilfrage 2: *Zeigt die Erreichbarkeit Unterschiede durch die Nutzung von formellen und semiformellen Verkehrsmitteln? Inwieweit trägt informeller öffentlicher Verkehr zur gesamten Erreichbarkeit des öffentlichen Verkehrs bei?*

Bezüglich der **Teilfrage 2** ergab die Untersuchung einen starken Unterschied in der Erreichbarkeit zwischen den formellen und semiformellen Verkehrsmitteln (Abbildung 7.3). Die höchste Erreichbarkeit mit 98.9%, wurde für den semiformellen Minibus-Verkehr festgestellt. Dieser Wert übertraf die kombinierte Erreichbarkeit aller formellen Verkehrshaltestellen, einschließlich sowohl der Bus- als auch der U-Bahn-Haltestellen, die 2021 bei 62.8% lagen, sowie die berechnete Erreichbarkeit von 38.35% laut UN-Habitat (UN-Habitat, 2021a). Diese Ergebnisse unterstreichen den Beitrag semiformeller Verkehrsträger für die Erreichbarkeit des öffentlichen Verkehrs in Medellín. Semiformelle und informelle Verkehrsmittel spielen insbesondere in städtischen Gebieten mit unzureichender Abdeckung durch formelle Verkehrssysteme eine zentrale Rolle, um Funktionen der Stadt erreichen zu können. In Städten wie Alexandria, Ägypten, ergänzen beispielsweise Mikrobusse das formelle öffentliche Verkehrsangebot, indem sie Bereiche erschließen, die von Bussen oder Schienenverkehr aufgrund ihrer festen Linienführung nicht erreicht werden (ElDeeb et al., 2024). Genau dieser Effekt konnte auch in dieser Dissertation empirisch für Medellín nachgewiesen werden. Darüber hinaus sind solche Verkehrsmittel besonders bedeutsam für benachteiligte Bevölkerungsgruppen, so profitieren etwa Straßenverkäuferinnen in Kampala, Uganda, von neu eingerichteten Minibuslinien, die ihnen einen besseren Zugang zu urbanen Zentren ermöglichen (Kerzhner, 2024).




Abbildung 7.3: Distanz zu Fuß zur nächsten Haltestelle des öffentlichen Verkehrs für einen beispielhaften Ausschnitt des Studiengebietes in Medellín. Oben: Distanz zum formellen Verkehrssystem (U-Bahn und Bus); unten: Distanz zum semiformellen Verkehrssystem (Minibus).

Teilfrage 3: *Welche Rolle spielt die Erweiterung des U-Bahnsystems in Medellín (2016 vs. 2021) bei der Verbesserung der Erreichbarkeit zu öffentlichen Verkehrsmitteln?*

Ein weiteres zentrales Ergebnis in Bezug auf **Teilfrage 3** ist die deutliche Verbesserung der Erreichbarkeit durch die Erweiterung des U-Bahn-Systems zwischen 2016 und 2021. Die Erreichbarkeit der U-Bahn-Stationen allein stieg erheblich – 11.9 % mehr Bewohner als zuvor hatten Zugang zu diesem Verkehrsmittel mit hoher Kapazität. Dieser positive Effekt zeigte sich auch in der allgemeinen Erreichbarkeit formeller ÖV-Haltestellen, die sowohl U-Bahn- als auch Busstationen umfassen: 9.5 % der Bevölkerung erhielten zusätzlich Zugang zum öffentlichen Verkehr.

Teilfrage 4: *Gibt es Unterschiede in der Erreichbarkeit zu öffentlichen Verkehrsmitteln in informellen Siedlungen im Vergleich zu formellen Siedlungen und wie korreliert die Erreichbarkeit mit sozioökonomischen Faktoren?*

Zudem wurde im Hinblick auf **Teilfrage 4** festgestellt, dass die Erreichbarkeit zum öffentlichen Verkehr eng mit sozioökonomischen Faktoren verknüpft ist. Besonders die Gruppe mit hohem sozioökonomischen Index (Gruppe 4) profitierte am meisten von der U-Bahn-Erweiterung nach 2016, mit einer Reduktion der Entfernung um 41.5 %. Im Gegensatz dazu ist für die niedrigste sozioökonomische Gruppe (Gruppe 1) die geringste Verbesserung mit einer Reduktion von 15.3 % zu verzeichnen. Dies unterstreicht, dass es den lokalen Behörden zwar gelungen ist, die Fußwegedistanzen über die sozioökonomischen Gruppen hinweg zu verringern, die Vorteile jedoch nicht gleichmäßig verteilt sind. Zudem variiert die Erreichbarkeit je nach Siedlungstyp. Nach den empirischen Befunden dieser Studie, haben die Bewohner informeller Siedlungen über alle Verkehrsmittel hinweg eine schlechtere Erreichbarkeit. So sind die Fußwege zu formellen öffentlichen Verkehrsträgern für Bewohner informeller Siedlungen 185 m länger (609 m) als für Bewohner formeller Siedlungen (424 m) (basierend auf formellen Haltestellen für das Jahr 2021). Darüber hinaus wurde auch festgestellt, dass Einwohner, die in Sektoren mit dem höchsten Anteil an Informalität (50 % bis 75 % und 75 % bis 100 %) leben, am wenigsten von der Erweiterung der U-Bahn profitierten. Am meisten profitierten hingegen die Gruppen, die in Sektoren mit 25 % bis 50 % Informalität lebten. Somit sind die Vorteile erneut nicht gleichmäßig auf alle Bewohner verteilt, was die entscheidende Rolle des Minibus-Systems für Bewohner der informellen Gebiete unterstreicht. Die Haltestellen des Minibusses werden am besten von Bewohnern in Sektoren mit einem Anteil von 75 % bis 100 % Informalität erreicht (Entfernung von 77 m), gefolgt von Sektoren mit 50 % bis 75 % (Entfernung von 112 m) und 25 % bis 50 % (Entfernung von 124 m) Informalität.

Anhand der Ergebnisse konnte festgestellt werden, dass das semiformelle Minibus-System in Medellín entscheidend dafür ist, die lokale Bevölkerung aus informellen Siedlungen mit dem öffentlichen Verkehrssystem der Stadt zu verbinden. Das formelle öffentliche Verkehrssystem allein würde den Bewohnern informeller Siedlungen nur Zugang mit erheblich längeren Fußwegen zum Stadtzentrum ermöglichen. Den Behörden ist es allerdings gelungen, die Erreichbarkeit in

informellen Siedlungen durch den Ausbau des U-Bahnsystems zu verbessern, insbesondere mit der Einführung der neuen Seilbahnlinien. Die Wirksamkeit der Seilbahnen in Medellín zur Anbindung an die Stadt wurde bereits in der Literatur nachgewiesen (Heinrichs und Bernet, 2014). Allerdings müssen Bevölkerungsgruppen mit niedrigem sozioökonomischen Status weiterhin längere Wege zurücklegen, um diese effizienten formellen Verkehrsmittel zu erreichen. Die Ungleichheit beim Zugang zu sicherem, zuverlässigem und reguliertem öffentlichem Verkehr besteht somit fort und diese Studie konnte darstellen, dass durch die U-Bahn-Erweiterung dieser Effekt lediglich abgemildert werden konnte. Ein sicherer und für alle zugänglicher öffentlicher Verkehr ist eine Schlüsselfunktion zur Vermeidung sozialer Exklusion, insbesondere in Ländern des Globalen Südens, wo er eine zentrale Rolle für soziale Teilhabe spielt (Brussel et al., 2019). Öffentlicher Verkehr kann eine transformative Wirkung für marginalisierte städtische Bereiche haben Heinrichs und Bernet, 2014. Daher ist es von zentraler Bedeutung, eine Verkehrsplanung zu fördern, die auf eine gleichberechtigte Erreichbarkeit abzielt.

Teilfrage 5: *Können Fernerkundungsdaten als praktikable Lösung zur Überbrückung der Datenlücke in Gebieten ohne Bevölkerungsdaten dienen, insbesondere in Regionen mit weniger verlässlichen Daten, wie dem Globalen Süden?*

Für **Teilfrage 5** ergab sich, dass Bevölkerungsdaten, die mit Hilfe von Fernerkundungsdaten abgeleitet wurden, eine praktikable Alternative zu offiziellen Zensusdaten darstellen. Insbesondere konnte gezeigt werden, dass Ansätze, die regionale Gegebenheiten einbeziehen (Datensatz 2), den global verfügbaren Bevölkerungsdatensätzen (Datensatz 3) vorzuziehen sind, da sie eine höhere Übereinstimmung mit dem Referenz-Bevölkerungsdatensatz (Datensatz 1) aufweisen. Diese Erkenntnis unterstreicht das Potenzial fernerkundungsbasierter Bevölkerungsdatensätze insbesondere in datenarmen Regionen, um so die Erreichbarkeit von ÖV besser abschätzen und analysieren zu können.

Soweit aus der Literatur ersichtlich, gehört diese Untersuchung zu den ersten, die fernerkundungsbasierte Bevölkerungsdaten in Analysen zur Erreichbarkeit des öffentlichen Verkehrs einbezieht, um Bevölkerungsdaten unterschiedlicher räumlicher Auflösung systematisch zu vergleichen und mit offiziellen Statistiken abzugleichen. Damit leistet diese Untersuchungen einen Beitrag zur Forschung, indem sie die potenzielle Rolle von Fernerkundung als ergänzende Datenquelle bei fehlenden oder unzureichenden Zensusdaten aufzeigt. Zudem wurde gezeigt, wie regionsspezifische Bevölkerungsdatensätze (Datensatz 2) die räumliche Verteilung der Bevölkerung besser erfassen als globale Datensätze (Datensatz 3), die lokale Variationen oft nicht abbilden können. Diese differenzierten Bevölkerungsdaten könnten die Verkehrsplanung und die Bewertung der Erreichbarkeit in schnell wachsenden städtischen Gebieten effektiver und gerechter gestalten.

Darüber hinaus konnten die Ergebnisse die Bedeutung des semiformalen Minibusses für die Gesamt-Erreichbarkeit des öffentlichen Verkehrs in Medellín unterstreichen. Diese semiformalen Verkehrssysteme schließen Erreichbarkeitslücken des formellen öffentlichen Verkehrs und spielen

damit eine zentrale Rolle für die Mobilität in Ländern des Globalen Südens (Cervero und Golub, 2007; Guillen et al., 2013; Kumar et al., 2016; Kerzhner, 2024). Die Ergebnisse liefern wertvolle Einblicke in die ausgeprägten Unterschiede in der Erreichbarkeit des öffentlichen Verkehrs zwischen formellen und informellen Siedlungen und stehen im Einklang mit Erkenntnissen anderer Studien (Boisjoly et al., 2017; Hidayati et al., 2020). Sie tragen damit zu einem differenzierteren Verständnis der räumlichen und sozioökonomischen Ungleichheiten in der städtischen Verkehrsversorgung bei. Zudem konnten empirisch deutliche Verbesserungen der Erreichbarkeit formeller öffentlicher Verkehrsmittel nachgewiesen werden, in diesem Fall durch die Erweiterung des U-Bahnsystems um neue Seilbahnlinien innerhalb eines Fünfjahreszeitraums. Wie die Ergebnisse dieser Studie zeigen, konnten auch Bewohner informeller Siedlungen von diesen Maßnahmen profitieren – ein Befund, der die Bedeutung gezielter Infrastrukturinvestitionen zur Verringerung von Ungleichheiten der ÖV-Erreichbarkeit in Medellín unterstreicht. Die Ergebnisse fördern das Verständnis urbaner Verkehrssysteme in datenarmen Regionen und liefern Entscheidungshilfen für eine gerechtere Mobilitätsplanung. Die Erreichbarkeitsmuster zeigen klar, wo formeller öffentlicher Verkehr fehlt und wo Verbesserungen prioritär umgesetzt werden sollten. Dies wird besonders in den Randgebieten der Stadt deutlich (vgl. Abbildung 6.9 b und c). Während die Erweiterung des U-Bahnsystems die Erreichbarkeit zu formellem öffentlichen Verkehr erhöht hat (vgl. Tabelle 6.6), waren die Vorteile für Bewohner mit höherem sozioökonomischem Status in formellen Siedlungen im Vergleich zu denen mit niedrigerem sozioökonomischen Status in informellen Siedlungen überproportional größer (vgl. Tabelle 6.5). Dies unterstreicht den dringenden Bedarf an gezielten Maßnahmen seitens der lokalen Behörden, um Ungleichheiten bei der Erreichbarkeit des öffentlichen Verkehrs weiter zu verringern, mit besonderem Fokus auf die Verbesserung der ÖV-Erreichbarkeit für marginalisierte Gruppen.

Darüber hinaus wurde die Erreichbarkeit von Haltestellen des öffentlichen Verkehrs für verschiedene Szenarien betrachtet: Dabei wurden der Einfluss verfügbarer Bevölkerungsdaten, Verkehrsträger, sozioökonomischer Faktoren und Informalität berücksichtigt. Die Aussagekraft der durchgeführten Analysen ist in hohem Maße von der Qualität und Zuverlässigkeit der verwendeten Datengrundlagen abhängig. Potenzielle Limitationen ergeben sich insbesondere durch die Nutzung frei verfügbarer Verkehrshaltestellendaten, deren Vollständigkeit und Genauigkeit nicht vollständig überprüft werden konnten. Ein wesentlicher Nachteil von Open-Source-Daten ist ihre stark variierende Qualität (Biljecki et al., 2023). Dennoch sind sie oft die einzige Alternative, wenn offizielle Daten fehlen.

Die detaillierten geographischen Analysen dieser Untersuchung zeigen eine erhebliche Variabilität der Erreichbarkeit in Medellín – eine Differenzierung, die in der UN-Methode, welche die Stadt als einheitliches Gebiet betrachtet, nicht berücksichtigt wird. Ein Vergleich ist lediglich mit den Berechnungen von UN-Habitat möglich, die eine Erreichbarkeit des formellen Verkehrs von 38.35 % ermittelten, während die Ergebnisse dieser Arbeit einen Wert von 62.8 % ergeben. Die

Unterschiede könnten auf die Verwendung unterschiedlicher Bevölkerungsdaten, Straßennetzdaten, ÖV-Haltestellen-Daten, oder eines unterschiedlichen Routingansatzes, sowie auf unterschiedliche Abgrenzungen des Untersuchungsgebiets zurückzuführen sein.

Während der Fokus dieser Untersuchung auf die ÖV-Erreichbarkeit im Hinblick auf die Gehdistanz zu Haltestellen konzentriert, spielen weitere Faktoren eine entscheidende Rolle bei der Wahl des Verkehrsmittels. Dazu zählen beispielsweise zeitliche Faktoren wie Frequenz und Reisedauer, sowie Zuverlässigkeit. Diese Informationen sind jedoch in Kontexten, die durch semiformalen und informellen Verkehr gekennzeichnet sind, häufig nicht verfügbar und/oder nicht verlässlich genug (Williams et al., 2015). In dieser Studie waren entsprechende Daten allerdings nicht verfügbar. Dennoch ist es im Rahmen solcher Betrachtungen wichtig, die Qualität des öffentlichen Verkehrs zu integrieren (Cervero und Golub, 2007). Die systematische Erhebung und Integration entsprechender Daten sollte in zukünftigen Studien stärker in den Fokus rücken, um fundierte Planungsgrundlagen für eine verbesserte und gerechtere Erreichbarkeit des öffentlichen Verkehrs in benachteiligten Stadtteilen bereitzustellen.

Während Umweltfaktoren wie Wetterbedingungen oder Temperaturen die Erreichbarkeit des öffentlichen Verkehrs beeinflussen können, insbesondere in Regionen mit bedeutender saisonaler oder klimatischer Variabilität, wurden diese Faktoren in dieser Analyse nicht berücksichtigt. Das Untersuchungsgebiet konzentrierte sich auf Medellín, eine Stadt mit relativ stabilen Temperaturen aufgrund ihrer äquatorialen Lage, aber mit bimodalen Regenzeiten im April-Mai und Oktober-November. Perioden starker Regenfälle können die Erreichbarkeit beeinträchtigen, insbesondere in Gebieten, die anfällig für Überschwemmungen sind oder über weniger resiliente Infrastruktur verfügen (Li et al., 2018). Der Fokus hier lag auf strukturellen und sozioökonomischen Einflüssen, Umweltvariablen wurden jedoch nicht berücksichtigt. Zukünftige Studien, die mehrere Städte oder Regionen untersuchen, könnten solche Faktoren einbeziehen, um ein umfassenderes Verständnis ihrer Auswirkungen auf die ÖV-Erreichbarkeit zu ermöglichen.

Die Analysen beruhen auf einer Routing-Methode anstelle der euklidischen Distanz. Allerdings berücksichtigt der distanzbasierte Ansatz, der sowohl von der UN als auch in dieser Untersuchung genutzt wird, keine Erreichbarkeitsbarrieren. Erreichbarkeitsbarrieren umfassen Aspekte wie die Qualität der urbanen Umgebung, Erschwinglichkeit, Zuverlässigkeit, geschlechtsspezifische Sicherheitswahrnehmungen, Kapazität des Verkehrs, fehlende Verfügbarkeit zu bestimmten Zeiten oder die Unerreichbarkeit bestimmter Ziele (Tiznado-Aitken et al., 2018). Vor diesem Hintergrund muss die Laufentfernung als eine die Realität vereinfachende Näherungsinformation angesehen werden.

Trotz der genannten Limitationen bietet der vorgestellte Ansatz zur Messung der Erreichbarkeit von ÖV-Haltestellen eine vergleichsweise robuste, global anwendbare Methode, die unabhängig von hochdetaillierten lokalen Datensätzen funktioniert und somit insbesondere für datenarme Regionen einen wichtigen Beitrag zur internationalen Vergleichbarkeit und evidenzbasierten Verkehrsplanung leisten kann.

7.3 Detektion von Verkehrsteilnehmenden auf Webcam-Bilddaten

Offene Webcams bieten die Möglichkeit Verkehr zu erfassen. In diesem Teil der Dissertation wurden frei zugängliche Webcam-Bilder mit vortrainierten YOLOv8-Objekterkennungsmodellen kombiniert, um Verkehrsteilnehmende in städtischen Umgebungen zu zählen und zu analysieren. Dafür wurden sechzehn Webcams mit einer temporalen Auflösung von einer Minute ausgewählt und ein spezifischer Workflow für die Vorprozessierung und Filterung erarbeitet. Zur Bewertung von 110 Parameterkombinationen für die Confidence- und IoU-Schwellenwerte von YOLOv8 wurde ein manuell annotierter Referenzdatensatz erstellt. Der höchste F1-Score von 0,75 wurde mit YOLOv8x bei einem Confidence-Wert von 0,1 und einem IoU-Wert von 0,4 erzielt. Dieses optimierte Modell wurde anschließend auf fast 500.000 Bilder angewendet, die von zehn Berliner Webcams im Herbst 2018 (vor COVID-19) und Herbst 2020 (während COVID-19) aufgenommen wurden. Die resultierende Analyse lieferte wertvolle Einblicke in lokale Verkehrsmuster und zeigte über die meisten Klassen hinweg signifikante Rückgänge in der Anzahl der Verkehrsteilnehmenden zwischen den Zeiträumen vor und während COVID-19, wobei Unterschiede je nach Straße und Nutzertyp festgestellt wurden. Auffällig war ein deutlicher Anstieg der Anzahl an Radfahrenden, was auf mögliche Veränderungen im Mobilitätsverhalten während der Pandemie hinweist.

7.3.1 Webcam-Daten zur Zählung von Verkehrsteilnehmenden

Ein zentrales Merkmal dieser Analyse war die ausschließliche Nutzung offener Webcam-Daten in Kombination mit Open-Source-Software für die Detektion von Verkehrsteilnehmenden. Dieser Ansatz reduziert die Kosten und den Aufwand für eine in-situ-Datenerfassung erheblich und ermöglicht zugleich die Analyse des Verkehrsaufkommens über längere Zeiträume. Die Nutzung von Webcam-Daten erlaubte zudem Trend- und Veränderungsanalysen, beispielsweise durch den Vergleich der Verkehrsteilnehmenden in den Zeiträumen vor und während COVID-19, wodurch wertvolle Erkenntnisse über die Änderungen des Mobilitätsverhaltens gewonnen werden konnten.

Die Nutzung offener Webcam-Daten bringt jedoch auch spezifische Herausforderungen mit sich. Forschende und Anwender können beispielsweise keinen direkten Einfluss auf die genaue Platzierung der Kameras, ihr Sichtfeld, die Bildqualität oder die Wartung nehmen. Für eine optimale Verkehrsdetektion sollten Kameras idealerweise den gesamten Straßenquerschnitt erfassen, damit die relevanten Objekte in einer erkennbaren Größe dargestellt sind (Aung und Lwin, 2024). Dadurch würde die Überlagerung der Verkehrsobjekte und die Erfassung nicht-verkehrsbezogener Elemente reduziert werden und. Die verwendeten Webcams wiesen jedoch in unterschiedlichem Maße Abweichungen von diesen idealen Bedingungen auf (Abbildung 4.9), was die Vergleichbarkeit der erfassten Detektionen zwischen verschiedenen Standorten einschränken könnte (Zhang et al., 2022).

Darüber hinaus können schlechte Lichtverhältnisse die Genauigkeit der Detektion reduzieren (Al-qaness et al., 2021; Zhu et al., 2021). Daher wurden Bilder, die während lichtarmer Zeiträume, wie den frühen Morgen- und späten Abendstunden, aufgenommen wurden, bereits vorab als

Teil der Vorprozessierung herausgefiltert. Diese Filterung reduzierte die täglich für die Analyse verfügbare Bildanzahl, wobei diese auftretenden Unterschiede in den nachfolgenden Analysen berücksichtigt wurden. Allerdings stellt dieser Schritt auch eine Limitation dar, da nächtliche Verkehrsbewegungen ausgeschlossen wurden, was die Gesamtaussagekraft der Ergebnisse potenziell beeinflusst.

Trotz dieser Einschränkungen ermöglichte die temporale Auflösung der Webcams von einem Bild pro Minute eine vergleichende Analyse der Verkehrsteilnehmenden. Dies unterstreicht das Potenzial von Webcams mit ähnlicher zeitlicher Auflösung als wertvolle Datenquellen für langfristige Trendanalysen. Während verwandte Studien häufig Videoaufnahmen für die YOLO-basierte Verkehrserkennung verwenden (Al-qaness et al., 2021; Azimjonov und Özmen, 2021; Tung et al., 2019), bieten Videos zwar eine höhere temporale Auflösung, erhöhen jedoch auch erheblich die Anforderungen an die Speicherkapazität und die Verarbeitung und Analyse der Daten, insbesondere bei längeren Beobachtungszeiträumen, wie sie in dieser Fallstudie untersucht wurden.

7.3.2 Detektion von Verkehrsteilnehmenden mit YOLOv8

Für die Objekterkennung wurde ein YOLOv8x-Modell eingesetzt, das basierend auf dem COCO-2017-Datensatz trainiert worden war. Zur Bestimmung der optimalen Parameterkombination für die Confidence- und IoU-Werte wurden 110 Konfigurationen getestet, wodurch ein robuster F1-Score von 0,75 erzielt wurde. Der Schwerpunkt lag auf der Bewertung der Leistung des YOLOv8-Modells ohne Fine-Tuning, um den arbeits- und zeitintensiven Prozess der zusätzlichen Anpassungen zu vermeiden, der manuelle Annotationen, Fachwissen und oft nicht verfügbare Rechenressourcen wie GPUs erfordert. Obwohl Fine-Tuning in verwandten Studien als effektiv nachgewiesen wurde (z. B. Azimjonov und Özmen, 2021; Cao et al., 2019; Stark et al., 2023), ist es mit erheblichen Arbeitsaufwänden verbunden. Bei einer Schätzzeit von einer Minute pro Bild würde die Annotation beispielsweise 447 Stunden für 26.820 Bilder (Cao et al., 2019) oder 120 Stunden für 7.216 Bilder (Azimjonov und Özmen, 2021) in Anspruch nehmen. Techniken wie Data Augmentation (Stiller et al., 2019b) oder synthetisches Oversampling (Jain et al., 2020) könnten den Annotierungsaufwand jedoch reduzieren und letztlich die Modellleistung verbessern.

Für die Erstellung eines Referenzdatensatzes von 48 Bildern, wurden jeweils drei Bilder pro Webcam zufällig ausgewählt. Dieser Datensatz umfasste insgesamt 662 annotierte verkehrsrelevante Objekte und wies ein stärkeres Klassenungleichgewicht auf, mit 507 Autos, 80 Lastwagen und 45 Personen. Diese Ungleichverteilung könnte die Modellleistung insbesondere für seltener vorkommende Klassen beeinflussen und sollte bei der Interpretation der Ergebnisse berücksichtigt werden. Weniger repräsentierte Klassen umfassten Busse (12), Fahrräder (11) und Motorräder (7), was sowohl die Webcam-Standorte (z. B. stark befahrene Straßen wie Heerstraße und Messedamm) widerspiegelt als auch bereits in der Literatur beobachtete Muster bestätigt (Liu et al., 2017). Eine klassenbasierte Stichprobenziehung könnte diese Ungleichverteilung effektiver ausgleichen als eine zufällige Auswahl.

Obwohl YOLOv8x ohne Anpassungen eine robuste Leistung erzielte, traten in bestimmten Szenarien Fehldetektionen auf (Abbildung 7.4). Besonders schlechte Licht- und Wetterbedingungen führten zu übersehenen Objekten (Cao et al., 2019; Zhang et al., 2022). Überlagerungen und dicht gedrängte Fahrzeuge, wie in Abbildung 7.4 c gezeigt, führten dazu, dass Hintergrundobjekte nicht erkannt wurden, ein Problem, von dem auch in verwandten Studien berichtet wurde (Cao et al., 2019; Jiang et al., 2022; Zhang et al., 2022).

Zu den weiteren Fehlern zählten Fehlklassifikationen (z. B. Straßenschilder als Lastwagen), sich überlappende Mehrfachdetektionen (z. B. Sprinter-Vans, die gleichzeitig als Autos und Lastwagen klassifiziert wurden), sowie Ungenauigkeiten bei der Fußgängerzählung aufgrund nicht erkannter Fußgänger, erkannte Person im Fahrzeug oder Werbebilder, wie in Abbildung 7.4 b, d, e und f dargestellt. Tabelle 7.1 fasst die identifizierten Fehlertypen zusammen und unterscheidet zwischen systematischen, zufälligen, Detektions- und semantischen Fehlern. Während einzelne Fehler in großen Datensätzen vernachlässigbar sind, könnten systematische Fehler (z. B. statische Fehlklassifikationen) die Ergebnisse verzerren. Eine verbesserte Vorverarbeitung, etwa durch Bildzuschnitte, könnte helfen, diese Probleme zu minimieren.

Insgesamt kann die Detektionsleistung von YOLOv8 als robust bewertet werden, insbesondere in Anbetracht, dass kein zusätzliches Fine-Tuning stattgefunden hat. Während in einer verwandten Studie durch groß angelegtes Fine-Tuning ein F1-Score von über 0,9 erzielt wurde (Azimjonov und Özmen, 2021), stellt der erreichte F1-Score von 0,75 ein vielversprechendes Ergebnis dar.




Abbildung 7.4: Beispielbilder aus dem Fallstudien-Datensatz zur Veranschaulichung möglicher Detektionsfehler mit YOLO. (a) zufälliger Detektionsfehler verursacht durch Überbelichtung von Scheinwerfern auf einer nassen Fahrbahnoberfläche; (b) systematischer Detektionsfehler, der eine Straßenmarkierung als Auto identifiziert; (c) systematischer Detektionsfehler aufgrund von Überlagerung der Objekte durch Stauung vor einer Ampel; (d) zufälliger Detektionsfehler, der zu einer falsch-negativen Detektion für eine Person auf einem Fahrrad führt; (e) systematischer semantischer Fehler bei der Klassifizierung von (Sprinter-) Vans als „Auto“ oder „Lastwagen“; (f) zufälliger semantischer Fehler aufgrund einer erkannten Person auf einer Lastwagen-Werbung (Stiller et al., eingereichtes Manuskript).

Tabelle 7.1: Schematische Skizzierung verschiedener Fehlertypen, die bei der Verwendung von offenen Webcam-Bildern und dem vortrainierten YOLOv8x auftraten (nach *Stiller et al.*, eingereichtes Manuskript).

	Systematische Fehler	Zufällige Fehler
Detektionsfehler	Falsch positive (FP) für statische Objekte, wie Straßenschilder, Straßenmarkierungen usw.	Gelegentliche falsch positive (FP) und falsch negative (FN) für Verkehrsteilnehmende.
	Falsch negative (FN) in Kamera-Sichtfeldern mit häufigen Überlagerungen von Verkehrsteilnehmenden.	Schlechte Sichtbarkeit aufgrund von Wetterbedingungen, Dunkelheit oder Fahrzeugscheinwerfern.
Semantische Fehler	Für Radfahrende/Motorradfahrende: getrennte Detektion von Fahrrädern/Motorrädern und Person.	Einzelne Detektionen irrelevanter Elemente, z. B. Person im Fahrzeug oder abgebildete Personen auf Fahrzeugwerbung.
	Für (Sprinter-) Transporter und ähnlich große Fahrzeuge: Fehlklassifikation als „Auto“ oder „Lkw“.	

7.3.3 Langzeit-Verkehrsmonitoring: Detektion von Verkehrsteilnehmenden in Webcam-Szenen vor und während COVID-19

Die Fallstudie in Berlin konzentrierte sich auf relative Verkehrsänderungen im Jahr 2020 im Vergleich zu 2018, unter der Annahme, dass YOLO-Detektionsfehler über beide Zeiträume hinweg konsistent auftauchen. Folglich werden die prozentualen Änderungen innerhalb der fast 500.000 analysierten Webcam-Szenen als robust angenommen, trotz potenzieller Verzerrungen in den absoluten Werten.

Faktoren jenseits der COVID-19-Pandemie könnten jedoch die beobachteten Verkehrsunterschiede beeinflusst haben. Zwei mögliche Störfaktoren wurden untersucht: Erstens wurden Bauarbeiten und andere Einschränkungen und Störungen des Verkehrs durch Online-Recherchen und visuelle Analysen von Webcam-Bildern bewertet. Da keine signifikanten Bauprojekte oder Störungen für die Studienzeiträume gefunden wurden (Verkehrsinformationszentrale Berlin, 2023b), ist davon auszugehen, dass dieser potentielle Störfaktor ausgeschlossen werden kann. Zweitens wurden Wetter- und Lichtverhältnisse, die sowohl die Detektionsleistung von YOLO (Al-qaness et al., 2021; Zhu et al., 2021) als auch die Verkehrsmittelwahl beeinflussen, mit Daten der Station Berlin-Tegel (Deutscher Wetterdienst, 2023a) verglichen. Beide Zeiträume wiesen 17 Tage mit Niederschlag auf (Deutscher Wetterdienst, 2023b), mit geringfügigen Unterschieden im Gesamt-Niederschlag (39.3 mm im Jahr 2018 im Vergleich zu 22.0 mm im Jahr 2020), der Sonnenscheindauer (79,2 Stunden im Jahr 2018 im Vergleich zu 84,0 Stunden im Jahr 2020) und

der durchschnittlichen täglichen Bewölkung (6,2 Achtel im Jahr 2018 im Vergleich zu 6,1 Achtel im Jahr 2020). Diese Ähnlichkeiten lassen darauf schließen, dass das Wetter die Gesamtergebnisse nicht signifikant verzerrt hat.

Während die ausgewählten Webcams wertvolle Einblicke in die städtische Verkehrsdynamik bieten, sind sie gemäß der RIN-Klassifikation auf die Straßennetzebenen 1 (großräumige Verbindungen), 2 (überregionale Verbindungen) und 3 (regionale Verbindungen) beschränkt. Es waren keine geeigneten öffentlich zugänglichen Webcam-Daten für Ebene 0 (Autobahnen) oder Ebene 4 (Nebenstraßen) verfügbar, was die Repräsentativität des Datensatzes über das gesamte Spektrum der Straßentypen hinweg einschränkt. Daher könnten die Ergebnisse die Verkehrsmuster auf Autobahnen oder kleineren Nebenstraßen nicht erfassen, auf denen sich Mobilitätsverhalten und Fahrzeugzusammensetzungen unterscheiden könnten. Die Studie zeigt aber, dass diese Art des Verkehrsmonitorings bestehende Daten zum Verkehr sinnvoll ergänzen und relative Änderung in der Mobilität erfassen kann.

Darüber hinaus konnte in dieser Studie gezeigt werden, dass der motorisierte Verkehr im Jahr 2020 im Vergleich zu 2018 um -9.5% abnahm, was eng mit dem landesweiten Rückgang in Deutschland von -9.2% übereinstimmt (Umweltbundesamt, 2023). Die trendspezifischen Unterschiede variierten jedoch je nach Standort. Die Webcams in der Straße Messedamm zeigten stärkere Rückgänge, die wahrscheinlich durch die eingeschränkte Messeaktivitäten bedingt waren, bei denen nur 28 der 120 geplanten Veranstaltungen stattfanden (Messe Berlin, 2021). Zudem konnte ein Rückgang der Fernbuspassagiere um 70% am nahegelegenen zentralen Busbahnhof verzeichnet werden Statistisches Bundesamt (Statistisches Bundesamt, 2021). Im Gegensatz dazu zeigte die Heerstraße gemischte Trends, mit einigen Rückgängen, aber stabilem oder steigendem Verkehr in geringerer Distanz zum Stadtzentrum. Der Lkw-Verkehr nahm weniger stark ab als der Pkw-Verkehr, was die zunehmende Bedeutung städtischer Lieferdienste widerspiegelt (Bundesministerium für Digitales und Verkehr, 2020; Umweltbundesamt, 2023). Die Tendenz von YOLO, Lieferfahrzeuge als Lkw zu erkennen, könnte einige der Ergebnisse erklären (vgl. Abbildung 7.4 c und e). Verkehrsdaten von offiziellen Berliner Quellen zeigen ähnliche Trends (Verkehrsinformationszentrale Berlin, 2022), mit erheblichen Rückgängen während des ersten Lockdowns, gefolgt von einer teilweisen Erholung. Dies stimmt mit den Webcam-basierten Ergebnissen überein. Die Behörden berichteten von den größten Verkehrsrückgängen in der Leipziger Straße, während sich die Mobilität in Gebieten wie Zehlendorf schneller wieder normalisierte (Verkehrsinformationszentrale Berlin, 2022). Diese Muster bestätigen, dass COVID-19 den motorisierten Verkehr in Berlin beeinflusste, wobei Unterschiede je nach Straßennutzung und nahegelegenen Aktivitätsorten zu beobachten sind.

Die Detektion von Fahrrädern nahm in allen Kameras signifikant zu (25.2%). Insbesondere verzeichneten die Webcams „032 Messedamm“ mit 45.4% oder „038 Messedamm“ mit 34.1% starke Zuwächse (Abbildung 6.12 c). Am Messedamm trug die Einführung einer 7.2 km langen Pop-up-Fahrradspur auf der Kantstraße bzw. an der Neuen Kanstraße im Jahr 2020 wahrscheinlich zu diesem Anstieg bei (Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin, 2021),

was die Plausibilität der detektierten Trends verstärkt. Ähnliche Trends wurden auf städtischer Ebene beobachtet, wobei der Fahrradverkehr sogar in Bereichen ohne Infrastrukturverbesserungen zunahm (Becker et al., 2022; Buehler und Pucher, 2022; infraVelo, 2023b). Fest installierte Fahrradzählstellen konnten für Berlin einen Anstieg des Fahrradverkehrs um 22 % für 2022 im Vergleich zu 2019 feststellen (Buehler und Pucher, 2022), was eng mit den 25.2 % übereinstimmt, die in dieser Analyse festgestellt wurden.

Die Detektion von Fußgängern nahm 2020 um mehr als 15 % ab, aber die Leistung von YOLO bei der Fußgängerdetektion kann als die am wenigsten zuverlässige angesehen werden, aufgrund ihrer kleinen Objektgröße in den Webcam-Bildern. Zudem zeigen die ausgewählten Straßen eher Hauptverkehrsachsen und sind damit nur bedingt zur Detektion der Fußgängermobilität geeignet. Das Umweltbundesamt berichtete von einem landesweiten Anstieg der Fußgänger-Kilometer um 1.4 % im Jahr 2020 im Vergleich zu 2017 (Umweltbundesamt, 2023). Dieser Trend konnte in den Beobachtungen dieser Studie nicht nachgewiesen werden.

Zusammenfassend zeigen die Ergebnisse signifikante Verkehrsveränderungen im Zeitraum der Fallstudie 2020 im Vergleich zu 2018, wobei die COVID-19-Pandemie und die damit verbundenen Einschränkungen sowie abgesagte Kulturveranstaltungen plausible Haupttreiber darstellen (Betschka et al., 2021). Interessanterweise sind für die drei untersuchten Straßen zukünftig Veränderungen geplant. An der Heerstraße soll eine 15 km lange Fahrrad-Schnellstraße in westlicher Richtung eingerichtet werden (infraVelo, 2023b). Eine geschützte Fahrradspur wurde für den Messedamm im Jahr 2024 initiiert (infraVelo, 2023a), während Alt-Moabit für eine Umgestaltung zugunsten des nicht-motorisierten Verkehrs vorgeschlagen wurde (Stadtteilvertretung Turmstrasse, 2021). Diese geplanten Maßnahmen zielen auf eine nachhaltige Verkehrswende und die Förderung aktiver Mobilitätsformen ab, stehen jedoch in einem Spannungsfeld zwischen politischen Zielsetzungen und tatsächlicher Umsetzung im Stadtraum. Gerade in dicht besiedelten urbanen Gebieten ist es entscheidend, die Auswirkungen solcher Eingriffe nicht nur modellbasiert, sondern auch empirisch im Zeitverlauf zu bewerten. Eine kontinuierliche Erfassung und Analyse des Verkehrsgeschehens kann dabei helfen, Veränderungen in der Nutzung des Straßenraums frühzeitig zu erkennen und Anpassungsbedarfe aufzuzeigen. Der vorgestellte verwendete Ansatz, der auf freiverfügbare Webcam-Daten und Open-Source-Objekterkennungsverfahren zurückgreift, könnte ein kostengünstiges Werkzeug zur Überwachung und Bewertung dieser Projekte darstellen.

Fazit und Ausblick

Die globalen Herausforderungen der rasanten Urbanisierung, des Klimawandels sowie zunehmende soziale Disparitäten in städtischen Räumen machen deutlich, dass die Stadtplanung an ihre Grenzen stößt, wenn es um eine evidenzbasierte Gestaltung nachhaltiger und gerechter Mobilitätssysteme geht (United Nations, 2015, 2019). Gerade in schnell wachsenden Städten des globalen Südens fehlt es häufig an belastbaren, flächendeckenden Daten, um urbane Strukturen systematisch zu analysieren und Mobilitätsbedarfe gezielt zu adressieren (Walker et al., 2010; Cervero, 2013). Dabei ist ein funktionierendes und auch zugängliches Verkehrssystem nicht nur eine infrastrukturelle und wirtschaftliche Notwendigkeit, sondern ein zentrales Element urbaner Resilienz, sozialer Inklusion und ökologischer Transformation (Nieuwenhuijsen, 2020).

Vor diesem Hintergrund zielt diese Dissertation darauf ab, datengetriebene Methoden zu entwickeln und zu erproben, mit denen urbane Strukturen und Verkehrsmuster systematisch analysiert werden können, sowohl im Globalen Süden als auch im Globalen Norden. Im Zentrum stand dabei die Frage, wie heterogene Datenquellen, darunter Fernerkundung, Geodaten und öffentlich verfügbare Kamerabilder, nutzbar gemacht werden können, um zentrale Parameter urbaner Mobilität abzuleiten. Die Kombination dieser Daten mit Methoden des maschinellen Lernens verspricht eine neue Qualität in der Erfassung und Interpretation städtischer Räume: hin zu flächendeckenden, aktuellen und übertragbaren Informationsgrundlagen (Bibri und Krogstie, 2020).

Im Spannungsfeld zwischen methodischer Innovation und praktischer Anwendbarkeit wurde in dieser Arbeit ein besonderer Fokus auf die Skalierbarkeit und Generalisierbarkeit der entwickelten Ansätze gelegt. Die inhaltliche Klammer bildet dabei die Annahme, dass urbane Mobilität nicht isoliert, sondern stets im Zusammenspiel mit der bebauten Umwelt, sozioökonomischen Strukturen und institutionellen Rahmenbedingungen zu betrachten ist (Boarnet und Crane, 2001; Ihlanfeldt, 2020). Ziel war es daher nicht nur, neue Methoden zur Datengenerierung zu entwickeln, sondern auch aufzuzeigen, wie sich daraus relevante Indikatoren für eine nachhaltige und gerechte Stadtentwicklung ableiten lassen.

Im Zentrum dieser Dissertation standen drei leitende Forschungsfragen, deren Beantwortung im Folgenden strukturiert dargestellt wird.

Forschungsfrage 1: Wie können fernerkundungsbasierte und offene Geodaten genutzt werden, um zentrale Merkmale der städtischen Raumstruktur – Gebäude, Landnutzung und Bevölkerung – mit hoher räumlicher Auflösung zu erfassen und als Proxydaten für verkehrsbezogene Analysen in datenarmen Regionen dienen? Im Rahmen der ersten Forschungsfrage wurde ein generischer Ansatz zur Generierung relevanter Daten für die Stadt- und Verkehrsforschung entwickelt, der drei Schlüsselfaktoren der städtischen Raumstruktur erfassen kann: Gebäude, Landnutzung und innerstädtische Bevölkerungsverteilung. Durch seine Übertragbarkeit ist der Ansatz nicht auf einen speziellen Stadt- oder Regionstyp beschränkt und kann unabhängig von offiziellen Daten umgesetzt werden. Folgende vier Schlüsselaspekte können genannt werden:

- Gebäudedetektion mit Deep Learning: Fernerkundungsdaten wurden mithilfe von Deep-Learning-basierter Klassifikationsverfahren analysiert, um Gebäude mit hoher Genauigkeit flächendeckend zu extrahieren.
- Datenfusion für detaillierte 3D-Stadtmodelle: Fernerkundungsdaten unterschiedlicher räumlicher Auflösung wurden kombiniert, um physische Merkmale urbaner Räume dreidimensional mit hohem Detailgrad abzuleiten.
- Gebäude-Landnutzung-Verknüpfung über OSM: Bestimmung der detaillierten Landnutzung aus verschiedenen OSM-Datensätzen auf Einzelgebäudeebene.
- Bevölkerungsschätzung skalenabhängig: Für kleinräumige Analysen erwies sich die zusätzliche Einbeziehung der Landnutzung als sinnvoll (hier: auf Stadtblockebene mit einer durchschnittlichen Größe von ca. $120 \times 120 \text{m}$); für größere Einheiten reichen ausschließlich fernerkundungsbasierte Ansätze aus (hier: auf Stadtbezirksebene von ca. $1.600 \times 1.600 \text{m}$).

Die Kombination von Fernerkundungsdaten und -techniken mit offenen Geodaten kann dazu beitragen, die Datenverfügbarkeit im Bereich des städtischen Verkehrs voranzutreiben, insbesondere in Ländern des Globalen Südens. Die drei untersuchten Parameter der städtischen Raumstruktur sind für städtische Verkehrssysteme von besonderer Bedeutung (Cervero und Murakami, 2010; Choi und Zhang, 2017; Cao et al., 2019). Wenn relevante Daten zu diesen Schlüsselparametern nicht verfügbar sind oder herkömmliche Methoden an ihre Grenzen stoßen, könnte das vorgestellte Verfahren als Alternative dienen, um die Verkehrsplanung und -forschung im Hinblick auf ein nachhaltigeres und effektiveres städtisches Verkehrssystem mit diesen großflächigen Basisdaten zu unterstützen. Dies ist besonders wichtig angesichts der globalen Urbanisierung, bei der die höchsten Wachstumsraten in Ländern des Globalen Südens zu verzeichnen sind (Taubenböck et al., 2024).

Die mit dem entwickelten Verfahren erzeugten flächendeckenden Bevölkerungsabschätzungen wurden unter anderem für die nächste Untersuchung in Medellín herangezogen, um die zweite Forschungsfrage zu adressieren:

Forschungsfrage 2: Wie unterscheiden sich Erreichbarkeiten zu öffentlichen Verkehrsmitteln in Medellín zwischen verschiedenen Siedlungsformen und sozioökonomischen Gruppen und inwiefern kann Fernerkundung helfen, datenbedingte Ungleichheiten in der Analyse zu überwinden?

Diese zweite Forschungsfrage zielte darauf ab, die Erreichbarkeit öffentlicher Verkehrsmittel nach dem Vorbild des SDG 11.2 Indikators in Medellín differenziert zu analysieren. Dies wurde unter Berücksichtigung verschiedener Verkehrsträger (hoch- vs. niedrigkapazitiv, formell vs. semiformell), räumlicher Bezugseinheiten (gesamtes Stadtgebiet, Verwaltungsgrenzen, Rasterebenen), sozioökonomischer Gruppen sowie der Differenzierung zwischen formellen und informellen Siedlungen durchgeführt. Die Ergebnisse zeigen deutlich, dass sich Erreichbarkeiten je nach Verkehrsmittel, gewählter Raumebene sozio-ökonomischen Faktoren und Siedlungstyp stark unterscheiden, mit schlechterer Anbindung für informelle Siedlungen und ärmere Bevölkerungsgruppen. Stadtweite Durchschnittswerte von Erreichbarkeitsanalysen überdecken dabei oft lokale Defizite in der Erreichbarkeit öffentlicher Verkehrsmittel.

Ein zentrales Ergebnis betrifft die Rolle des semiformalen Verkehrssystems der Minibusse, die insbesondere im Fall von Medellín, aber auch im Globalen Süden entscheidend zur Mobilität benachteiligter Gruppen beitragen (Pareja, 2015; Plano und Behrens, 2022). Besonders in denjenigen Teilen der Stadt, die vom formellen öffentlichen Verkehr unterversorgt sind, fungieren sie als komplementäres System. Diese Beobachtung legt nahe, dass Planungsentscheidungen häufig implizit einkommensstärkere Bevölkerungsteile bevorzugen. Das verdeutlicht jedoch auch, dass die Kreativität der Betreiber semiformaler und informeller Verkehrsmittel dazu beitragen kann, die unzureichende Erreichbarkeit formeller Verkehrsangebote auszugleichen.

Die Analyse stützt sich auf ein methodisches Fundament, das klassische Erreichbarkeitsanalysen mit fernerkundungsbasierten Bevölkerungsdaten kombiniert. Fernerkundung spielt dabei eine doppelte Rolle: Erstens wurde sie genutzt, um die Siedlungsstruktur großflächig zu kartieren und informelle Siedlungen zu identifizieren. Dies ist ein Aspekt, der in offiziellen Daten häufig unterrepräsentiert oder gar nicht erfasst ist (Hertrich et al., 2025). Auf Basis dieser Gebäudeextraktion konnte eine intraurbane Bevölkerungsverteilung realisiert werden. Dadurch lassen sich auch in Bereichen mit Datenlücken verkehrsrelevante Analysen wie die Berechnung von Erreichbarkeiten durchführen und Disparitäten sichtbar machen. Fernerkundung erweist sich somit als ein entscheidendes Instrument, um bestehende Datenungleichheiten zu überbrücken und Erreichbarkeitsanalysen in komplexen, datenarmen urbanen Kontexten zu ermöglichen.

Während die zweite Forschungsfrage die Nutzung von Fernerkundungs- und Bevölkerungsdaten zur Analyse von Erreichbarkeiten in datenlimitierten Kontexten wie Medellín untersuchte, richtet sich der Fokus der dritten Forschungsfrage auf Regionen mit potentiell besserer Datenverfügbarkeit. Ziel ist es, auch dort innovative, datengetriebene Methoden zu entwickeln und zu erproben. Dabei ging es um die Analyse offener Webcam-Bilddaten für die Ableitung des Verkehrsgeschehens in Berlin:

Forschungsfrage 3: Wie geeignet sind offen zugängliche Webcam-Daten in Kombination mit Deep-Learning-Methoden zur automatisierten Erfassung urbaner Mobilität und zur Analyse langfristiger Veränderungen im Mobilitätsverhalten?

Im Zentrum der Untersuchung zu Forschungsfrage 3 stand die Bewertung des Deep-Learning-Modells YOLOv8 im Kontext urbaner Verkehrsanalysen unter Verwendung öffentlich zugänglicher Webcam-Daten. Ziel war es, sowohl die technische Leistungsfähigkeit als auch das Anwendungspotenzial solcher Daten für verkehrsbezogene Analysen zu untersuchen. Die COVID-19-Pandemie lieferte ein konkretes Anwendungsszenario, an dem sich diese Herangehensweise besonders gut untersuchen lassen konnte.

YOLOv8 zeigte trotz fehlenden domänenspezifischen Fine-Tunings eine verlässliche Erkennungsleistung und erreichte einen F1-Score von 0,75. Angesichts der zahlreichen Herausforderungen bei der automatisierten Bildanalyse offener Webcam-Daten, wie etwa Perspektivwechsel, wechselnde Lichtverhältnisse, Witterungseinflüsse und Objektüberlagerungen, kann dies als ein robustes Ergebnis bewertet werden. Die Befunde belegen damit, dass auch ein Out-of-the-Box-Modell wertvolle Informationen für das Verkehrsmonitoring liefern kann, was besonders für die Anwendung in der Praxis von Bedeutung sein könnte.

Ein weiteres Ziel dieser Untersuchung war es, das YOLO-Objekterkennungsverfahren auf einen umfangreichen Bilddatensatz anzuwenden, um langfristige Änderungen im Mobilitätsverhalten festzustellen. Dafür wurden 493.000 Webcambilder aus Berlin analysiert, die zwei Zeiträume abdecken, vor (2018) und während (2020) der COVID-19 Pandemie. Dabei zeigte sich ein signifikanter Rückgang des motorisierten Verkehrs (Pkw: -9.6% , Lkw: -8.0%), während gleichzeitig ein starker Anstieg des Radverkehrs ($+25.2\%$) zu beobachten war. Die Veränderungen variierten jedoch je nach Straßentyp und Fahrzeugkategorie. Diese Ergebnisse decken sich mit früheren Studien und bestätigen, dass offene Webcams ein geeignetes Werkzeug zur kontinuierlichen Erfassung solcher Trends sein können (Ide et al., 2017; Zhang et al., 2017b).

Es lässt sich daher festhalten, dass die Kombination aus offenen Webcam-Daten und vor-trainierten Deep-Learning-Modellen wie YOLOv8 ein praktikables und skalierbares Verfahren zur Erfassung urbaner Mobilitätsmuster darstellt. Dieses Verfahren kann nicht nur retrospektive Analysen wie jene zur COVID-19-Pandemie ermöglichen, sondern auch zukünftig in Echtzeitbeobachtungen, Verkehrsmanagementsysteme oder Stadtplanungskonzepte integriert werden. Der Ansatz ist grundsätzlich auf andere Städte übertragbar, sofern vergleichbare offene Webcam-Daten verfügbar sind. Da keine personenbezogenen Daten verarbeitet werden, bestehen zudem keine datenschutzrechtlichen Hürden im Rahmen der analysierten Anwendungsfälle.

Die Ergebnisse dieser Dissertation zeigen, dass der Einsatz von Fernerkundung, offenen Geodaten und Deep-Learning-Verfahren bedeutende Potenziale für die urbane Verkehrs- und Raumforschung bietet. Die entwickelten Ansätze ermöglichen es, zentrale stadtstrukturelle Parameter zu erfassen, diese in Verbindung mit Analysen der Erreichbarkeit zu bringen, sowie punktuell Verkehrsmonitoring durchzuführen. Dies schafft eine belastbare Grundlage für strate-

gische Entscheidungen im Bereich nachhaltiger Mobilität und kann Kommunen, internationale Organisationen und zivilgesellschaftliche Akteure bei der Entwicklung datengetriebener Maßnahmen unterstützen (United Nations, 2015; European Commission, 2019; Deutscher Bundestag, 2024).

Ein zentraler Mehrwert dieser Arbeit liegt in ihrer interdisziplinären Ausrichtung. Mit der Verknüpfung verschiedener Forschungsfelder positioniert sich diese Dissertation im Schnittpunkt der Stadtforschung, Verkehrsgeografie, Fernerkundung und Data Science. Die Kombination etablierter geowissenschaftlicher Methoden mit aktuellen KI-basierten Verfahren eröffnet neue Wege, um urbane Räume datenbasiert zu analysieren und zu verstehen. Gleichzeitig leistet diese Arbeit einen Beitrag zur Entwicklung praxisnaher Werkzeuge, mit denen sich urbane Verkehrssysteme nicht nur besser erfassen und analysieren, sondern langfristig auch gezielter gestalten lassen.

Gleichzeitig machen die Ergebnisse weiteren Forschungsbedarf sichtbar, der sich entlang der drei leitenden Forschungsfragen skizzieren lässt:

Im Bereich der Datengewinnung zur städtischen Raumstruktur zeigen sich vor allem bei der Generalisierbarkeit der Gebäudeklassifikation und der differenzierten Erfassung von Gebäudehöhen und Bevölkerungsverteilung Möglichkeiten der Weiterentwicklung. Künftige Arbeiten könnten verstärkt auf diversifizierte Trainingsdaten aus unterschiedlichen Stadtstrukturen setzen oder kontextspezifische Modellanpassungen vornehmen, insbesondere im Hinblick auf gemischte Nutzungsformen und deren Einfluss auf die Bevölkerungsmodellierung.

Im Kontext der Analyse sozio-räumlicher Erreichbarkeiten besteht weiterer Forschungsbedarf vor allem in der Integration zusätzlicher, auch subjektiver Datenquellen, etwa zur wahrgenommenen Sicherheit oder Zugänglichkeit verschiedener Verkehrsmittel. Ebenso könnten zukünftige Studien stärker untersuchen, wie informelle und formelle Mobilitätssysteme zusammenspielen und wie datenbasierte Werkzeuge politische Entscheidungsprozesse hin zu gerechteren Verkehrssystemen besser unterstützen können.

Bei der Nutzung offener Webcam-Daten zur Mobilitätsanalyse wäre es vielversprechend, tiefergehende Modellanpassungen durch gezieltes Fine-Tuning mit domänenspezifischen Daten zu erproben. Darüber hinaus bieten sich weiterführende Untersuchungen auf Basis von zeitlich höher aufgelösten Bilddaten, beispielsweise Videodaten, um dynamische Aspekte wie Verkehrsflüsse, Durchschnittsgeschwindigkeiten oder veränderte Mobilitätsmuster in Echtzeit präziser abbilden zu können.

Langfristig können datengetriebene und automatisierte Verfahren dieser Art dazu beitragen, urbane Mobilität nicht nur effizienter, sondern auch gerechter zu gestalten. Gerade mit Blick auf die globalen Urbanisierungstendenzen und die wachsenden Anforderungen an resiliente, nachhaltige Infrastrukturen eröffnet die Verbindung aus flächendeckenden Fernerkundungsdaten und offenen Geodaten in Kombination mit KI-Methoden neue Perspektiven, sowohl für die

Forschung als auch für die Praxis. Diese Dissertation versteht sich daher auch als Impuls, die Entwicklung intelligenter, sozial gerechter Verkehrslösungen in urbanen Räumen voranzutreiben und damit urbane Mobilität resilient mitzugestalten.

Literatur

- Abdollahi, A., Pradhan, B., Shukla, N., Chakraborty, S. und Alamri, A. (2020). „Deep Learning Approaches Applied to Remote Sensing Datasets for Road Extraction: A State-Of-The-Art Review“. In: *Remote Sensing* 12.9, S. 1444. DOI: [10.3390/rs12091444](https://doi.org/10.3390/rs12091444).
- Ahas, R., Krisp, J. M. und Toivonen, T. (2017). „Methodological aspects of using geocoded data from mobile devices in transportation research“. In: *Journal of Location Based Services* 11.2, S. 75–77. DOI: [10.1080/17489725.2017.1427020](https://doi.org/10.1080/17489725.2017.1427020).
- Ahlström, A., Pilesjö, P. und Lindberg, J. (2011). „Improved accessibility modeling and its relation to poverty – A case study in Southern Sri Lanka“. In: *Habitat International* 35.2, S. 316–326. DOI: [10.1016/j.habitatint.2010.11.002](https://doi.org/10.1016/j.habitatint.2010.11.002).
- Akuraju, V., Pradhan, P., Haase, D., Kropp, J. P. und Rybski, D. (2020). „Relating SDG11 indicators and urban scaling – An exploratory study“. In: *Sustainable Cities and Society* 52, S. 101853. DOI: [10.1016/j.scs.2019.101853](https://doi.org/10.1016/j.scs.2019.101853).
- Al-qaness, M. A. A., Abbasi, A. A., Fan, H., Ibrahim, R. A., Alsamhi, S. H. und Hawbani, A. (2021). „An improved YOLO-based road traffic monitoring system“. In: *Computing*. DOI: [10.1007/s00607-020-00869-8](https://doi.org/10.1007/s00607-020-00869-8).
- Albacete, X., Olaru, D., Paül, V. und Biermann, S. (2015). „Measuring the Accessibility of Public Transport: A Critical Comparison Between Methods in Helsinki“. In: *Applied Spatial Analysis and Policy* 10.2, S. 161–188. DOI: [10.1007/s12061-015-9177-8](https://doi.org/10.1007/s12061-015-9177-8).
- Aljoufie, M., Zuidgeest, M., Brussel, M. und Maarseveen, M. van (2013). „Spatial-temporal analysis of urban growth and transportation in Jeddah City, Saudi Arabia“. In: *Cities* 31, S. 57–68. DOI: [10.1016/j.cities.2012.04.008](https://doi.org/10.1016/j.cities.2012.04.008).
- Amiegbebhor, D., Popoola, B. et al. (2021). „Initiating Smart Public Transportation in Lagos: Setting the Tone for African Cities“. In: *Journal of Construction Project Management and Innovation* 11.1, S. 22–30.
- Amt für Statistik Berlin-Brandenburg (2023). *Bevölkerungsentwicklung und Bevölkerungsstand in Berlin*. Verfügbar unter: https://download.statistik-berlin-brandenburg.de/417d5cbe631b8e82/923eaa65c65d/SB_A01-07-00_2023m04_BE.pdf. Zuletzt abgerufen am 03.04.2025.

- Amt für Statistik Berlin-Brandenburg (2024). *Statistischer Bericht: Bevölkerung in Berlin 2023 - Bevölkerungsentwicklung, Bevölkerungsstand, Bevölkerungsfortschreibung auf Basis Zensus 2022*. Verfügbar unter: https://download.statistik-berlin-brandenburg.de/5819c0096285c59a/ad4103b9a6c9/SB_A01-03-00_2023j01_BEa.pdf. Zuletzt abgerufen am 03.04.2025.
- Andreasen, M. H. und Møller-Jensen, L. (2017). „Access to the city: Mobility patterns, transport and accessibility in peripheral settlements of Dar es Salaam“. In: *Journal of Transport Geography* 62, S. 20–29. DOI: [10.1016/j.jtrangeo.2017.05.005](https://doi.org/10.1016/j.jtrangeo.2017.05.005).
- Angel, S., Parent, J., Civco, D. L., Blei, A. und Potere, D. (2011). „The dimensions of global urban expansion: Estimates and projections for all countries, 2000–2050“. In: *Progress in Planning* 75.2, S. 53–107. DOI: [10.1016/j.progress.2011.04.001](https://doi.org/10.1016/j.progress.2011.04.001).
- Ang, K. L.-M., Seng, J. K. P., Ngharamike, E. und Ijamaru, G. K. (2022). „Emerging Technologies for Smart Cities' Transportation: Geo-Information, Data Analytics and Machine Learning Approaches“. In: *ISPRS International Journal of Geo-Information* 11.2, S. 85. DOI: [10.3390/ijgi11020085](https://doi.org/10.3390/ijgi11020085).
- Anke, J., Francke, A., Schaefer, L.-M. und Petzoldt, T. (2021). „Impact of SARS-CoV-2 on the mobility behaviour in Germany“. In: *European Transport Research Review* 13.1. DOI: [10.1186/s12544-021-00469-3](https://doi.org/10.1186/s12544-021-00469-3).
- Aravena Pelizari, P., Geiß, C., Aguirre, P., Santa María, H., Merino Peña, Y. und Taubenböck, H. (2021). „Automated building characterization for seismic risk assessment using street-level imagery and deep learning“. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 180, S. 370–386. DOI: [10.1016/j.isprsjprs.2021.07.004](https://doi.org/10.1016/j.isprsjprs.2021.07.004).
- Arellana, J., Oviedo, D., Guzman, L. A. und Alvarez, V. (2021). „Urban transport planning and access inequalities: A tale of two Colombian cities“. In: *Research in Transportation Business and Management* 40, S. 100554. DOI: [10.1016/j.rtbm.2020.100554](https://doi.org/10.1016/j.rtbm.2020.100554).
- Armenta-Déu, C. (2025). „Environmental Impact of Urban Surface Transportation: Influence of Driving Mode and Drivers' Attitudes“. In: *Pollutants* 5.1, S. 5. DOI: [10.3390/pollutants5010005](https://doi.org/10.3390/pollutants5010005).
- Arsanjani, J. J., Zipf, A., Mooney, P. und Helbich, M., Hrsg. (2015). *OpenStreetMap in GIS-science. Experiences, research, and applications*. Verfügbar unter: https://www.ebook.de/de/product/25035095/openstreetmap_in_giscience.html. Zuletzt abgerufen am 18.5.2020. Cham, Heidelberg, New York, Dodrecht, und London: Springer-Verlag GmbH.
- Atluri, M., Chowdhury, M., Kanhere, N., Fries, R., Sarasua, W. und Ogle, J. (2009). „Development of a sensor system for traffic data collection“. In: *Journal of Advanced Transportation* 43.1, S. 1–20. DOI: [10.1002/atr.5670430102](https://doi.org/10.1002/atr.5670430102).
- Aung, Y. Y. und Lwin, M. M. (2024). „Real-Time Object Distance Estimation Based on YOLOv8 Using Webcam“. In: *2024 IEEE Conference on Computer Applications (ICCA)*. IEEE, S. 1–6. DOI: [10.1109/icca62361.2024.10532829](https://doi.org/10.1109/icca62361.2024.10532829).
- Azimjonov, J. und Özmen, A. (2021). „A real-time vehicle detection and a novel vehicle tracking systems for estimating and monitoring traffic flow on highways“. In: *Advanced Engineering Informatics* 50, S. 101393. DOI: [10.1016/j.aei.2021.101393](https://doi.org/10.1016/j.aei.2021.101393).

- Bähr, J. und Meyer-Kriesten, K. (2007). „Santiago de Chile - a fragmented city? A factorial analysis of the urban structure in 2002 in comparison with 1970“. In: *Erdkunde* 61.3, S. 258–276. DOI: [10.3112/erdkunde.2007.03.04](https://doi.org/10.3112/erdkunde.2007.03.04).
- Balser, M. (2022). *Ukraine Krieg: Kameras an deutschen Autobahnen offline*. Verfügbar unter: <https://www.sueddeutsche.de/politik/ukraine-krieg-deutsche-autobahnen-militaertransporte-verkehrskameras-1.5547662>. Zuletzt abgerufen am 13.01.2025.
- Barrington-Leigh, C. und Millard-Ball, A. (2017). „The world's user-generated road map is more than 80% complete“. In: *PLOS ONE* 12.8, e0180698. DOI: [10.1371/journal.pone.0180698](https://doi.org/10.1371/journal.pone.0180698).
- Barbosa, H., Hazarie, S., Dickinson, B., Bassolas, A., Frank, A., Kautz, H., Sadilek, A., Ramasco, J. J. und Ghoshal, G. (2021). „Uncovering the socioeconomic facets of human mobility“. In: *Scientific Reports* 11.1. DOI: [10.1038/s41598-021-87407-4](https://doi.org/10.1038/s41598-021-87407-4).
- Barter, P. A. (1999). „An international comparative perspective on urban transport and urban form in Pacific Asia: the challenge of rapid motorisation in dense cities“. Verfügbar unter: <https://researchportal.murdoch.edu.au/esploro/outputs/991005541523307891/filesAndLinks?index=0>. Zuletzt abgerufen am 05.06.2025. Doktorarbeit. Murdoch University.
- Becker, S., Schneidemesser, D. von, Caseiro, A., Götting, K., Schmitz, S. und Schneidemesser, E. von (2022). „Pop-up cycling infrastructure as a niche innovation for sustainable transportation in European cities: An inter- and transdisciplinary case study of Berlin“. In: *Sustainable Cities and Society* 87, S. 104168. DOI: [10.1016/j.scs.2022.104168](https://doi.org/10.1016/j.scs.2022.104168).
- Beirão, G. und Sarsfield Cabral, J. (2007). „Understanding attitudes towards public transport and private car: A qualitative study“. In: *Transport Policy* 14.6, S. 478–489. DOI: [10.1016/j.tranpol.2007.04.009](https://doi.org/10.1016/j.tranpol.2007.04.009).
- Benton, J. S., Evans, J., Mourby, M., Elliot, M. J., Anderson, J., Hipp, J. A. und French, D. P. (2023). „Using Video Cameras as a Research Tool in Public Spaces: Addressing Ethical and Information Governance Challenges Under Data Protection Legislation“. In: *Journal for the Measurement of Physical Behaviour* 6.2, S. 145–155. DOI: [10.1123/jmpb.2022-0037](https://doi.org/10.1123/jmpb.2022-0037).
- Berlin.de (2023). *Busbahnhof Zentraler Omnibusbahnhof Berlin (ZOB)*. Verfügbar unter: <https://www.berlin.de/tourismus/infos/bahnhoefe/1872089-1832700-busbahnhof-zentraler-omnibusbahnhof-berl.html>. Zuletzt abgerufen am 09.06.2025.
- Betschka, J., Brandhofer, B., Kleist-Heinrich, K., Meidinger, D. und Perdoni, S. (2021). *Ein Jahr Corona in Berlin. Chronik einer Stadt im Jojo-Lockdown*. Verfügbar unter: <https://interaktiv.tagesspiegel.de/lab/ein-jahr-corona-in-berlin/>. Zuletzt abgerufen am 10.01.2025.
- Bezirksamt Charlottenburg-Wilmersdorf (2023). *Heerstraße*. Verfügbar unter: <https://www.berlin.de/ba-charlottenburg-wilmersdorf/ueber-den-bezirk/freiflaechen/strassen/artikel.178373.php>. Zuletzt abgerufen am 18.03.2025.

- Bibri, S. E. und Krogstie, J. (2020). „The emerging data-driven Smart City and its innovative applied solutions for sustainability: the cases of London and Barcelona “. In: *Energy Informatics* 3.1. DOI: [10.1186/s42162-020-00108-6](https://doi.org/10.1186/s42162-020-00108-6).
- Biljecki, F., Ohori, K. A., Ledoux, H., Peters, R. und Stoter, J. (2016). „Population estimation using a 3D city model: A multi-scale country-wide study in the Netherlands“. In: *PLOS ONE* 11.6. DOI: [10.1371/journal.pone.0156808](https://doi.org/10.1371/journal.pone.0156808).
- Biljecki, F., Chow, Y. S. und Lee, K. (2023). „Quality of crowdsourced geospatial building information: A global assessment of OpenStreetMap attributes“. In: *Building and Environment* 237, S. 110295. DOI: [10.1016/j.buildenv.2023.110295](https://doi.org/10.1016/j.buildenv.2023.110295).
- Bittner, K., Cui, S. und Reinartz, P. (2017). „Building extraction from remote sensing data using fully convolutional networks“. In: *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-1/W1*, S. 481–486. DOI: [10.5194/isprs-archives-xlii-1-w1-481-2017](https://doi.org/10.5194/isprs-archives-xlii-1-w1-481-2017).
- Bittner, K., Adam, F., Cui, S., Korner, M. und Reinartz, P. (2018). „Building Footprint Extraction From VHR Remote Sensing Images Combined With Normalized DSMs Using Fused Fully Convolutional Networks“. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11.8, S. 2615–2629. DOI: [10.1109/jstars.2018.2849363](https://doi.org/10.1109/jstars.2018.2849363).
- Bittencourt, T. A., Giannotti, M. und Marques, E. (2020). „Cumulative (and self-reinforcing) spatial inequalities: Interactions between accessibility and segregation in four Brazilian metropolises“. In: *Environment and Planning B: Urban Analytics and City Science* 48.7, S. 1989–2005. DOI: [10.1177/2399808320958426](https://doi.org/10.1177/2399808320958426).
- Boarnet, M. und Crane, R. C. (2001). *Travel by Design: The Influence of Urban Form on Travel*. Oxford University Press. DOI: [10.1093/oso/9780195123951.001.0001](https://doi.org/10.1093/oso/9780195123951.001.0001).
- Boisjoly, G., Moreno-Monroy, A. I. und El-Geneidy, A. (2017). „Informality and accessibility to jobs by public transit: Evidence from the São Paulo Metropolitan Region“. In: *Journal of Transport Geography* 64, S. 89–96. DOI: [10.1016/j.jtrangeo.2017.08.005](https://doi.org/10.1016/j.jtrangeo.2017.08.005).
- Bok, J. und Kwon, Y. (2016). „Comparable Measures of Accessibility to Public Transport Using the General Transit Feed Specification“. In: *Sustainability* 8.3, S. 224. DOI: [10.3390/su8030224](https://doi.org/10.3390/su8030224).
- Bondarenko, M., Kerr, D., Sorichetta, A. und Tatem, A. (2020). *Census/projection-disaggregated gridded population datasets for 189 countries in 2020 using Built-Settlement Growth Model (BSGM) outputs*. DOI: [10.5258/SOTON/WP00684](https://doi.org/10.5258/SOTON/WP00684).
- Borzacchiello, M. T., Casas, I., Ciuffo, B. und Nijkamp, P. (2009). „Geo-ICT in Transportation Science“. In: *Geospatial Technology and the Role of Location in Science*. Springer Netherlands, S. 267–285. DOI: [10.1007/978-90-481-2620-0_14](https://doi.org/10.1007/978-90-481-2620-0_14).
- Bowen, B., Vlasek, K. und Webb, C. (2004). „An assessment of remote sensing applications in transportation“. In: *The 2004 Annual Forum of the Transportation Research Forum*. Verfügbar unter: https://www.ugpti.org/smartse/research/citations/downloads/Bowen-Assessment_of_RS_in_Transportation-2004.pdf. Zuletzt abgerufen am 17.04.2021, S. 1–33.

- Briem, L., Heilig, M., Klinkhardt, C. und Vortisch, P. (2019). „Analyzing OpenStreetMap as data source for travel demand models A case study in Karlsruhe“. In: *Transportation Research Procedia* 41, S. 104–112. DOI: [10.1016/j.trpro.2019.09.021](https://doi.org/10.1016/j.trpro.2019.09.021).
- Brovelli, M. und Zamboni, G. (2018). „A new method for the assessment of spatial accuracy and completeness of OpenStreetMap building footprints“. In: *ISPRS International Journal of Geo-Information* 7.8, S. 289. DOI: [10.3390/ijgi7080289](https://doi.org/10.3390/ijgi7080289).
- Brussel, M., Zuidgeest, M., Pfeffer, K. und Maarseveen, M. van (2019). „Access or Accessibility? A Critique of the Urban Transport SDG Indicator“. In: *ISPRS International Journal of Geo-Information* 8.2, S. 67. DOI: [10.3390/ijgi8020067](https://doi.org/10.3390/ijgi8020067).
- Buehler, R. und Pucher, J. (2022). „Cycling through the COVID-19 Pandemic to a More Sustainable Transport Future: Evidence from Case Studies of 14 Large Bicycle-Friendly Cities in Europe and North America“. In: *Sustainability* 14.12, S. 7293. DOI: [10.3390/su14127293](https://doi.org/10.3390/su14127293).
- Bundesministerium für Digitales und Verkehr (2020). *Ergebnisbericht. Die Veränderungen des gewerblichen Lieferverkehrs und dessen Auswirkungen auf die städtische Logistik*. Verfügbar unter: https://fops.de/wp-content/uploads/2020/12/70-906_Ergebnisbericht.pdf. Zuletzt abgerufen am 10.12.2024.
- Burkhard, O., Ahas, R., Saluveer, E. und Weibel, R. (2017). „Extracting regular mobility patterns from sparse CDR data without a priori assumptions“. In: *Journal of Location Based Services* 11.2, S. 78–97. DOI: [10.1080/17489725.2017.1333638](https://doi.org/10.1080/17489725.2017.1333638).
- Cameron, I., Lyons, T. und Kenworthy, J. (2004). „Trends in vehicle kilometres of travel in world cities, 1960–1990: underlying drivers and policy responses“. In: *Transport Policy* 11.3, S. 287–298. DOI: [10.1016/j.tranpol.2004.01.002](https://doi.org/10.1016/j.tranpol.2004.01.002).
- Cao, X., Næss, P. und Wolday, F. (2019). „Examining the effects of the built environment on auto ownership in two Norwegian urban regions“. In: *Transportation Research Part D: Transport and Environment* 67, S. 464–474. DOI: [10.1016/j.trd.2018.12.020](https://doi.org/10.1016/j.trd.2018.12.020).
- Ceder, A. (2020). „Urban mobility and public transport: future perspectives and review“. In: *International Journal of Urban Sciences* 25.4, S. 455–479. DOI: [10.1080/12265934.2020.1799846](https://doi.org/10.1080/12265934.2020.1799846).
- Cervero, R. und Golub, A. (2007). „Informal transport: A global perspective“. In: *Transport Policy* 14.6, S. 445–457. DOI: [10.1016/j.tranpol.2007.04.011](https://doi.org/10.1016/j.tranpol.2007.04.011).
- Cervero, R. und Murakami, J. (2010). „Effects of Built Environments on Vehicle Miles Traveled: Evidence from 370 US Urbanized Areas“. In: *Environment and Planning A: Economy and Space* 42.2, S. 400–418. DOI: [10.1068/a4236](https://doi.org/10.1068/a4236).
- Cervero, R. B. (2013). „Linking urban transport and land use in developing countries“. In: *Journal of Transport and Land Use* 6.1, S. 7. DOI: [10.5198/jtlu.v6i1.425](https://doi.org/10.5198/jtlu.v6i1.425).
- Chakraborty, P., Adu-Gyamfi, Y. O., Poddar, S., Ahsani, V., Sharma, A. und Sarkar, S. (2018). „Traffic Congestion Detection from Camera Images using Deep Convolution Neural Networks“. In: *Transportation Research Record: Journal of the Transportation Research Board* 2672.45, S. 222–231. DOI: [10.1177/0361198118777631](https://doi.org/10.1177/0361198118777631).

- Chan, R. K. C., Lim, J. M.-Y. und Parthiban, R. (2023). „Missing Traffic Data Imputation for Artificial Intelligence in Intelligent Transportation Systems: Review of Methods, Limitations, and Challenges“. In: *IEEE Access* 11, S. 34080–34093. DOI: [10.1109/access.2023.3264216](https://doi.org/10.1109/access.2023.3264216).
- Chatzioannou, I., Nikitas, A., Tzouras, P. G., Bakogiannis, E., Alvarez-Icaza, L., Chias-Becerril, L., Karolemeas, C., Tsigdinos, S., Wallgren, P. und Rexfelt, O. (2023). „Ranking sustainable urban mobility indicators and their matching transport policies to support liveable city Futures: A MICMAC approach“. In: *Transportation Research Interdisciplinary Perspectives* 18, S. 100788. DOI: [10.1016/j.trip.2023.100788](https://doi.org/10.1016/j.trip.2023.100788).
- Chen, T., Hui, E. C., Wu, J., Lang, W. und Li, X. (2019). „Identifying urban spatial structure and urban vibrancy in highly dense cities using georeferenced social media data“. In: *Habitat International* 89, S. 102005. DOI: [10.1016/j.habitatint.2019.102005](https://doi.org/10.1016/j.habitatint.2019.102005).
- Cheng, L., Chen, X., Yang, S., Cao, Z., Vos, J. D. und Witlox, F. (2019). „Active travel for active ageing in China: The role of built environment“. In: *Journal of Transport Geography* 76, S. 142–152. DOI: [10.1016/j.jtrangeo.2019.03.010](https://doi.org/10.1016/j.jtrangeo.2019.03.010).
- Cheng, G., Xie, X., Han, J., Guo, L. und Xia, G.-S. (2020). „Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities“. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13, S. 3735–3756. DOI: [10.1109/jstars.2020.3005403](https://doi.org/10.1109/jstars.2020.3005403).
- Choupani, A.-A. und Mamdoohi, A. R. (2016). „Population synthesis using iterative proportional fitting (IPF): A review and future research“. In: *Transportation Research Procedia* 17, S. 223–233. DOI: [10.1016/j.trpro.2016.11.078](https://doi.org/10.1016/j.trpro.2016.11.078).
- Choi, K. und Zhang, M. (2017). „The impact of metropolitan, county, and local land use on driving emissions in US metropolitan areas: Mediator effects of vehicle travel characteristics“. In: *Journal of Transport Geography* 64, S. 195–202. DOI: [10.1016/j.jtrangeo.2017.09.004](https://doi.org/10.1016/j.jtrangeo.2017.09.004).
- Cichosz, P. (2015). *Data mining algorithms: Explained using R*. John Wiley & Sons United Kingdom. 716 S.
- City of Medellín (2014). *Plan de Ordenamiento Territorial: GDP POT Acuerdo 48 de 2014*. Verfügbar unter: <https://geomedellin-mmedellin.opendata.arcgis.com/datasets/gdb-pot-acuerdo48-de-2014>. Zuletzt abgerufen am 28.09.2022.
- Condurat, M., Nicuță, A. M. und Andrei, R. (2017). „Environmental Impact of Road Transport Traffic. A Case Study for County of Iași Road Network“. In: *Procedia Engineering* 181, S. 123–130. DOI: [10.1016/j.proeng.2017.02.379](https://doi.org/10.1016/j.proeng.2017.02.379).
- Dablanc, L. und Adoue, F. (2025). „New ways of collecting urban freight traffic data and applications for urban freight policies and research“. In: *Case Studies on Transport Policy* 19, S. 101315. DOI: [10.1016/j.cstp.2024.101315](https://doi.org/10.1016/j.cstp.2024.101315).
- d'Angelo, P. und Reinartz, P. (2011). „Semiglobal matching results on the ISPRS stereo matching benchmark“. In: *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVIII-4/W19*, S. 79–84. DOI: [10.5194/isprsarchives-xxxviii-4-w19-79-2011](https://doi.org/10.5194/isprsarchives-xxxviii-4-w19-79-2011).

- D'Aranno, P., Di Benedetto, A., Fiani, M. und Marsella, M. (2019). „Remote Sensing Technologies for Linear Infrastructure Monitoring“. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLII-2/W11, S. 461–468. DOI: [10.5194/isprs-archives-xlii-2-w11-461-2019](https://doi.org/10.5194/isprs-archives-xlii-2-w11-461-2019).
- Departamento Administrativo Nacional de Estadística (DANE) (2018). *Censo Nacional de Población y Vivienda (CNPV)*. URL: <http://microdatos.dane.gov.co/index.php/catalog/643/study-description>.
- Deutscher Wetterdienst (2023a). *Klimadaten Deutschland - Monats- und Tageswerte (Archiv)*. Berlin-Tegel (bis 06.05.2021) - Tageswerte - historisch. Verfügbar unter: <https://www.dwd.de/DE/leistungen/klimadatendeutschland/klarchivtagmonat.html#buehneTop>. Zuletzt aufgerufen am 27.06.2023.
- Deutscher Wetterdienst (2023b). *Wetter- und Klimalexikon. Niederschlagstag*. Verfügbar unter: <https://www.dwd.de/DE/service/lexikon/Functions/glossar.html?lv2=101812&lv3=101910>. Zuletzt aufgerufen am 27.06.2023.
- Deutscher Bundestag (2024). *Unterrichtung durch die Bundesregierung. Klimaschutzbericht 2024*. Verfügbar unter: <https://dserver.bundestag.de/btd/20/127/2012760.pdf>. Zuletzt abgerufen am 14.05.2025.
- Dewi, C., Chen, R.-C., Liu, Y.-T., Jiang, X. und Hartomo, K. D. (2021). „Yolo V4 for Advanced Traffic Sign Recognition With Synthetic Training Data Generated by Various GAN“. In: *IEEE Access* 9, S. 97228–97242. DOI: [10.1109/access.2021.3094201](https://doi.org/10.1109/access.2021.3094201).
- Dincer, S. E., Akdemir, F., Ulvi, H. und Duzkaya, H. (2019). „Assessing urban sprawl effect of transportation investments using remote sensing data and GIS methods: The case of Ankara protocol road“. In: *IOP Conference Series: Materials Science and Engineering* 471, S. 092079. DOI: [10.1088/1757-899x/471/9/092079](https://doi.org/10.1088/1757-899x/471/9/092079).
- Doda, S., Wang, Y., Kahl, M., Hoffmann, E. J., Ouan, K., Taubenböck, H. und Zhu, X. X. (2022). „So2Sat POP - A Curated Benchmark Data Set for Population Estimation from Space on a Continental Scale“. In: *Scientific Data* 9.1. DOI: [10.1038/s41597-022-01780-x](https://doi.org/10.1038/s41597-022-01780-x).
- Du, L., Zhang, W., Fu, H., Ren, W. und Zhang, X. (2019). „An efficient privacy protection scheme for data security in video surveillance“. In: *Journal of Visual Communication and Image Representation* 59, S. 347–362. DOI: [10.1016/j.jvcir.2019.01.027](https://doi.org/10.1016/j.jvcir.2019.01.027).
- Dubska, M., Herout, A., Juranek, R. und Sochor, J. (2015). „Fully Automatic Roadside Camera Calibration for Traffic Surveillance“. In: *IEEE Transactions on Intelligent Transportation Systems* 16.3, S. 1162–1171. DOI: [10.1109/tits.2014.2352854](https://doi.org/10.1109/tits.2014.2352854).
- Duncan, M. J., Winkler, E., Sugiyama, T., Cerin, E., duToit, L., Leslie, E. und Owen, N. (2010). „Relationships of land use mix with walking for transport: Do land uses and geographical scale matter?“ In: *Journal of Urban Health* 87.5, S. 782–795. DOI: [10.1007/s11524-010-9488-7](https://doi.org/10.1007/s11524-010-9488-7).
- Dunn, A., Hanson, B. und Seeger, C. J. (2018). „Evaluating walkability in the age of open data: OpenStreetMap and community-level transportation analysis“. In: *Journal of Digital Landscape Architecture* 3, S. 119–129.

- Echeverri, C. A., Murillo, D. M. und Valencia, G. M. (2011). „Simulación de ruido de tránsito automotor como herramienta para el rediseño de rutas de transporte público colectivo en el municipio de Medellín“. In: *Revista Ingenierías Universidad de Medellín* 10, S. 19–30.
- El-Gafy, M. A., Abdelrazig, Y. A. und Abdelhamid, T. S. (2011). „Environmental Impact Assessment for Transportation Projects: Case Study Using Remote-Sensing Technology, Geographic Information Systems, and Spatial Modeling“. In: *Journal of Urban Planning and Development* 137.2, S. 153–158. DOI: [10.1061/\(asce\)up.1943-5444.0000050](https://doi.org/10.1061/(asce)up.1943-5444.0000050).
- ElDeeb, S., Abd EL-Baky, R. A. und Masoumi, H. (2024). „Unveiling transportation disparities: investigating accessibility gaps in metropolitan cities using GIS—a case study of Alexandria, Egypt“. In: *Frontiers in Sustainable Cities* 6. DOI: [10.3389/frsc.2024.1372918](https://doi.org/10.3389/frsc.2024.1372918).
- Elkins, T. H. und Hofmeister, B. (2005). *Berlin: the spatial structure of a divided city*. Routledge.
- Engin, Z., Dijk, J. van, Lan, T., Longley, P. A., Treleaven, P., Batty, M. und Penn, A. (2020). „Data-driven urban management: Mapping the landscape“. In: *Journal of Urban Management* 9.2, S. 140–150. DOI: [10.1016/j.jum.2019.12.001](https://doi.org/10.1016/j.jum.2019.12.001).
- Essien, A., Petrounias, I., Sampaio, P. und Sampaio, S. (2020). „A deep-learning model for urban traffic flow prediction with traffic events mined from twitter“. In: *World Wide Web* 24.4, S. 1345–1368. DOI: [10.1007/s11280-020-00800-3](https://doi.org/10.1007/s11280-020-00800-3).
- Estima, J. und Painho, M. (2015). „Investigating the potential of OpenStreetMap for land use/land cover production: A case study for continental Portugal“. In: *Lecture Notes in Geoinformation and Cartography*. Springer International Publishing, S. 273–293. DOI: [10.1007/978-3-319-14280-7_14](https://doi.org/10.1007/978-3-319-14280-7_14).
- European Commission (2019). *Sustainable mobility: the European Green Deal*. Hrsg. von D.-G. for Communication. LU: Publications Office. DOI: [10.2775/395792](https://doi.org/10.2775/395792).
- Faghih-Imani, A., Eluru, N., El-Geneidy, A. M., Rabbat, M. und Haq, U. (2014). „How land-use and urban form impact bicycle flows: Evidence from the bicycle-sharing system (BIXI) in Montreal“. In: *Journal of Transport Geography* 41, S. 306–314. DOI: [10.1016/j.jtrangeo.2014.01.013](https://doi.org/10.1016/j.jtrangeo.2014.01.013).
- Fan, H., Zipf, A., Fu, Q. und Neis, P. (2014). „Quality assessment for building footprints data on OpenStreetMap“. In: *International Journal of Geographical Information Science* 28.4, S. 700–719. DOI: [10.1080/13658816.2013.867495](https://doi.org/10.1080/13658816.2013.867495).
- Faro, A., Giordano, D. und Spampinato, C. (2008). „Evaluation of the Traffic Parameters in a Metropolitan Area by Fusing Visual Perceptions and CNN Processing of Webcam Images“. In: *IEEE Transactions on Neural Networks* 19.6, S. 1108–1129. DOI: [10.1109/tnn.2008.2000392](https://doi.org/10.1109/tnn.2008.2000392).
- Farber, S. und Li, X. (2013). „Urban sprawl and social interaction potential: An empirical analysis of large metropolitan regions in the United States“. In: *Journal of Transport Geography* 31, S. 267–277. DOI: [10.1016/j.jtrangeo.2013.03.002](https://doi.org/10.1016/j.jtrangeo.2013.03.002).

- Ferster, C., Fischer, J., Manaugh, K., Nelson, T. und Winters, M. (2019). „Using OpenStreetMap to inventory bicycle infrastructure: A comparison with open data from cities“. In: *International Journal of Sustainable Transportation* 14.1, S. 64–73. DOI: [10.1080/15568318.2018.1519746](https://doi.org/10.1080/15568318.2018.1519746).
- Fonte, C., Minghini, M., Patriarca, J., Antoniou, V., See, L. und Skopeliti, A. (2017). „Generating up-to-date and detailed land use and land cover maps using OpenStreetMap and GlobeLand30“. In: *ISPRS International Journal of Geo-Information* 6.4, S. 125. DOI: [10.3390/ijgi6040125](https://doi.org/10.3390/ijgi6040125).
- Frasco, M., Hamner, B. und LeDell, E. (2018). *Metrics: Evaluation Metrics for Machine Learning*. Verfügbar unter: <https://CRAN.R-project.org/package=Metrics>. Zuletzt abgerufen am 12.01.2020.
- Freire, S., MacManus, K., Pesaresi, M., Doxsey-Whitfield, E. und Mills, J. (2016). „Development of new open and free multi-temporal global population grids at 250 m resolution“. In: *Geospatial Data in a Changing World; Association of Geographic Information Laboratories in Europe (AGILE), AGILE 2016*.
- Fried, T., Tun, T. H., Klopp, J. M. und Welle, B. (2020). „Measuring the Sustainable Development Goal (SDG) Transport Target and Accessibility of Nairobi’s Matatus“. In: *Transportation Research Record: Journal of the Transportation Research Board* 2674.5, S. 196–207. DOI: [10.1177/0361198120914620](https://doi.org/10.1177/0361198120914620).
- Gajurel, A., Puppala, A. J., Biswas, N. und Chimaurya, H. R. (2024). „Application of Satellite-Based Remote Sensing for the Management of Pavement Infrastructure Assets“. In: *Transportation Research Record: Journal of the Transportation Research Board* 2678.9, S. 623–638. DOI: [10.1177/03611981241230535](https://doi.org/10.1177/03611981241230535).
- Gao, Y. und Zhu, J. (2022). „Characteristics, Impacts and Trends of Urban Transportation“. In: *Encyclopedia* 2.2, S. 1168–1182. DOI: [10.3390/encyclopedia2020078](https://doi.org/10.3390/encyclopedia2020078).
- Ge, M., Friedrich, J. und Vigna, L. (2024). *Where Do Emissions Come From? 4 Charts Explain Greenhouse Gas Emissions by Sector*. Verfügbar unter: <https://www.wri.org/insights/4-charts-explain-greenhouse-gas-emissions-countries-and-sectors>. Zuletzt abgerufen am 25.03.2025. World Resources Institute.
- Georganos, S., Grippa, T., Gadiaga, A. N., Linard, C., Lennert, M., Vanhuysse, S., Mboga, N., Wolff, E. und Kalogirou, S. (2019). „Geographical random forests: a spatial extension of the random forest algorithm to address spatial heterogeneity in remote sensing and population modelling“. In: *Geocarto International*, S. 1–16. DOI: [10.1080/10106049.2019.1595177](https://doi.org/10.1080/10106049.2019.1595177).
- Geurs, K. T. und Wee, B. van (2004). „Accessibility evaluation of land-use and transport strategies: review and research directions“. In: *Journal of Transport Geography* 12.2, S. 127–140. DOI: [10.1016/j.jtrangeo.2003.10.005](https://doi.org/10.1016/j.jtrangeo.2003.10.005).
- Geurs, K. und Wee, B. van (2023). „Accessibility: perspectives, measures and applications“. In: *The transport system and transport policy: An introduction*. Edward Elgar, S. 178–199.

- Ghanea, M., Moallem, P. und Momeni, M. (2016). „Building extraction from high-resolution satellite images in urban areas: Recent methods and strategies against significant challenges“. In: *International Journal of Remote Sensing* 37.21, S. 5234–5248. DOI: [10.1080/01431161.2016.1230287](https://doi.org/10.1080/01431161.2016.1230287).
- Ghosh, A., Nundy, S., Ghosh, S. und Mallick, T. K. (2020). „Study of COVID-19 pandemic in London (UK) from urban context“. In: *Cities* 106, S. 102928. DOI: [10.1016/j.cities.2020.102928](https://doi.org/10.1016/j.cities.2020.102928).
- Gil, J. (2015). „Building a Multimodal Urban Network Model Using OpenStreetMap Data for the Analysis of Sustainable Accessibility“. In: *OpenStreetMap in GIScience*. Springer International Publishing, S. 229–251. DOI: [10.1007/978-3-319-14280-7_12](https://doi.org/10.1007/978-3-319-14280-7_12).
- Glazener, A. und Khreis, H. (2019). „Transforming Our Cities: Best Practices Towards Clean Air and Active Transportation“. In: *Current Environmental Health Reports* 6.1, S. 22–37. DOI: [10.1007/s40572-019-0228-1](https://doi.org/10.1007/s40572-019-0228-1).
- Glaeser, E. (2011). *Triumph of the city: How our greatest invention makes us richer, smarter, greener, healthier, and happier*. London: Penguin Press HC. 338 S.
- Glaeser, E. L. (2020). *Infrastructure and Urban Form*. Verfügbar unter: <https://ssrn.com/abstract=3756319>. NBER Working Paper. Zuletzt abgerufen am 09.10.2020.
- Goodwin, P. (2004). *The economic costs of road traffic congestion*. Verfügbar unter: https://discovery.ucl.ac.uk/id/eprint/1259/1/2004_25.pdf. Zuletzt abgerufen am 09.06.2025.
- Goodship, P. (2015). „The Social and Spatial Transformative Impact of an Urban Cable-Car: The case of Medellin (ab S. 397)“. In: *Architecture and Resilience - on the Human Scale*.
- Goodship, P. (2016). „Understanding the role of spatial connectivity in integrating informal settlements, through the case of Medellin’s urban cable-cars“. In: *Proceedings of the International Conference on Education and Research in Computer Aided Architectural Design in Europe*. Bd. 2, S. 79–88.
- Grange, L. de und Troncoso, R. (2011). „Impacts of vehicle restrictions on urban transport flows: The case of Santiago, Chile“. In: *Transport Policy*. DOI: [10.1016/j.tranpol.2011.06.001](https://doi.org/10.1016/j.tranpol.2011.06.001).
- Griffin, G. P., Mulhall, M., Simek, C. und Riggs, W. W. (2020). „Mitigating Bias in Big Data for Transportation“. In: *Journal of Big Data Analytics in Transportation* 2.1, S. 49–59. DOI: [10.1007/s42421-020-00013-0](https://doi.org/10.1007/s42421-020-00013-0).
- Guan, J., Zhang, K., Zhang, S. und Chen, Y. (2020). „How is public transit in the megacity peripheral relocatees’ area in China? Captive transit rider and dynamic modal accessibility gap analytics in a peripheral large-scale residential area in Shanghai, China“. In: *Journal of Transport and Land Use* 13.1, S. 1–21. DOI: [10.5198/jtlu.2020.1505](https://doi.org/10.5198/jtlu.2020.1505).
- Guindon, B. und Zhang, Y. (2007). „Using satellite remote sensing to survey transport-related urban sustainability. Part 2. Results of a Canadian urban assessment“. In: *International Journal of Applied Earth Observation and Geoinformation* 9.3, S. 276–293. DOI: [10.1016/j.jag.2006.09.006](https://doi.org/10.1016/j.jag.2006.09.006).

- Guillen, M. D., Ishida, H. und Okamoto, N. (2013). „Is the use of informal public transport modes in developing countries habitual? An empirical study in Davao City, Philippines“. In: *Transport Policy* 26, S. 31–42. DOI: [10.1016/j.tranpol.2012.03.008](https://doi.org/10.1016/j.tranpol.2012.03.008).
- Guney, E., Bayilmis, C. und Cakan, B. (2022). „An Implementation of Real-Time Traffic Signs and Road Objects Detection Based on Mobile GPU Platforms“. In: *IEEE Access* 10, S. 86191–86203. DOI: [10.1109/access.2022.3198954](https://doi.org/10.1109/access.2022.3198954).
- Guzman, L. A., Oviedo, D. und Rivera, C. (2017). „Assessing equity in transport accessibility to work and study: The Bogotá region“. In: *Journal of Transport Geography* 58, S. 236–246. DOI: [10.1016/j.jtrangeo.2016.12.016](https://doi.org/10.1016/j.jtrangeo.2016.12.016).
- Haitao, H., Yang, K., Liang, H., Menendez, M. und Guler, S. I. (2019). „Providing public transport priority in the perimeter of urban networks: A bimodal strategy“. In: *Transportation Research Part C: Emerging Technologies* 107, S. 171–192. DOI: [10.1016/j.trc.2019.08.004](https://doi.org/10.1016/j.trc.2019.08.004).
- Harvey, J. T. (2002). „Estimating census district populations from satellite imagery: Some approaches and limitations“. In: *International Journal of Remote Sensing* 23.10, S. 2071–2095. DOI: [10.1080/01431160110075901](https://doi.org/10.1080/01431160110075901).
- He, K., Gkioxari, G., Dollar, P. und Girshick, R. (2017). „Mask R-CNN“. In: *2017 IEEE International Conference on Computer Vision (ICCV)*. IEEE, S. 2980–2988. DOI: [10.1109/iccv.2017.322](https://doi.org/10.1109/iccv.2017.322).
- Hecht, R., Kunze, C. und Hahmann, S. (2013). „Measuring completeness of building footprints in OpenStreetMap over space and time“. In: *ISPRS International Journal of Geo-Information* 2.4, S. 1066–1091. DOI: [10.3390/ijgi2041066](https://doi.org/10.3390/ijgi2041066).
- Heinrichs, D. und Bernet, J. S. (2014). „Public Transport and Accessibility in Informal Settlements: Aerial Cable Cars in Medellín, Colombia“. In: *Transportation Research Procedia* 4, S. 55–67. DOI: [10.1016/j.trpro.2014.11.005](https://doi.org/10.1016/j.trpro.2014.11.005).
- Héritier, H., Vienneau, D., Frei, P., Eze, I., Brink, M., Probst-Hensch, N. und Röösli, M. (2014). „The Association between Road Traffic Noise Exposure, Annoyance and Health-Related Quality of Life (HRQOL)“. In: *International Journal of Environmental Research and Public Health* 11.12, S. 12652–12667. DOI: [10.3390/ijerph111212652](https://doi.org/10.3390/ijerph111212652).
- Herfort, B., Lautenbach, S., Albuquerque, J. P. de, Anderson, J. und Zipf, A. (2023). „A spatio-temporal analysis investigating completeness and inequalities of global urban building data in OpenStreetMap“. In: *Nature Communications* 14.1. DOI: [10.1038/s41467-023-39698-6](https://doi.org/10.1038/s41467-023-39698-6).
- Hertrich, M., Stiller, D., Sapena, M., Stark, T., Rose, P., Wurm, M. und Taubenböck, H. (2025). „Instance Segmentation of Informal Buildings in Medellín for Assessing Population at Risk from Landslides“. In: *2025 Joint Urban Remote Sensing Event (JURSE)*. IEEE, S. 1–4. DOI: [10.1109/jurse60372.2025.11076048](https://doi.org/10.1109/jurse60372.2025.11076048).
- Hidayati, I., Yamu, C. und Tan, W. (2020). „Realised pedestrian accessibility of an informal settlement in Jakarta, Indonesia“. In: *Journal of Urbanism: International Research on Placemaking and Urban Sustainability* 14.4, S. 434–456. DOI: [10.1080/17549175.2020.1814391](https://doi.org/10.1080/17549175.2020.1814391).

- Hipp, J. A., Manteiga, A., Burgess, A., Stylianou, A. und Pless, R. (2015). „Cameras and crowds in transportation tracking“. In: *Proceedings of the conference on Wireless Health*. WH '15. ACM, S. 1–8. DOI: [10.1145/2811780.2811941](https://doi.org/10.1145/2811780.2811941).
- Holzwarth, S. (2021). *Public Transport Accessibility - Monitoring SDG 11.2. UN-Habitat*. Verfügbar unter: https://unece.org/sites/default/files/2021-06/07UNHABITATUNECE2021_finalDM.pdf. Zuletzt abgerufen am 09.09.2024.
- Hoxha, G., Fandaj, A. und Bajrami, X. (2023). „Quality of Automatic Traffic Volume Counting by Cameras and Impact on the Qualitative Indicators of Traffic“. In: *Infrastructures* 8.3, S. 44. DOI: [10.3390/infrastructures8030044](https://doi.org/10.3390/infrastructures8030044).
- Hu, H., Xu, J., Shen, Q., Shi, F. und Chen, Y. (2018). „Travel mode choices in small cities of China: A case study of Changting“. In: *Transportation Research Part D: Transport and Environment* 59, S. 361–374. DOI: [10.1016/j.trd.2018.01.013](https://doi.org/10.1016/j.trd.2018.01.013).
- Huang, B., Zhao, B. und Song, Y. (2018). „Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery“. In: *Remote Sensing of Environment* 214, S. 73–86. DOI: [10.1016/j.rse.2018.04.050](https://doi.org/10.1016/j.rse.2018.04.050).
- Huang, Q., Yang, Y., Xu, Y., Yang, F., Yuan, Z. und Sun, Y. (2021). „Citywide road-network traffic monitoring using large-scale mobile signaling data“. In: *Neurocomputing* 444, S. 136–146. DOI: [10.1016/j.neucom.2020.07.150](https://doi.org/10.1016/j.neucom.2020.07.150).
- Huang, H., Wang, B., Xiao, J. und Zhu, T. (2024). „Improved small-object detection using YOLOv8: A comparative study“. In: *Applied and Computational Engineering* 41.1, S. 80–88. DOI: [10.54254/2755-2721/41/20230714](https://doi.org/10.54254/2755-2721/41/20230714).
- Hui, J., Du, M., Ye, X., Qin, Q. und Sui, J. (2019). „Effective building extraction from high-resolution remote sensing images with multitask driven deep neural network“. In: *IEEE Geoscience and Remote Sensing Letters* 16.5, S. 786–790. DOI: [10.1109/lgrs.2018.2880986](https://doi.org/10.1109/lgrs.2018.2880986).
- Ide, T., Katsuki, T., Morimura, T. und Morris, R. (2017). „City-Wide Traffic Flow Estimation From a Limited Number of Low-Quality Cameras“. In: *IEEE Transactions on Intelligent Transportation Systems* 18.4, S. 950–959. DOI: [10.1109/tits.2016.2597160](https://doi.org/10.1109/tits.2016.2597160).
- Ihlanfeldt, K. (2020). „Vehicle miles traveled and the built environment: New evidence from panel data“. In: *Journal of Transport and Land Use* 13.1, S. 23–48. DOI: [10.5198/jtlu.2020.1647](https://doi.org/10.5198/jtlu.2020.1647).
- Infraestructura de Datos Geoespeciales Chile (2019). *Fotografía aérea del Gran Santiago año 2014*. Verfügbar unter: <http://www.ide.cl/index.php/imagenes-y-mapas-base/item/1577-fotografia-aerea-del-gran-santiago-ano-2014>. Zuletzt abgerufen am 06.03.2019.
- infraVelo (2023a). *Projektkarte*. Verfügbar unter: <https://www.infravelo.de/karte/>. Zuletzt abgerufen am 27.06.2023.
- infraVelo (2023b). *Radschnellverbindung West-Route. Auf direktem Weg vom Westen Berlins Richtung Stadtmitte*. Verfügbar unter: <https://www.infravelo.de/projekt/west-route/>. Zuletzt abgerufen am 27.06.2023.

- INRIX (2023). *INRIX 2022 Global Traffic Scorecard*. Verfügbar unter: <https://inrix.com/scorecard-2022/>. Zuletzt abgerufen am 15.05.2024.
- Instituto Nacional de Estadísticas Chile (2017). *Censo de población y vivienda*. Verfügbar unter: <https://www.ine.cl/estadisticas/sociales/censos-de-poblacion-y-vivienda/poblacion-y-vivienda>. Zuletzt abgerufen am 08.08.2019.
- Instituto Social de Vivienda y Hábitat de Medellín (2019). *Plan estratégico habitacional de Medellín PEHMED 2030. Diagnóstico del Sistema Municipal Habitacional*. Spanish. Verfügbar unter: <https://isvimed.gov.co/wp-content/uploads/2020/10/PEHMED-2030.pdf>. Zuletzt abgerufen am 28.09.2022.
- Isenberg, T., Salazar, Z., Blanco, R. und Plaisant, C. (2022). „Do You Believe Your (Social Media) Data? A Personal Story on Location Data Biases, Errors, and Plausibility as Well as Their Visualization“. In: *IEEE Transactions on Visualization and Computer Graphics* 28.9, S. 3277–3291. DOI: [10.1109/tvcg.2022.3141605](https://doi.org/10.1109/tvcg.2022.3141605).
- Jain, S., Seth, G., Paruthi, A., Soni, U. und Kumar, G. (2020). „Synthetic data augmentation for surface defect detection and classification using deep learning“. In: *Journal of Intelligent Manufacturing* 33.4, S. 1007–1020. DOI: [10.1007/s10845-020-01710-x](https://doi.org/10.1007/s10845-020-01710-x).
- Jäppinen, S., Toivonen, T. und Salonen, M. (2013). „Modelling the potential effect of shared bicycles on public transport travel times in Greater Helsinki: An open data approach“. In: *Applied Geography* 43, S. 13–24. DOI: [10.1016/j.apgeog.2013.05.010](https://doi.org/10.1016/j.apgeog.2013.05.010).
- Ji, S., Wei, S. und Lu, M. (2018). „A scale robust convolutional neural network for automatic building extraction from aerial and satellite imagery“. In: *International Journal of Remote Sensing*, S. 1–15. DOI: [10.1080/01431161.2018.1528024](https://doi.org/10.1080/01431161.2018.1528024).
- Jia, J., Sun, H., Jiang, C., Karila, K., Karjalainen, M., Ahokas, E., Khoramshahi, E., Hu, P., Chen, C., Xue, T., Wang, T., Chen, Y. und Hyyppä, J. (2021). „Review on Active and Passive Remote Sensing Techniques for Road Extraction“. In: *Remote Sensing* 13.21, S. 4235. DOI: [10.3390/rs13214235](https://doi.org/10.3390/rs13214235).
- Jiang, P., Ergu, D., Liu, F., Cai, Y. und Ma, B. (2022). „A Review of Yolo Algorithm Developments“. In: *Procedia Computer Science* 199, S. 1066–1073. DOI: [10.1016/j.procs.2022.01.135](https://doi.org/10.1016/j.procs.2022.01.135).
- Jimenez, E. und Rengifo, D. (2016). „Delivering User Information in Resource-constrained Urban Transit Systems: The Case of Ibagué, Colombia“. In: *Transportation Research Procedia* 14, S. 3257–3264. DOI: [10.1016/j.trpro.2016.05.271](https://doi.org/10.1016/j.trpro.2016.05.271).
- Jin, J. (2019). „The effects of labor market spatial structure and the built environment on commuting behavior: Considering spatial effects and self-selection“. In: *Cities* 95, S. 102392. DOI: [10.1016/j.cities.2019.102392](https://doi.org/10.1016/j.cities.2019.102392).
- Jung, A. B., Wada, K., Crall, J., Tanaka, S., Graving, J., Reinders, C., Yadav, S., Banerjee, J., Vecsei, G., Kraft, A., Rui, Z., Borovec, J., Vallentin, C., Zhydenko, S., Pfeiffer, K., Cook, B., Fernández, I., De Rainville, F.-M., Weng, C.-H., Ayala-Acevedo, A., Meudec, R., Laporte, M. et al. (2020). *imgaug*. Verfügbar unter: <https://github.com/aleju/imgaug>. Zuletzt abgerufen am 01.02.2020.

- Kaddoura, I., Kröger, L. und Nagel, K. (2016). „User-specific and dynamic internalization of road traffic noise exposures“. In: *Networks and Spatial Economics* 17.1, S. 153–172. DOI: [10.1007/s11067-016-9321-2](https://doi.org/10.1007/s11067-016-9321-2).
- Kerzhner, T. (2024). „Creating an Informal Transport Route: Implications for Mobility, Gender, and Planning Processes“. In: *Journal of the American Planning Association* 90.4, S. 656–671. DOI: [10.1080/01944363.2024.2307920](https://doi.org/10.1080/01944363.2024.2307920).
- Khazukov, K., Shepelev, V., Karpeta, T., Shabiev, S., Slobodin, I., Charbadze, I. und Alferova, I. (2020). „Real-time monitoring of traffic parameters“. In: *Journal of Big Data* 7.1. DOI: [10.1186/s40537-020-00358-x](https://doi.org/10.1186/s40537-020-00358-x).
- Khalili, B. und Smyth, A. W. (2024). „SOD-YOLOv8—Enhancing YOLOv8 for Small Object Detection in Aerial Imagery and Traffic Scenes“. In: *Sensors* 24.19, S. 6209. DOI: [10.3390/s24196209](https://doi.org/10.3390/s24196209).
- Khomenko, S., Cirach, M., Barrera-Gómez, J., Pereira-Barboza, E., Iungman, T., Mueller, N., Foraster, M., Tonne, C., Thondoo, M., Jephcote, C., Gulliver, J., Woodcock, J. und Nieuwenhuijsen, M. (2022). „Impact of road traffic noise on annoyance and preventable mortality in European cities: A health impact assessment“. In: *Environment International* 162, S. 107160. DOI: [10.1016/j.envint.2022.107160](https://doi.org/10.1016/j.envint.2022.107160).
- Klinkhardt, C., Woerle, T., Briem, L., Heilig, M., Kagerbauer, M. und Vortisch, P. (2021). „Using OpenStreetMap as a Data Source for Attractiveness in Travel Demand Models“. In: *Transportation Research Record: Journal of the Transportation Research Board* 2675.8, S. 294–303. DOI: [10.1177/0361198121997415](https://doi.org/10.1177/0361198121997415).
- Klopp, J. M. und Cavoli, C. (2019). „Mapping minibuses in Maputo and Nairobi: engaging paratransit in transportation planning in African cities“. In: *Transport Reviews* 39.5, S. 657–676. DOI: [10.1080/01441647.2019.1598513](https://doi.org/10.1080/01441647.2019.1598513).
- Klumpp, M. (2018). „Economic and Social Advances for Geospatial Data Use in Vehicle Routing“. In: *Dynamics in Logistics*. Springer International Publishing, S. 368–377. DOI: [10.1007/978-3-319-74225-0_50](https://doi.org/10.1007/978-3-319-74225-0_50).
- Kochupillai, M., Kahl, M., Schmitt, M., Taubenbock, H. und Zhu, X. X. (2022). „Earth Observation and Artificial Intelligence: Understanding emerging ethical issues and opportunities“. In: *IEEE Geoscience and Remote Sensing Magazine* 10.4, S. 90–124. DOI: [10.1109/mgrs.2022.3208357](https://doi.org/10.1109/mgrs.2022.3208357).
- Koizumi, Y., Nishimiya, N. und Kaneako, M. (2013). „Urban Transportation Characteristics and Urban Mass Transit Introduction in the Cities of Developing Countries“. In: *Journal of the Eastern Asia Society for Transportation Studies* 10, S. 81–99. DOI: [10.11175/easts.10.81](https://doi.org/10.11175/easts.10.81).
- Kolarova, V., Eisenmann, C., Nobis, C., Winkler, C. und Lenz, B. (2021). „Analysing the impact of the COVID-19 outbreak on everyday travel behaviour in Germany and potential implications for future travel patterns“. In: *European Transport Research Review* 13.1. DOI: [10.1186/s12544-021-00486-2](https://doi.org/10.1186/s12544-021-00486-2).

- König, A. und Dreßler, A. (2021). „A mixed-methods analysis of mobility behavior changes in the COVID-19 era in a rural case study“. In: *European Transport Research Review* 13.1. DOI: [10.1186/s12544-021-00472-8](https://doi.org/10.1186/s12544-021-00472-8).
- Kopsiaftis, G. und Karantza, K. (2015). „Vehicle detection and traffic density monitoring from very high resolution satellite video data“. In: *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. IEEE. DOI: [10.1109/igarss.2015.7326160](https://doi.org/10.1109/igarss.2015.7326160).
- Köpfer, L. und Wieland, T. (2024). „Road User Classification from High-Frequency GNSS Data Using Distributed Edge Intelligence“. In: DOI: [10.48550/ARXIV.2412.00132](https://doi.org/10.48550/ARXIV.2412.00132). arXiv: [2412.00132 \[cs.LG\]](https://arxiv.org/abs/2412.00132).
- Krauß, T. (2014). „Six years operational processing of satellite data using CATENA at DLR: Experiences and recommendations“. In: *Kartographische Nachrichten* 64, S. 74–80. DOI: [10.1007/BF03544117](https://doi.org/10.1007/BF03544117).
- Krehl, A., Siedentop, S., Taubenböck, H. und Wurm, M. (2016). „A comprehensive view on urban spatial structure: Urban density patterns of German city regions“. In: *ISPRS International Journal of Geo-Information* 5.6, S. 76. DOI: [10.3390/ijgi5060076](https://doi.org/10.3390/ijgi5060076).
- Kühnl, M., Moll, M. S. und Taubenböck, H. (2021). „Categorizing Urban Structural Types using an Object-Based Local Climate Zone Classification Scheme in Medellín, Colombia“. In: *CITIES 20.50. Creating Habitats for the 3rd Millennium: Smart – Sustainable – Climate Neutral. Proceedings of the 26th International Conference on Urban Planning, Regional Development and Information Society*. CORP - Competence Center of Urban und Regional Planning, S. 173–182.
- Kumar, M., Singh, S., Ghate, A. T., Pal, S. und Wilson, S. A. (2016). „Informal public transport modes in India: A case study of five city regions“. In: *IATSS Research* 39.2, S. 102–109. DOI: [10.1016/j.iatssr.2016.01.001](https://doi.org/10.1016/j.iatssr.2016.01.001).
- Kumar, A., Zimmerman, S. und Arroyo, F. A. (2021). *Myths and Realities of Informal Public Transport in Developing Countries: Approaches for Improving the Sector - Discussion Paper*. License: CC BY 3.0 IGO. World Bank. URL: <http://hdl.handle.net/10986/37083>.
- Kumar, P., Choudhary, S. K., Pallerla, S., Sangani, S., Thota, A. und Matta, V. (2024). „Pi-Vision: Leveraging YOLO V8 for Real-Time Person Detection and Recognition on Raspberry Pi“. In: *2024 5th International Conference on Data Intelligence and Cognitive Informatics (ICDICI)*. IEEE, S. 1446–1450. DOI: [10.1109/icdici62993.2024.10810836](https://doi.org/10.1109/icdici62993.2024.10810836).
- Laar, M. van (2020). *ColombiaGTFS Medellin Metro*. Verfügbar unter: <https://github.com/ColombiaInfo/ColombiaGTFS/tree/master/Medellin%20-%20Metro>. Zuletzt abgerufen am 28.05.2025.
- Lantseva, A. A. und Ivanov, S. V. (2016). „Modeling Transport Accessibility with Open Data: Case Study of St. Petersburg“. In: *Procedia Computer Science* 101, S. 197–206. DOI: [10.1016/j.procs.2016.11.024](https://doi.org/10.1016/j.procs.2016.11.024).
- Landesamt für Gesundheit und Soziales Berlin (2021). *Lagebericht 27.02.2021. Zeitlicher Verlauf*. Verfügbar unter: <https://data.lageso.de/lageso/corona/archiv/berlin-website-2021-02-27.html#zeitlicher-verlauf>. Zuletzt abgerufen am 27.06.2023.

- LeCun, Y., Bengio, Y. und Hinton, G. (2015). „Deep learning“. In: *Nature* 521.7553, S. 436–444. DOI: [10.1038/nature14539](https://doi.org/10.1038/nature14539).
- Lee, S. und Lee, B. (2020). „Comparing the impacts of local land use and urban spatial structure on household VMT and GHG emissions“. In: *Journal of Transport Geography* 84, S. 102694. DOI: [10.1016/j.jtrangeo.2020.102694](https://doi.org/10.1016/j.jtrangeo.2020.102694).
- Lehmann, F., Berger, R., Brauchle, J., Hein, D., Meissner, H., Pless, S., Strackenbrock, B. und Wieden, A. (2011). „MACS – Modular Airborne Camera System for generating photogrammetric high-resolution products“. In: *Photogrammetrie - Fernerkundung - Geoinformation* 2011.6, S. 435–446. DOI: [10.1127/1432-8364/2011/0096](https://doi.org/10.1127/1432-8364/2011/0096).
- Levinson, H. S. und Falcocchio, J. (2011). „Urban Development and Traffic Congestion“. In: *Transportation and Development Institute Congress 2011*. American Society of Civil Engineers, S. 948–956. DOI: [10.1061/41167\(398\)90](https://doi.org/10.1061/41167(398)90).
- Levashev, A. (2017). „Application of geoinformation technologies for the transportation demand estimation“. In: *Transportation Research Procedia* 20, S. 406–411. DOI: [10.1016/j.trpro.2017.01.066](https://doi.org/10.1016/j.trpro.2017.01.066).
- Li, M., Kwan, M.-P., Yin, J., Yu, D. und Wang, J. (2018). „The potential effect of a 100-year pluvial flood event on metro accessibility and ridership: A case study of central Shanghai, China“. In: *Applied Geography* 100, S. 21–29. DOI: [10.1016/j.apgeog.2018.09.001](https://doi.org/10.1016/j.apgeog.2018.09.001).
- Li, J., Pei, X., Wang, X., Yao, D., Zhang, Y. und Yue, Y. (2021). „Transportation mode identification with GPS trajectory data and GIS information“. In: *Tsinghua Science and Technology* 26.4, S. 403–416. DOI: [10.26599/tst.2020.9010014](https://doi.org/10.26599/tst.2020.9010014).
- Li, Q., Mou, L., Sun, Y., Hua, Y., Shi, Y. und Zhu, X. X. (2024). „A Review of Building Extraction From Remote Sensing Imagery: Geometrical Structures and Semantic Attributes“. In: *IEEE Transactions on Geoscience and Remote Sensing* 62, S. 1–15. DOI: [10.1109/tgrs.2024.3369723](https://doi.org/10.1109/tgrs.2024.3369723).
- Liang, Y., You, J., Wang, R., Qin, B. und Han, S. (2024). „Urban Transportation Data Research Overview: A Bibliometric Analysis Based on CiteSpace“. In: *Sustainability* 16.22, S. 9615. DOI: [10.3390/su16229615](https://doi.org/10.3390/su16229615).
- Liddle, B. (2013). „Urban density and climate change: A STIRPAT analysis using city-level data“. In: *Journal of Transport Geography* 28, S. 22–29. DOI: [10.1016/j.jtrangeo.2012.10.010](https://doi.org/10.1016/j.jtrangeo.2012.10.010).
- Lin, T.-Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L. und Dollár, P. (2014). „Microsoft COCO: Common Objects in Context“. In: DOI: [10.48550/ARXIV.1405.0312](https://doi.org/10.48550/ARXIV.1405.0312). arXiv: [1405.0312 \[cs.CV\]](https://arxiv.org/abs/1405.0312).
- Linton, C., Grant-Muller, S. und Gale, W. F. (2015). „Approaches and techniques for modelling CO₂ emissions from road transport“. In: *Transport Reviews* 35.4, S. 533–553. DOI: [10.1080/01441647.2015.1030004](https://doi.org/10.1080/01441647.2015.1030004).
- Liu, W., Zhang, M., Luo, Z. und Cai, Y. (2017). „An Ensemble Deep Learning Method for Vehicle Type Classification on Visual Traffic Surveillance Sensors“. In: *IEEE Access* 5, S. 24417–24425. DOI: [10.1109/access.2017.2766203](https://doi.org/10.1109/access.2017.2766203).

- Liu, R., Wu, J., Lu, W., Miao, Q., Zhang, H., Liu, X., Lu, Z. und Li, L. (2024). „A Review of Deep Learning-Based Methods for Road Extraction from High-Resolution Remote Sensing Images“. In: *Remote Sensing* 16.12, S. 2056. DOI: [10.3390/rs16122056](https://doi.org/10.3390/rs16122056).
- Liu, L. (2020). „Emerging study on the transmission of the Novel Coronavirus (COVID-19) from urban perspective: Evidence from China“. In: *Cities* 103, S. 102759. DOI: [10.1016/j.cities.2020.102759](https://doi.org/10.1016/j.cities.2020.102759).
- Lu, Z., Im, J., Quackenbush, L. und Halligan, K. (2010). „Population estimation based on multi-sensor data fusion“. In: *International Journal of Remote Sensing* 31.21, S. 5587–5604. DOI: [10.1080/01431161.2010.496801](https://doi.org/10.1080/01431161.2010.496801).
- Lutz, E., Wicki, M. und Kaufmann, D. (2024). „Creating inequality in access to public transit? Density, gentrification, and displacement“. In: *Environment and Planning B: Urban Analytics and City Science* 51.9, S. 2196–2212. DOI: [10.1177/23998083241242883](https://doi.org/10.1177/23998083241242883).
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. und Johnson, B. A. (2019). „Deep learning in remote sensing applications: A meta-analysis and review“. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 152, S. 166–177. DOI: [10.1016/j.isprsjprs.2019.04.015](https://doi.org/10.1016/j.isprsjprs.2019.04.015).
- Machado, C. A. S. und Quintanilha, J. A. (2019). „Identification of trip generators using remote sensing and geographic information system“. In: *Transportation Research Interdisciplinary Perspectives* 3, S. 100069. DOI: [10.1016/j.trip.2019.100069](https://doi.org/10.1016/j.trip.2019.100069).
- Macioszek, E. und Kurek, A. (2021). „Extracting Road Traffic Volume in the City before and during covid-19 through Video Remote Sensing“. In: *Remote Sensing* 13.12, S. 2329. DOI: [10.3390/rs13122329](https://doi.org/10.3390/rs13122329).
- Magazzino, C. und Mele, M. (2021). „On the relationship between transportation infrastructure and economic development in China“. In: *Research in Transportation Economics* 88, S. 100947. DOI: [10.1016/j.retrec.2020.100947](https://doi.org/10.1016/j.retrec.2020.100947).
- Mai-Tan, H., Pham-Nguyen, H.-N., Long, N. X. und Minh, Q. T. (2020). „Mining Urban Traffic Condition from Crowd-Sourced Data“. In: *SN Computer Science* 1.4. DOI: [10.1007/s42979-020-00244-6](https://doi.org/10.1007/s42979-020-00244-6).
- Mansour, A. I. und Aljamal, H. A. (2022). „Investigating the Effect of Traffic Flow on Pollution, Noise for Urban Road Network“. In: *IOP Conference Series: Earth and Environmental Science* 961.1, S. 012067. DOI: [10.1088/1755-1315/961/1/012067](https://doi.org/10.1088/1755-1315/961/1/012067).
- Maparu, T. S. und Mazumder, T. N. (2021). „Investigating causality between transport infrastructure and urbanization: A state-level study of India (1991–2011)“. In: *Transport Policy* 113, S. 46–55. DOI: [10.1016/j.tranpol.2020.03.008](https://doi.org/10.1016/j.tranpol.2020.03.008).
- Martínez, L. M., Viegas, J. M. und Silva, E. A. (2009). „A traffic analysis zone definition: A new methodology and algorithm“. In: *Transportation* 36.5, S. 581–599. DOI: [10.1007/s11116-009-9214-z](https://doi.org/10.1007/s11116-009-9214-z).
- María, H. S., Hube, M. A., Rivera, F., Yepes-Estrada, C. und Valcárcel, J. A. (2016). „Development of national and local exposure models of residential structures in Chile“. In: *Natural Hazards* 86.S1, S. 55–79. DOI: [10.1007/s11069-016-2518-3](https://doi.org/10.1007/s11069-016-2518-3).

- Mateo-Babiano, I., Recio, R. B., Ashmore, D. P., Guillen, M. D. und Gaspay, S. M. (2020). „Formalising the jeepney industry in the Philippines – A confirmatory thematic analysis of key transitionary issues“. In: *Research in Transportation Economics* 83, S. 100839. DOI: [10.1016/j.retrec.2020.100839](https://doi.org/10.1016/j.retrec.2020.100839).
- McCormack, G. R. und Shiell, A. (2011). „In search of causality: a systematic review of the relationship between the built environment and physical activity among adults“. In: *International Journal of Behavioral Nutrition and Physical Activity* 8.1, S. 125. DOI: [10.1186/1479-5868-8-125](https://doi.org/10.1186/1479-5868-8-125).
- McKeen, T., Bondarenko, M., Kerr, D., Esch, T., Marconcini, M., Palacios-Lopez, D., Zeidler, J., Valle, R. C., Juran, S., Tatem, A. J. und Sorichetta, A. (2023). „High-resolution gridded population datasets for Latin America and the Caribbean using official statistics“. In: *Scientific Data* 10.1. DOI: [10.1038/s41597-023-02305-w](https://doi.org/10.1038/s41597-023-02305-w).
- McKeown, D. M. (1990). „Toward Automatic Cartographic Feature Extraction“. In: *Mapping and Spatial Modelling for Navigation*. Springer Berlin Heidelberg, S. 149–180. DOI: [10.1007/978-3-642-84215-3_8](https://doi.org/10.1007/978-3-642-84215-3_8).
- Messe Berlin (2021). *Geschäftsbericht 2020*. Verfügbar unter: <https://legacy.messe-berlin.de/messe-berlin/downloads-deutsch/unternehmen/messe-berlin-geschaeftsbericht-2020.pdf>. Zuletzt abgerufen am 04.08.2023.
- Metro de Medellín (2021). *Mapa del Metro de Medellín. Datos del Sistema / Metro Facts*. Verfügbar unter: [https://www.metrodemedellin.gov.co/hs-fs/hubfs/Infografico-datos-sistema-metro-2023\(1\).webp?width=1800&height=1788&name=Infografico-datos-sistema-metro-2023\(1\).webp](https://www.metrodemedellin.gov.co/hs-fs/hubfs/Infografico-datos-sistema-metro-2023(1).webp?width=1800&height=1788&name=Infografico-datos-sistema-metro-2023(1).webp). Zuletzt abgerufen am 09.06.2025.
- Microsoft (2025). *Global ML Building Footprints*. Verfügbar unter: <https://github.com/microsoft/GlobalMLBuildingFootprints>. Zuletzt abgerufen am 06.05.2025.
- Miller, H. J. und Shaw, S.-L. (2015). „Geographic Information Systems for Transportation in the 21st Century“. In: *Geography Compass* 9.4, S. 180–189. DOI: [10.1111/gec3.12204](https://doi.org/10.1111/gec3.12204).
- Milojevic-Dupont, N., Wagner, F., Nachtigall, F., Hu, J., Brüser, G. B., Zumwald, M., Biljecki, F., Heeren, N., Kaack, L. H., Pichler, P.-P. und Creutzig, F. (2023). „EUBUCCO v0.1: European building stock characteristics in a common and open database for 200+ million individual buildings“. In: *Scientific Data* 10.1. DOI: [10.1038/s41597-023-02040-2](https://doi.org/10.1038/s41597-023-02040-2).
- Mok, T. M., Cornish, F. und Tarr, J. (2014). „Too Much Information: Visual Research Ethics in the Age of Wearable Cameras“. In: *Integrative Psychological and Behavioral Science* 49.2, S. 309–322. DOI: [10.1007/s12124-014-9289-8](https://doi.org/10.1007/s12124-014-9289-8).
- Molloy, J., Schatzmann, T., Schoeman, B., Tchervenkov, C., Hintermann, B. und Axhausen, K. W. (2021). „Observed impacts of the Covid-19 first wave on travel behaviour in Switzerland based on a large GPS panel“. In: *Transport Policy* 104, S. 43–51. DOI: [10.1016/j.tranpol.2021.01.009](https://doi.org/10.1016/j.tranpol.2021.01.009).
- Morales, J., Flacke, J., Morales, J. und Zevenbergen, J. (2017). „Mapping Urban Accessibility in Data Scarce Contexts Using Space Syntax and Location-Based Methods“. In: *Applied Spatial Analysis and Policy* 12.2, S. 205–228. DOI: [10.1007/s12061-017-9239-1](https://doi.org/10.1007/s12061-017-9239-1).

- Müller, C. und Doevenspeck, M. (2023). „The fast and the victorious: Mobility, motorcyclists and political mobilisation in Uganda“. In: *Area* 55.3, S. 399–406. DOI: [10.1111/area.12872](https://doi.org/10.1111/area.12872).
- Nelson, R. J. (2021). „The spatial and social logic of the Minibus Taxi network: how access may support social inclusion in Cape Town, South Africa“. In: *Applied Mobilities* 8.1, S. 1–25. DOI: [10.1080/23800127.2021.1926054](https://doi.org/10.1080/23800127.2021.1926054).
- Ngo, T.-T., Collet, C. und Mazet, V. (2015). „Automatic rectangular building detection from VHR aerial imagery using shadow and image segmentation“. In: *2015 IEEE International Conference on Image Processing (ICIP)*. IEEE. DOI: [10.1109/icip.2015.7351047](https://doi.org/10.1109/icip.2015.7351047).
- Nicolas, J.-P. (2000). „Analysing road traffic influences on air pollution: How to achieve sustainable urban development“. In: *Transport Reviews* 20.2, S. 219–232. DOI: [10.1080/014416400295266](https://doi.org/10.1080/014416400295266).
- Nieland, S. und Yosmaoglu, S. (2022). *PtAC*. Verfügbar unter: <https://github.com/DLR-VF/PtAC>. Zuletzt abgerufen am 09.06.2025.
- Nieuwenhuijsen, M. J. (2020). „Urban and transport planning pathways to carbon neutral, liveable and healthy cities; A review of the current evidence“. In: *Environment International* 140, S. 105661. DOI: [10.1016/j.envint.2020.105661](https://doi.org/10.1016/j.envint.2020.105661).
- Nordenholz, F., Metzler, S. und Winkler, C. (2019). „An automated gradual zoning approach for large-scale transport models“. In: *Procedia Computer Science* 151, S. 147–154. DOI: [10.1016/j.procs.2019.04.023](https://doi.org/10.1016/j.procs.2019.04.023).
- Nuhn, H. und Hesse, M. (2006). *Verkehrsgeographie*. Paderborn: Ferdinand Schöningh GmbH.
- O’Brien, J. und Evans, J. (2017). „Informal mobilities and elusive subjects: Researching urban transport in the Global South“. In: *Urban Mobilities in the Global South*. Routledge, S. 78–94.
- Ochoa-Covarrubias, G., Grindlay, A. L. und Lizarraga, C. (2021). „Does the Mass Public Transport System Cover the Social Transport Needs? Targeting SDG 11.2 in Guadalajara, Mexico“. In: *Applied Sciences* 11.16, S. 7709. DOI: [10.3390/app11167709](https://doi.org/10.3390/app11167709).
- Okami, S., Matsuyuki, M., Sarmiento-Ordosgoitia, I. und Nakamura, F. (2022). „Residents’ travel behavior in a low-income settlement with aerial cable cars in Medellín, Colombia“. In: *Case Studies on Transport Policy* 10.2, S. 1332–1342. DOI: [10.1016/j.cstp.2022.04.016](https://doi.org/10.1016/j.cstp.2022.04.016).
- Okokon, E., Turunen, A., Ung-Lanki, S., Vartiainen, A.-K., Tiittanen, P. und Lanki, T. (2015). „Road-traffic noise: Annoyance, risk perception, and noise sensitivity in the Finnish adult population“. In: *International Journal of Environmental Research and Public Health* 12.6, S. 5712–5734. DOI: [10.3390/ijerph120605712](https://doi.org/10.3390/ijerph120605712).
- OpenStreetMap contributors (2025). *OpenStreetMap*. Verfügbar unter: <https://www.openstreetmap.org>. Zuletzt abgerufen am 16.05.2025.
- Palubinskas, G., Kurz, F. und Reinartz, P. (2008). „Detection of Traffic Congestion in Optical Remote Sensing Imagery“. In: *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, S. II-426–II-429. DOI: [10.1109/igarss.2008.4779019](https://doi.org/10.1109/igarss.2008.4779019).
- Palubinskas, G., Kurz, F. und Reinartz, P. (2010). „Model based traffic congestion detection in optical remote sensing imagery“. In: *European Transport Research Review* 2.2, S. 85–92. DOI: [10.1007/s12544-010-0028-z](https://doi.org/10.1007/s12544-010-0028-z).

- Palacios-Lopez, D., Esch, T., MacManus, K., Marconcini, M., Sorichetta, A., Yetman, G., Zeidler, J., Dech, S., Tatem, A. J. und Reinartz, P. (2022). „Towards an Improved Large-Scale Gridded Population Dataset: A Pan-European Study on the Integration of 3D Settlement Data into Population Modelling“. In: *Remote Sensing* 14.2, S. 325. DOI: [10.3390/rs14020325](https://doi.org/10.3390/rs14020325).
- Parr, J. B. (2013). „The regional economy, spatial structure and regional urban systems“. In: *Regional Studies* 48.12, S. 1926–1938. DOI: [10.1080/00343404.2013.799759](https://doi.org/10.1080/00343404.2013.799759).
- Pareja, D. J. (2015). *Transporte informal está en más de 70 sectores de Medellín*. Verfügbar unter: <https://www.eltiempo.com/archivo/documento/CMS-15380917>. Zuletzt abgerufen am 09.06.2025.
- Perko, R., Raggam, H., Gutjahr, K. H. und Schardt, M. (2015). „Advanced DTM generation from very high resolution satellite stereo images“. In: *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences* II-3/W4, S. 165–172. DOI: [10.5194/isprsannals-ii-3-w4-165-2015](https://doi.org/10.5194/isprsannals-ii-3-w4-165-2015).
- Petutschnig, A., Resch, B., Lang, S. und Havas, C. (2021). „Evaluating the Representativeness of Socio-Demographic Variables over Time for Geo-Social Media Data“. In: *ISPRS International Journal of Geo-Information* 10.5, S. 323. DOI: [10.3390/ijgi10050323](https://doi.org/10.3390/ijgi10050323).
- Pijl, A., Bailly, J.-S., Feurer, D., Maaoui, M. A. E., Boussema, M. R. und Tarolli, P. (2020). „TERRA: Terrain extraction from elevation rasters through repetitive anisotropic filtering“. In: *International Journal of Applied Earth Observation and Geoinformation* 84, S. 101977. DOI: [10.1016/j.jag.2019.101977](https://doi.org/10.1016/j.jag.2019.101977).
- Piltz, B., Bayer, S. und Poznanska, A. M. (2016). „Volume based DTM generation from very high resolution photogrammetric DSMS“. In: *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLI-B3, S. 83–90. DOI: [10.5194/isprs-archives-XLI-B3-83-2016](https://doi.org/10.5194/isprs-archives-XLI-B3-83-2016).
- Plano, C. und Behrens, R. (2022). „Integrating para- and scheduled transit: Minibus paratransit operators' perspective on reform in Cape Town“. In: *Research in Transportation Business and Management* 42, S. 100664. DOI: [10.1016/j.rtbm.2021.100664](https://doi.org/10.1016/j.rtbm.2021.100664).
- Prieto, C. A. M. (2014). *En el transporte público de Colombia se mezclan lo formal y lo informal*. Techn. Ber. World Bank.
- Puertas, O. L., Henríquez, C. und Meza, F. J. (2014). „Assessing spatial dynamics of urban growth using an integrated land use model. Application in Santiago metropolitan area, 2010–2045“. In: *Land Use Policy* 38, S. 415–425. DOI: [10.1016/j.landusepol.2013.11.024](https://doi.org/10.1016/j.landusepol.2013.11.024).
- Rahman, M. M., Najaf, P., Fields, M. G. und Thill, J.-C. (2021). „Traffic congestion and its urban scale factors: Empirical evidence from American urban areas“. In: *International Journal of Sustainable Transportation* 16.5, S. 406–421. DOI: [10.1080/15568318.2021.1885085](https://doi.org/10.1080/15568318.2021.1885085).
- Redmon, J., Divvala, S., Girshick, R. und Farhadi, A. (2016). „You Only Look Once: Unified, Real-Time Object Detection“. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. DOI: [10.1109/cvpr.2016.91](https://doi.org/10.1109/cvpr.2016.91).

- Ren, S., He, K., Girshick, R. und Sun, J. (2017). „Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 39.6, S. 1137–1149. DOI: [10.1109/tpami.2016.2577031](https://doi.org/10.1109/tpami.2016.2577031).
- Resch, E., Bohne, R. A., Kvamsdal, T. und Lohne, J. (2016). „Impact of urban density and building height on energy use in cities“. In: *Energy Procedia* 96, S. 800–814. DOI: [10.1016/j.egypro.2016.09.142](https://doi.org/10.1016/j.egypro.2016.09.142).
- Restrepo, V. (2019). *¿Nos llenamos de mototaxis en Medellín?* es. Verfügbar unter: <https://www.elcolombiano.com/antioquia/movilidad/mototaxis-en-medellin-ME10416758>. Zuletzt abgerufen am 09.06.2025.
- Rodrigue, J.-P., Comtois, C. und Slack, B. (2016). *The geography of transport systems*. Oxfordshire: Routledge, Taylor & Francis Ltd. 440 S.
- Rodriguez, C., Peralta-Quirós, T., Guzman, L. A. und Reyes, S. A. C. (2017). „Accessibility, Affordability, and Addressing Informal Services in Bus Reform: Lessons from Bogotá, Colombia“. In: *Transportation Research Record: Journal of the Transportation Research Board* 2634.1, S. 35–42. DOI: [10.3141/2634-06](https://doi.org/10.3141/2634-06).
- Roselló, X., Langeland, A. und Viti, F. (2016). „Public Transport in the Era of ITS: The Role of Public Transport in Sustainable Cities and Regions“. In: *Modelling Public Transport Passenger Flows in the Era of Intelligent Transport Systems*. Springer International Publishing, S. 3–27. DOI: [10.1007/978-3-319-25082-3_1](https://doi.org/10.1007/978-3-319-25082-3_1).
- Safaldin, M., Zaghdien, N. und Mejdoub, M. (2024). „An Improved YOLOv8 to Detect Moving Objects“. In: *IEEE Access* 12, S. 59782–59806. DOI: [10.1109/access.2024.3393835](https://doi.org/10.1109/access.2024.3393835).
- Saghapour, T., Moridpour, S. und Thompson, R. G. (2016). „Public transport accessibility in metropolitan areas: A new approach incorporating population density“. In: *Journal of Transport Geography* 54, S. 273–285. DOI: [10.1016/j.jtrangeo.2016.06.019](https://doi.org/10.1016/j.jtrangeo.2016.06.019).
- Saif, M. A., Zefreh, M. M. und Torok, A. (2019). „Public Transport Accessibility: A Literature Review“. In: *Periodica Polytechnica Transportation Engineering* 47.1, S. 36–43. DOI: [10.3311/pptr.12072](https://doi.org/10.3311/pptr.12072).
- Sakai, K., Seo, T. und Fuse, T. (2019). „Traffic density estimation method from small satellite imagery: Towards frequent remote sensing of car traffic“. In: *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*. IEEE, S. 1776–1781. DOI: [10.1109/itsc.2019.8916990](https://doi.org/10.1109/itsc.2019.8916990).
- Salanova Grau, J. M., Toumpalidis, I., Chaniotakis, E., Karanikolas, N. und Aifadopoulou, G. (2017). „Correlation between digital and physical world, case study in Thessaloniki“. In: *Journal of Location Based Services* 11.2, S. 118–132. DOI: [10.1080/17489725.2017.1420257](https://doi.org/10.1080/17489725.2017.1420257).
- Salvo, G., Caruso, L., Scordo, A., Guido, G. und Vitale, A. (2017). „Traffic data acquirement by unmanned aerial vehicle“. In: *European Journal of Remote Sensing* 50.1, S. 343–351. DOI: [10.1080/22797254.2017.1328978](https://doi.org/10.1080/22797254.2017.1328978).
- Sapena, M., Kühnl, M., Wurm, M., Patino, J. E., Duque, J. C. und Taubenböck, H. (2022). „Empiric recommendations for population disaggregation under different data scenarios“. In: *PLOS ONE* 17.9. Hrsg. von I. Benenson, e0274504. DOI: [10.1371/journal.pone.0274504](https://doi.org/10.1371/journal.pone.0274504).

- Sarlas, G., Páez, A. und Axhausen, K. W. (2020). „Betweenness-accessibility: Estimating impacts of accessibility on networks“. In: *Journal of Transport Geography* 84, S. 102680. DOI: [10.1016/j.jtrangeo.2020.102680](https://doi.org/10.1016/j.jtrangeo.2020.102680).
- Schultz, M., Voss, J., Auer, M., Carter, S. und Zipf, A. (2017). „Open land cover from OpenStreetMap and remote sensing“. In: *International Journal of Applied Earth Observation and Geoinformation* 63, S. 206–213. DOI: [10.1016/j.jag.2017.07.014](https://doi.org/10.1016/j.jag.2017.07.014).
- Schmidt, P., Feng, J. und Freeze, R. (2021). „Geographic Data Informs Funding and Management of Metro Bike Share System“. In: *Proceedings of the 54th Hawaii International Conference on System Sciences*. HICSS. Hawaii International Conference on System Sciences. DOI: [10.24251/hicss.2021.649](https://doi.org/10.24251/hicss.2021.649).
- Schuegraf, P., Stiller, D., Tian, J., Stark, T., Wurm, M., Taubenböck, H. und Bittner, K. (2024). „Ai-Based Building Instance Segmentation in Formal and Informal Settlements“. In: *IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium*. Bd. 3. IEEE, S. 1558–1561. DOI: [10.1109/igarss53475.2024.10642589](https://doi.org/10.1109/igarss53475.2024.10642589).
- Sclar, E. und Touber, J. (2011). „Economic fall-out of failing urban transport systems: an institutional analysis“. In: *Urban Transport in the Developing World*. Edward Elgar Publishing. DOI: [10.4337/9781849808392.00016](https://doi.org/10.4337/9781849808392.00016).
- Senaratne, H., Mobasher, A., Ali, A. L., Capineri, C. und Haklay, M. (2016). „A review of volunteered geographic information quality assessment methods“. In: *International Journal of Geographical Information Science* 31.1, S. 139–167. DOI: [10.1080/13658816.2016.1189556](https://doi.org/10.1080/13658816.2016.1189556).
- Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin (2018). *Mobilität in Städten – System repräsentativer Verkehrsbefragungen (SrV) 2018*. Verfügbar unter: <https://www.berlin.de/sen/uvk/mobilitaet-und-verkehr/verkehrsdaten/zahlen-und-fakten/mobilitaet-in-staedten-srv-2018/>. Zuletzt abgerufen am 09.06.2025.
- Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin (2021). *Fahrrad Berlin. Fortschrittsbericht 2020*.
- Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin (2023). *Übergeordnetes Straßennetz Bestand*. Verfügbar unter: https://fbinter.stadt-berlin.de/fb/index.jsp?loginkey=showMap&mapId=verkehr_strnetz@senstadt. Zuletzt abgerufen am 09.12.2024.
- Sevtsuk, A. und Mekonnen, M. (2012). „Urban network analysis. A new toolbox for ArcGIS“. In: *Revue internationale de géomatique* 22.2, S. 287–305. DOI: [10.3166/rig.22.287-305](https://doi.org/10.3166/rig.22.287-305).
- Shahi, K., Shafri, H. Z. M. und Hamedianfar, A. (2016). „Road condition assessment by OBIA and feature selection techniques using very high-resolution WorldView-2 imagery“. In: *Geocarto International* 32.12, S. 1389–1406. DOI: [10.1080/10106049.2016.1213888](https://doi.org/10.1080/10106049.2016.1213888).
- Sherbinin, A. de, Balk, D., Yager, K., Jaiteh, M., Pozzi, F., Giri, C. und Wannebo, A. (2002). „Social science applications of remote sensing. A CIESIN thematic guide“. In: Palisades, NY.

- Sierpiński, G. (2017). „Open Street Map as a Source of Information for a Freight Transport Planning System“. In: *Advanced Solutions of Transport Systems for Growing Mobility*. Springer International Publishing, S. 193–202. DOI: [10.1007/978-3-319-62316-0_16](https://doi.org/10.1007/978-3-319-62316-0_16).
- Sirmacek, B., Taubenböck, H., Reinartz, P. und Ehlers, M. (2012). „Performance Evaluation for 3-D City Model Generation of Six Different DSMs From Air- and Spaceborne Sensors“. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5.1, S. 59–70. DOI: [10.1109/jstars.2011.2178399](https://doi.org/10.1109/jstars.2011.2178399).
- Smith, M., Szongott, C., Henne, B. und Voigt, G. von (2012). „Big data privacy issues in public social media“. In: *2012 6th IEEE International Conference on Digital Ecosystems and Technologies (DEST)*. IEEE. DOI: [10.1109/dest.2012.6227909](https://doi.org/10.1109/dest.2012.6227909).
- Sohn, G. und Dowman, I. (2007). „Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction“. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 62.1, S. 43–63. DOI: [10.1016/j.isprsjprs.2007.01.001](https://doi.org/10.1016/j.isprsjprs.2007.01.001).
- Sohn, J. (2005). „Are commuting patterns a good indicator of urban spatial structure?“ In: *Journal of Transport Geography* 13.4, S. 306–317. DOI: [10.1016/j.jtrangeo.2004.07.005](https://doi.org/10.1016/j.jtrangeo.2004.07.005).
- Soltani, A. und Somenahalli, S. (2005). „Household vehicle ownership: Does urban structure matter?“ In: *28th Australasian Transport Research Forum, ATRF 05*. Bd. 28. Curtin University, Australia.
- Soliman, A., Soltani, K., Yin, J., Padmanabhan, A. und Wang, S. (2017). „Social sensing of urban land use based on analysis of Twitter users' mobility patterns“. In: *PLOS ONE* 12.7, e0181657. DOI: [10.1371/journal.pone.0181657](https://doi.org/10.1371/journal.pone.0181657).
- Soni, N. B. und Saraswat, J. (2017). „A review of IoT devices for traffic management system“. In: *2017 International Conference on Intelligent Sustainable Systems (ICISS)*. IEEE, S. 1052–1055. DOI: [10.1109/iss1.2017.8389341](https://doi.org/10.1109/iss1.2017.8389341).
- Spellerberg, I. (1998). „Ecological effects of roads and traffic: a literature review: Ecological effects of roads“. In: *Global Ecology and Biogeography* 7.5, S. 317–333. DOI: [10.1046/j.1466-822x.1998.00308.x](https://doi.org/10.1046/j.1466-822x.1998.00308.x).
- Srinivasan, S., Provost, R. und Steiner, R. (2013). „Modeling the land-use correlates of vehicle-trip lengths for assessing the transportation impacts of land developments“. In: *Journal of Transport and Land Use* 6.2, S. 59. DOI: [10.5198/jtlu.v6i2.254](https://doi.org/10.5198/jtlu.v6i2.254).
- Stanley, J. und Stanley, J. (2017). „The Importance of Transport for Social Inclusion“. In: *Social Inclusion* 5.4, S. 108–115. DOI: [10.17645/si.v5i4.1289](https://doi.org/10.17645/si.v5i4.1289).
- Staab, J., Udas, E., Mayer, M., Taubenböck, H. und Job, H. (2021). „Comparing established visitor monitoring approaches with triggered trail camera images and machine learning based computer vision“. In: *Journal of Outdoor Recreation and Tourism* 35, S. 100387. DOI: [10.1016/j.jort.2021.100387](https://doi.org/10.1016/j.jort.2021.100387).
- Starkey, P., Batool, Z., Younis, E. M. W., Rehman, A. U. und Ali, M. S. (2021). „Motorcycle three-wheelers in Pakistan: Low-cost rural transport services, crucial for women's mobility“. In: *Transportation Research Interdisciplinary Perspectives* 12, S. 100479. DOI: [10.1016/j.trip.2021.100479](https://doi.org/10.1016/j.trip.2021.100479).

- Stark, T., Ştefan, V., Wurm, M., Spanier, R., Taubenböck, H. und Knight, T. M. (2023). „YOLO object detection models can locate and classify broad groups of flower-visiting arthropods in images“. In: *Scientific Reports* 13.1. DOI: [10.1038/s41598-023-43482-3](https://doi.org/10.1038/s41598-023-43482-3).
- Stadtteilvertretung Turmstrasse (2021). *Alt-Moabit nicht links liegen lassen!* Verfügbar unter: <https://stv-turmstrasse.de/projekte/alt-moabit-nicht-links-liegen-lassen/>. Zuletzt abgerufen am: 09.06.2025.
- Statistisches Bundesamt (2021). *Fernbusse: Fahrgastrückgang im Linienverkehr um 70 % im Jahr 2020*. Verfügbar unter: https://www.destatis.de/DE/Presse/Pressemitteilungen/Zahl-der-Woche/2021/PD21_41_p002.html. Zuletzt abgerufen am 27.06.2023.
- Stevens, F. R., Gaughan, A. E., Linard, C. und Tatem, A. J. (2015). „Disaggregating census data for population mapping using random forests with remotely-sensed and ancillary data“. In: *PLOS ONE* 10.2, e0107042. DOI: [10.1371/journal.pone.0107042](https://doi.org/10.1371/journal.pone.0107042).
- Stevenson, M., Thompson, J., Sá, T. H. de, Ewing, R., Mohan, D., McClure, R., Roberts, I., Tiwari, G., Giles-Corti, B., Sun, X., Wallace, M. und Woodcock, J. (2016). „Land use, transport, and population health: Estimating the health benefits of compact cities“. In: *The Lancet* 388.10062, S. 2925–2935. DOI: [10.1016/s0140-6736\(16\)30067-8](https://doi.org/10.1016/s0140-6736(16)30067-8).
- Steinnocher, K., Bono, A. D., Chatenoux, B., Tiede, D. und Wendt, L. (2019). „Estimating urban population patterns from stereo-satellite imagery“. In: *European Journal of Remote Sensing* 52.sup2, S. 12–25. DOI: [10.1080/22797254.2019.1604081](https://doi.org/10.1080/22797254.2019.1604081).
- Stiller, D., Ottinger, M. und Leinenkugel, P. (2019a). „Spatio-temporal patterns of coastal aquaculture derived from Sentinel-1 time series data and the full Landsat archive“. In: *Remote Sensing* 11.14, S. 1707. DOI: [10.3390/rs11141707](https://doi.org/10.3390/rs11141707).
- Stiller, D., Stark, T., Wurm, M., Dech, S. und Taubenböck, H. (2019b). „Large-scale building extraction in very high-resolution aerial imagery using Mask R-CNN“. In: *2019 Joint Urban Remote Sensing Event (JURSE)*. IEEE. DOI: [10.1109/jurse.2019.8808977](https://doi.org/10.1109/jurse.2019.8808977).
- Stiller, D., Wurm, M., Stark, T., D'Angelo, P., Stebner, K., Dech, S. und Taubenböck, H. (2021). „Spatial parameters for transportation: A multi-modal approach for modelling the urban spatial structure using deep learning and remote sensing“. In: *Journal of Transport and Land Use* 14.1. DOI: [10.5198/jtlu.2021.1855](https://doi.org/10.5198/jtlu.2021.1855).
- Stiller, D., Wurm, M., Sapena, M., Nieland, S., Dech, S. und Taubenböck, H. (2025). „Does formal public transport serve the city well? The importance of semiformal transport for the accessibility in Medellín, Colombia“. In: *PLOS ONE* 20.4, e0321691. DOI: [10.1371/journal.pone.0321691](https://doi.org/10.1371/journal.pone.0321691).
- Suchandt, S., Runge, H., Breit, H., Steinbrecher, U., Kotenkov, A. und Balss, U. (2010). „Automatic Extraction of Traffic Flows Using TerraSAR-X Along-Track Interferometry“. In: *IEEE Transactions on Geoscience and Remote Sensing* 48.2, S. 807–819. DOI: [10.1109/tgrs.2009.2037919](https://doi.org/10.1109/tgrs.2009.2037919).
- Sun, B., Ermagun, A. und Dan, B. (2017). „Built environmental impacts on commuting mode choice and distance: Evidence from Shanghai“. In: *Transportation Research Part D: Transport and Environment* 52, S. 441–453. DOI: [10.1016/j.trd.2016.06.001](https://doi.org/10.1016/j.trd.2016.06.001).

- sunrise-and-sunset.com (2023). *Sonnenaufgang und Sonnenuntergang Deutschland*. Verfügbar unter: <https://www.sunrise-and-sunset.com/de/sun/deutschland>. Zuletzt abgerufen am 09.06.2025.
- Sweet, M. (2013). „Traffic Congestion’s Economic Impacts: Evidence from US Metropolitan Regions“. In: *Urban Studies* 51.10, S. 2088–2110. DOI: [10.1177/0042098013505883](https://doi.org/10.1177/0042098013505883).
- Szwoch, G. (2019). „Combining Road Network Data from OpenStreetMap with an Authoritative Database“. In: *Journal of Transportation Engineering, Part A: Systems* 145.2. DOI: [10.1061/jtepbs.0000215](https://doi.org/10.1061/jtepbs.0000215).
- Tatem, A. J. (2017). „WorldPop, open data for spatial demography“. In: *Scientific Data* 4.1. DOI: [10.1038/sdata.2017.4](https://doi.org/10.1038/sdata.2017.4).
- Taubenböck, H., Roth, A. und Dech, S. (2008). „Linking structural urban characteristics derived from high resolution satellite data to population distribution“. In: *Urban and regional data management*. Hrsg. von Coors, V und Rumor, M and Fendel, E and Zlatanova, S. Proceedings and Monographs in Engineering, Water and Earth Sciences. Annual Symposium of the Urban-Data-Management-Society, Stuttgart, Germany, OCT 10-12, 2007, S. 35–45.
- Taubenböck, H., Kraff, N. und Wurm, M. (2018). „The morphology of the Arrival City—A global categorization based on literature surveys and remotely sensed data“. In: *Applied Geography* 92, S. 150–167. DOI: [10.1016/j.apgeog.2018.02.002](https://doi.org/10.1016/j.apgeog.2018.02.002).
- Taubenböck, H., Weigand, M., Esch, T., Staab, J., Wurm, M., Mast, J. und Dech, S. (2019). „A new ranking of the world’s largest cities—Do administrative units obscure morphological realities?“ In: *Remote Sensing of Environment* 232, S. 111353. DOI: [10.1016/j.rse.2019.111353](https://doi.org/10.1016/j.rse.2019.111353).
- Taubenböck, H., Mast, J., Geiß, C., Wurm, M., Esch, T. und Seto, K. (2024). „Global differences in urbanization dynamics from 1985 to 2015 and outlook considering IPCC climate scenarios“. In: *Cities* 151, S. 105117. DOI: [10.1016/j.cities.2024.105117](https://doi.org/10.1016/j.cities.2024.105117).
- Teffo, M., Earl, A. und Zuidgeest, M. (2019). „Understanding public transport needs in Cape Town’s informal settlements: a Best-Worst-Scaling approach“. In: *Journal of the South African Institution of Civil Engineering* 61.2, S. 39–50. DOI: [10.17159/2309-8775/2019/v61n2a4](https://doi.org/10.17159/2309-8775/2019/v61n2a4).
- Thakur, G., Hui, P. und Helmy, A. (2012). „A framework for realistic vehicular network modeling using planet-scale public webcams“. In: S. 3–8. DOI: [10.1145/2307836.2307840](https://doi.org/10.1145/2307836.2307840).
- Thomson, J. M. (1977). *Great Cities and Their Traffic*. Littlehampton Book Services Ltd.
- Tian, Y., Zhou, Q. und Fu, X. (2019). „An analysis of the evolution, completeness and spatial patterns of OpenStreetMap building data in China“. In: *ISPRS International Journal of Geo-Information* 8.1, S. 35. DOI: [10.3390/ijgi8010035](https://doi.org/10.3390/ijgi8010035).
- Tiwari, G. und Phillip, C. (2021). „Development of public transport systems in small cities: A roadmap for achieving sustainable development goal indicator 11.2“. In: *IATSS Research* 45.1, S. 31–38. DOI: [10.1016/j.iatssr.2021.02.002](https://doi.org/10.1016/j.iatssr.2021.02.002).

- Tiznado-Aitken, I., Muñoz, J. C. und Hurtubia, R. (2018). „The Role of Accessibility to Public Transport and Quality of Walking Environment on Urban Equity: The Case of Santiago de Chile“. In: *Transportation Research Record: Journal of the Transportation Research Board* 2672.35, S. 129–138. DOI: [10.1177/0361198118782036](https://doi.org/10.1177/0361198118782036).
- Toth, C. und Grejner-Brzezinska, D. (2005). „Traffic flow estimation from airborne imaging sensors: A performance analysis“. In: *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36, S. 7.
- Tracy, A. J., Su, P., Sadek, A. W. und Wang, Q. (2011). „Assessing the impact of the built environment on travel behavior: A case study of Buffalo, New York“. In: *Transportation* 38.4, S. 663–678. DOI: [10.1007/s11116-011-9337-x](https://doi.org/10.1007/s11116-011-9337-x).
- Tucho, G. T. (2022). „A review on the socio-economic impacts of informal transportation and its complementarity to address equity and achieve sustainable development goals“. In: *Journal of Engineering and Applied Science* 69.1. DOI: [10.1186/s44147-022-00074-8](https://doi.org/10.1186/s44147-022-00074-8).
- Tung, C., Kelleher, M. R., Schlueter, R. J., Xu, B., Lu, Y., Thiruvathukal, G. K., Chen, Y. und Lu, Y. (2019). „Large-Scale Object Detection of Images from Network Cameras in Variable Ambient Lighting Conditions“. In: *2019 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, S. 393–398. DOI: [10.1109/MIPR.2019.00080](https://doi.org/10.1109/MIPR.2019.00080).
- Tun, T. H., Welle, B., Hidalgo, D., Albuquerque, C., Castellanos, S., Sclar, R. und Escalante, D. (2020). *Informal and Semiformal Services in Latin America: An Overview of Public Transportation Reforms*. Inter-American Development Bank. DOI: [10.18235/0002831](https://doi.org/10.18235/0002831).
- Turner, S. und Nguyen, B. N. (2024). „Contesting mobility injustices and infrastructural violence: the frictions arising from a modern transportation project in Hanoi, Vietnam“. In: *Handbook of Infrastructures and Cities*. Edward Elgar Publishing, S. 271–283.
- Ultralytics (2025). YOLOv8. Verfügbar unter: <https://github.com/ultralytics/ultralytics>. Zuletzt abgerufen am 27.06.2023.
- Umweltbundesamt (2023). *Fahrleistungen, Verkehrsleistung und Modal Split in Deutschland*. Verfügbar unter: <https://www.umweltbundesamt.de/daten/verkehr/fahrleistungen-verkehrsaufwand-modal-split#fahrleistung-im-personen-und-guterverkehr>. Zuletzt abgerufen am 27.06.2023.
- UN-Habitat (2015). *Habitat III Issue Papers. 22 - Informal Settlements*. Verfügbar unter: https://habitat3.org/wp-content/uploads/Habitat-III-Issue-Paper-22_Informal-Settlements-2.0.pdf. Zuletzt abgerufen am 12.12.2024. New York, NY, USA.
- UN-Habitat (2021a). *11.2.1 Percentage Access to Public Transport*. Verfügbar unter: <https://data.unhabitat.org/datasets/11-2-1-percentage-access-to-public-transport/explore?showTable=true>. Zuletzt abgerufen am 17.02.2025.
- UN-Habitat (2021b). *SDG indicator metadata*. Verfügbar unter: <https://unstats.un.org/sdgs/metadata/files/Metadata-11-02-01.pdf>. Zuletzt abgerufen am 03.11.2024.

- United Nations (2015). *Transforming our World: The 2030 Agenda for Sustainable Development*. Verfügbar unter: <https://sustainabledevelopment.un.org/content/documents/21252030AgendaforSustainableDevelopmentweb.pdf>. Zuletzt abgerufen am 13.12.2024.
- United Nations (2019). *World Urbanization Prospects: The 2018 Revision*. Verfügbar unter: <https://population.un.org/wup/Publications/Files/WUP2018-KeyFacts.pdf>. Zuletzt abgerufen am 14.04.2025.
- Ural, S., Shan, J., Romero, M. A. und Tarko, A. (2015). „Road and Roadside Feature Extraction Using Imagery and Lidar Data for Transportation Operation“. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* II-3/W4, S. 239–246. DOI: [10.5194/isprsannals-II-3-W4-239-2015](https://doi.org/10.5194/isprsannals-II-3-W4-239-2015).
- Vaccari, A., Batabyal, T., Tabassum, N., Hoppe, E. J., Bruckno, B. S. und Acton, S. T. (2018). „Integrating Remote Sensing Data in Decision Support Systems for Transportation Asset Management“. In: *Transportation Research Record: Journal of the Transportation Research Board* 2672.45, S. 23–35. DOI: [10.1177/0361198118786645](https://doi.org/10.1177/0361198118786645).
- Van Acker, V. und Witlox, F. (2010). „Commuting trips within tours: How is commuting related to land use?“ In: *Transportation* 38.3, S. 465–486. DOI: [10.1007/s11116-010-9309-6](https://doi.org/10.1007/s11116-010-9309-6).
- Verkehrsinformationszentrale Berlin (2022). *Entwicklung der täglichen Verkehrsstärke während der Corona-Pandemie*. Verfügbar unter: <https://viz.berlin.de/2022/05/verkehrsstaeke/>. Zuletzt abgerufen am 27.06.2023.
- Verkehrsinformationszentrale Berlin (2023a). *Baustellen, Sperrungen und sonstige Störungen*. Verfügbar unter: <https://viz.berlin.de/verkehr-in-berlin/baustellen-und-sperrungen/>. Zuletzt abgerufen am 27.06.2023.
- Verkehrsinformationszentrale Berlin (2023b). *Verkehr in Berlin: Fachdaten, Verkehrslage und -detektion*. Verfügbar unter: <https://viz.berlin.de/verkehr-in-berlin/>. Zuletzt abgerufen am 27.06.2023.
- Vivir en El Poblado (2022). *¿Cómo quedaron las tarifas del transporte público colectivo de Medellín para este 2022?* Verfügbar unter: <https://vivirenelpoblado.com/tarifas-de-buses-y-colectivos-en-medellin-para-2022/>. Zuletzt abgerufen am 09.12.2024.
- Walker, J., Li, J., Srinivasan, S. und Bolduc, D. (2010). „Travel demand models in the developing world: Correcting for measurement errors“. In: *Transportation Letters* 2.4, S. 231–243. DOI: [10.3328/tl.2010.02.04.231-243](https://doi.org/10.3328/tl.2010.02.04.231-243).
- Wang, Q. und Taylor, J. E. (2016). „Process Map for Urban-Human Mobility and Civil Infrastructure Data Collection Using Geosocial Networking Platforms“. In: *Journal of Computing in Civil Engineering* 30.2, S. 04015004. DOI: [10.1061/\(asce\)cp.1943-5487.0000469](https://doi.org/10.1061/(asce)cp.1943-5487.0000469).
- Wang, L., Lu, Y., Wang, H., Zheng, Y., Ye, H. und Xue, X. (2017). „Evolving boxes for fast vehicle detection“. In: *2017 IEEE International Conference on Multimedia and Expo (ICME)*. IEEE. DOI: [10.1109/icme.2017.8019461](https://doi.org/10.1109/icme.2017.8019461).

- Wang, Y., Geng, K., May, A. D. und Zhou, H. (2022). „The impact of traffic demand management policy mix on commuter travel choices“. In: *Transport Policy* 117, S. 74–87. DOI: [10.1016/j.tranpol.2022.01.002](https://doi.org/10.1016/j.tranpol.2022.01.002).
- Wang, H., Yang, D., Xie, Z., Wang, J., Hao, Z., Zhou, F. und Wang, X. (2024a). „Assessment of asphalt pavement aging condition based on GF-2 high-resolution remote sensing image“. In: *Journal of Applied Remote Sensing* 18.01. DOI: [10.1117/1.jrs.18.014528](https://doi.org/10.1117/1.jrs.18.014528).
- Wang, L., Zhang, M., Gao, X. und Shi, W. (2024b). „Advances and Challenges in Deep Learning-Based Change Detection for Remote Sensing Images: A Review through Various Learning Paradigms“. In: *Remote Sensing* 16.5, S. 804. DOI: [10.3390/rs16050804](https://doi.org/10.3390/rs16050804).
- Wee, G. und Geurs, K. (2011). „Discussing Equity and Social Exclusion in Accessibility Evaluations“. In: *European Journal of Transport and Infrastructure Research* 11. DOI: [10.18757/ejtir.2011.11.4.2940](https://doi.org/10.18757/ejtir.2011.11.4.2940).
- Welch, D., Shepherd, D., McBride, D., Dirks, K. und Marsh, S. (2013). „Road traffic noise and health-related quality of life: A cross-sectional study“. In: *Noise and Health* 15.65, S. 224. DOI: [10.4103/1463-1741.113513](https://doi.org/10.4103/1463-1741.113513).
- Williams, S., White, A., Waiganjo, P., Orwa, D. und Klopp, J. (2015). „The digital matatu project: Using cell phones to create an open source data for Nairobi’s semi-formal bus system“. In: *Journal of Transport Geography* 49, S. 39–51. DOI: [10.1016/j.jtrangeo.2015.10.005](https://doi.org/10.1016/j.jtrangeo.2015.10.005).
- Witte, J.-H. und Gómez, J. M. (2022). „Introducing a New Workflow for Pig Posture Classification Based on a Combination of YOLO and EfficientNet“. In: *Proceedings of the 55th Hawaii International Conference on System Sciences*, S. 1135–1144.
- Woolf, S. und Joubert, J. (2013). „A people-centred view on paratransit in South Africa“. In: *Cities* 35, S. 284–293. DOI: [10.1016/j.cities.2013.04.005](https://doi.org/10.1016/j.cities.2013.04.005).
- Wu, S., Qiu, X. und Wang, L. (2005). „Population estimation methods in GIS and remote sensing: A review“. In: *GIScience & Remote Sensing* 42.1, S. 80–96. DOI: [10.2747/1548-1603.42.1.80](https://doi.org/10.2747/1548-1603.42.1.80).
- Wu, S., Wang, L. und Qiu, X. (2008). „Incorporating GIS building data and census housing statistics for sub-block-level population estimation“. In: *The Professional Geographer* 60.1, S. 121–135. DOI: [10.1080/00330120701724251](https://doi.org/10.1080/00330120701724251).
- Wu, D., Lv, S., Jiang, M. und Song, H. (2020). „Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments“. In: *Computers and Electronics in Agriculture* 178, S. 105742. DOI: [10.1016/j.compag.2020.105742](https://doi.org/10.1016/j.compag.2020.105742).
- Wurm, M., Taubenböck, H., Krings, S., Birkmann, J., Roth, A. und Dech, S. (2009). „Derivation of population distribution for vulnerability assessment in flood-prone German cities using multisensoral remote sensing data“. In: *Remote Sensing for Environmental Monitoring, GIS Applications, and Geology IX*. Hrsg. von U. Michel und D. L. Civco. SPIE. DOI: [10.1117/12.830318](https://doi.org/10.1117/12.830318).

- Wurm, M., Taubenböck, H., Schardt, M., Esch, T. und Dech, S. (2011). „Object-based image information fusion using multisensor earth observation data over urban areas“. In: *International Journal of Image and Data Fusion* 2.2, S. 121–147. DOI: [10.1080/19479832.2010.543934](https://doi.org/10.1080/19479832.2010.543934).
- Wurm, M., d'Angelo, P., Reinartz, P. und Taubenböck, H. (2014). „Investigating the applicability of cartosat-1 DEMs and topographic maps to localize large-area urban mass concentrations“. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7.10, S. 4138–4152. DOI: [10.1109/jstars.2014.2346655](https://doi.org/10.1109/jstars.2014.2346655).
- Wurm, M., Goebel, J., Wagner, G. G., Weigand, M., Dech, S. und Taubenböck, H. (2019a). „Inferring floor area ratio thresholds for the delineation of city centers based on cognitive perception“. In: *Environment and Planning B: Urban Analytics and City Science*, S. 239980831986934. DOI: [10.1177/2399808319869341](https://doi.org/10.1177/2399808319869341).
- Wurm, M., Stark, T., Zhu, X. X., Weigand, M. und Taubenböck, H. (2019b). „Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks“. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 150, S. 59–69. DOI: [10.1016/j.isprsjprs.2019.02.006](https://doi.org/10.1016/j.isprsjprs.2019.02.006).
- Wurm, M., Droin, A., Stark, T., Geiß, C., Sulzer, W. und Taubenböck, H. (2021). „Deep Learning-Based Generation of Building Stock Data from Remote Sensing for Urban Heat Demand Modeling“. In: *ISPRS International Journal of Geo-Information* 10.1, S. 23. DOI: [10.3390/ijgi10010023](https://doi.org/10.3390/ijgi10010023).
- Wurm, M., Tubbesing, R., Stark, T., Kühnl, M., Sapena, M., Sulzer, W. und Taubenböck, H. (2023). „Revealing landslide exposure of informal settlements in Medellín using Deep Learning“. In: *2023 Joint Urban Remote Sensing Event (JURSE)*. IEEE. DOI: [10.1109/jurse57346.2023.10144128](https://doi.org/10.1109/jurse57346.2023.10144128).
- Xin, R., Ai, T., Ding, L., Zhu, R. und Meng, L. (2022). „Impact of the COVID-19 pandemic on urban human mobility - A multiscale geospatial network analysis using New York bike-sharing data“. In: *Cities* 126, S. 103677. DOI: [10.1016/j.cities.2022.103677](https://doi.org/10.1016/j.cities.2022.103677).
- Xu, Y., Wu, L., Xie, Z. und Chen, Z. (2018). „Building Extraction in Very High Resolution Remote Sensing Imagery Using Deep Learning and Guided Filters“. In: *Remote Sensing* 10.1. DOI: [10.3390/rs10010144](https://doi.org/10.3390/rs10010144).
- Xu, X., Zheng, Z., Hu, Z., Feng, K. und Ma, W. (2024a). „A unified dataset for the city-scale traffic assignment model in 20 U.S. cities“. In: *Scientific Data* 11.1. DOI: [10.1038/s41597-024-03149-8](https://doi.org/10.1038/s41597-024-03149-8).
- Xu, Y., Weng, D., Wang, S., Ge, Q., Hu, X., Wang, Z. und Zhang, L. (2024b). „Trends in Emissions from Road Traffic in Rapidly Urbanizing Areas“. In: *Sustainability* 16.17, S. 7400. DOI: [10.3390/su16177400](https://doi.org/10.3390/su16177400).
- Young, N. E., Anderson, R. S., Chignell, S. M., Vorster, A. G., Lawrence, R. und Evangelista, P. H. (2017). „A survival guide to Landsat preprocessing“. In: *Ecology* 98.4, S. 920–932. DOI: [10.1002/ecy.1730](https://doi.org/10.1002/ecy.1730).

- Yuan, J., Chowdhury, P. K. R., McKee, J., Yang, H. L., Weaver, J. und Bhaduri, B. (2018). „Exploiting deep learning and volunteered geographic information for mapping buildings in Kano, Nigeria“. In: *Scientific Data* 5.1. DOI: [10.1038/sdata.2018.217](https://doi.org/10.1038/sdata.2018.217).
- Zegras, C. und Gakenheimer, R. (2006). „Driving forces in developing cities' transportation systems: Insights from selected cases“. In: *Massachusetts Institute of Technology: Cambridge* 46.
- Zegras, C. (2010). „The built environment and motor vehicle ownership and use: Evidence from Santiago de Chile“. In: *Urban Studies* 47.8, S. 1793–1817. DOI: [10.1177/0042098009356125](https://doi.org/10.1177/0042098009356125).
- Zhang, Y. und Guindon, B. (2006). „Using satellite remote sensing to survey transport-related urban sustainability. Part 1: Methodologies for indicator quantification“. In: *International Journal of Applied Earth Observation and Geoinformation* 8.3, S. 149–164. DOI: [10.1016/j.jag.2005.08.005](https://doi.org/10.1016/j.jag.2005.08.005).
- Zhang, Y., Guindon, B. und Sun, K. (2010). „Measuring Canadian urban expansion and impacts on work-related travel distance: 1966–2001“. In: *Journal of Land Use Science* 5.3, S. 217–235. DOI: [10.1080/1747423x.2010.500684](https://doi.org/10.1080/1747423x.2010.500684).
- Zhang, H., Zhao, F. und Sutherland, J. W. (2013). „Manufacturing Scheduling for Reduced Energy cost in a Smart Grid scenario“. In: *Re-engineering Manufacturing for Sustainability*. Hrsg. von A. Y. Nee, B. Song und S.-K. Ong. Springer Science & Business Media. Kap. Methods and Tools for Resource Efficient Manufacturing, S. 183–190.
- Zhang, S., Wu, G., Costeira, J. P. und Moura, J. M. F. (2017a). „FCN-rLSTM: Deep Spatio-Temporal Neural Networks for Vehicle Counting in City Cameras“. In: *2017 IEEE International Conference on Computer Vision (ICCV)*. IEEE. DOI: [10.1109/iccv.2017.396](https://doi.org/10.1109/iccv.2017.396).
- Zhang, S., Wu, G., Costeira, J. P. und Moura, J. M. F. (2017b). „Understanding Traffic Density from Large-Scale Web Camera Data“. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. DOI: [10.1109/cvpr.2017.454](https://doi.org/10.1109/cvpr.2017.454).
- Zhao, K., Kang, J., Jung, J. und Sohn, G. (2018). „Building Extraction From Satellite Images Using Mask R-CNN With Building Boundary Regularization“. In: *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, S. 247–251.
- Zhang, S., Liu, X., Tang, J., Cheng, S. und Wang, Y. (2019). „Urban spatial structure and travel patterns: Analysis of workday and holiday travel using inhomogeneous Poisson point process models“. In: *Computers, Environment and Urban Systems* 73, S. 68–84. DOI: [10.1016/j.compenvurbsys.2018.08.005](https://doi.org/10.1016/j.compenvurbsys.2018.08.005).
- Zhang, Y., Guo, Z., Wu, J., Tian, Y., Tang, H. und Guo, X. (2022). „Real-Time Vehicle Detection Based on Improved YOLO v5“. In: *Sustainability* 14.19, S. 12274. DOI: [10.3390/su141912274](https://doi.org/10.3390/su141912274).
- Zhang, L., Yu, X., Daud, A., Mussah, A. R. und Adu-Gyamfi, Y. (2024). *Application of 2D Homography for High Resolution Traffic Data Collection using CCTV Cameras*. DOI: [10.48550/ARXIV.2401.07220](https://doi.org/10.48550/ARXIV.2401.07220).

- Zhou, Q., Zhang, Y., Chang, K. und Brovelli, M. A. (2022). „Assessing OSM building completeness for almost 13,000 cities globally“. In: *International Journal of Digital Earth* 15.1, S. 2400–2421. DOI: [10.1080/17538947.2022.2159550](https://doi.org/10.1080/17538947.2022.2159550).
- Zhu, X. X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F. und Fraundorfer, F. (2017). „Deep learning in remote sensing: A comprehensive review and list of resources“. In: *IEEE Geoscience and Remote Sensing Magazine* 5.4, S. 8–36. DOI: [10.1109/mgrs.2017.2762307](https://doi.org/10.1109/mgrs.2017.2762307).
- Zhu, J., Li, X., Jin, P., Xu, Q., Sun, Z. und Song, X. (2021). „MME-YOLO: Multi-Sensor Multi-Level Enhanced YOLO for Robust Vehicle Detection in Traffic Surveillance“. In: *Sensors* 21.1. DOI: [10.3390/s21010027](https://doi.org/10.3390/s21010027).