

Technische Universität München

TUM School of Engineering and Design

**Prädiktive Flottenstrategie für Ridesourcing-Dienste
am Beispiel des Münchner Taxiverkehrs**

Michael Wittmann, M. Sc.

Vollständiger Abdruck der von der TUM School of Engineering and Design der
Technischen Universität München zur Erlangung des akademischen Grades eines

Doktors der Ingenieurwissenschaften

genehmigten Dissertation.

Vorsitzender: Prof. Dr.-Ing. Gebhard Wulfhorst

Prüfer der Dissertation: 1. Prof. Dr.-Ing. Markus Lienkamp
2. Prof. Dr.-Ing. Rolf Moeckel

Die Dissertation wurde am 18.01.2022 bei der Technischen Universität München eingereicht und durch die
TUM School of Engineering and Design am 20.07.2022 angenommen.

Danksagung

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Fahrzeugtechnik der Technischen Universität München in den Jahren 2015 bis 2021.

An erster Stelle danke ich meinem Doktorvater, Markus Lienkamp, für die Betreuung meiner Arbeit und den strukturellen Input, der zum Gelingen dieser Arbeit beigetragen hat. Die Freiheit, Dinge ausprobieren zu können, dein Vertrauen mit dem du mir nach eineinhalb Jahren eine Forschungsgruppe anvertraut hast und die Möglichkeit, die Strategie und Vision eines BMBF Zukunftsclusters mitentwickeln zu können, haben mich nicht nur wissenschaftlich, sondern vor allem persönlich über die Maße reifen lassen.

Ebenfalls möchte ich meinem Zweitprüfer, Rolf Moeckel, für die unkomplizierte Übernahme des Koreferats, sowie Gebhard Wulfhorst für die Übernahme des Prüfungsvorsitzes danken.

Besonders bedanken möchte ich mich bei der IsarFunk Taxizentrale GmbH & Co. KG, namentlich bei Christian Hess und Gregor Beiner, für die großzügige Bereitstellung der Datenbasis dieser Arbeit und den wertvollen Austausch in den letzten sechs Jahren.

In meiner Zeit am Lehrstuhl hatte ich das Glück, von vielen großartigen Menschen umgeben sein zu dürfen. Vielen Dank an Alexa Lohrer, Benedikt Jäger, Thorsten Helfrich, Simon Schmeiler, Andreas Schulze, Adam Waclaw, Lukas Merkle, Julian Kreibich, Florian Schmid, Jana Fank, Alex Heilmeyer, Tanja Gewalt, Niko Wassiliadis und Konstantin Riedl, dass ihr den Lehrstuhl für mich zu einer Familie gemacht habt.

Ebenso Danke an alle MCubees Carolin Zimmer, Julia Kinigadner, Sophia Knopf, Alex Wentland, Daniel Schröder, Sebastian Pfothner, Gebhard Wulfhorst und Markus Lienkamp für die einzigartige Zusammenarbeit während der Konzeptionsphase des BMBF Zukunftsclusters MCube.

Ein weiterer Dank gilt der Forschungsgruppe Smarte Mobilität für die vielen konstruktiven Diskussionen und eure Unterstützung während der gesamten Zeit meiner Arbeit. Danke an meine Co-Autorin Layla Martin für deine Geduld und den fachlichen Austausch. Ein besonderer Dank geht an meine Korrektoren Lorenz Horlbeck und Jürgen Lohrer für ihre vielen konstruktiven Verbesserungsvorschläge und Anmerkungen.

Diese Arbeit wäre nicht ohne die Unterstützung der von mir betreuten StudentInnen möglich gewesen. Besonders hervorheben möchte ich an dieser Stelle die Beiträge von Maximilian Speicher, Michael Kollek und Lorenz Neuner. Eure gewissenhafte Arbeit und euer außerordentlicher Einsatz haben wesentlich zum Erfolg dieser Arbeit beigetragen.

Ein außerordentlicher Dank gilt meinen Freunden Johannes Betz, Lorenz Horlbeck und Jürgen Lohrer. Danke, dass ihr mich auch in schwierigen Zeiten immer wieder motiviert und ermutigt habt, diese Arbeit zu Ende zu bringen.

Ich widme diese Arbeit meiner Familie. Danke, dass ihr mich auf dem bisherigen Weg begleitet und in jeder denkbaren Situation unterstützt habt. Mein größter Dank gilt meiner Frau Jenny und meinen beiden Kindern Johannes und Leonie. Danke für euer Verständnis, eure Unterstützung an jedem Tag und dafür, dass ihr auf zwei Monate gemeinsame freie Zeit im Sommer mit mir verzichtet habt, damit ich diese Arbeit fertig schreiben konnte. Diese Arbeit ist für euch.

Graing, im Dezember 2021

Michael Wittmann

Inhaltsverzeichnis

Abkürzungsverzeichnis	V
Formelzeichen	VII
1 Einleitung	1
1.1 Motivation	1
1.2 Zielsetzung	2
2 Stand der Forschung und Technik	3
2.1 Taxi/Ridesourcing - Einordnung und Begriffsdefinition	3
2.1.1 Terminologie	3
2.1.2 Akteure	6
2.1.3 Hintergründe und aktuelle Entwicklungen	7
2.2 Methoden zur Optimierung von Ridesourcing Diensten	10
2.2.1 Vermittlungsstrategien	10
2.2.2 Prädiktion von Angebot und Nachfrage	13
2.2.3 Rebalancingstrategien	18
2.2.4 Flottengröße	21
2.3 Ableitung der Themenstellung	22
2.3.1 Forschungslücken im Stand der Technik.....	22
2.3.2 Forschungsfrage.....	24
2.3.3 Vorgehen und Lösungsansatz	25
2.4 Aufbau der Arbeit	27
3 Datenquellen und Datenaufbereitung	29
3.1 Taxi Bewegungsdaten	29
3.2 ÖPNV Verspätungen	31
3.3 Öffentliche Veranstaltungen	31
3.4 Wetter	32
4 Potentialanalyse am Beispiel des Münchner Taxiverkehrs	33
4.1 Angebot- und Nachfrageaufkommen	33
4.1.1 Zeitliche Analyse	33

4.1.2	Räumliche Analyse	36
4.1.3	Räumlich-zeitliche Analyse	38
4.1.4	Externe Einflussfaktoren auf das Nachfrageverhalten	40
4.2	Systemindikatoren	42
4.2.1	Fahrtbezogene Kennwerte	42
4.2.2	Flottenauslastung	43
4.2.3	Servicequalität	43
4.3	Monetäre Kennwerte	44
4.3.1	Fixkosten pro Fahrzeug	45
4.3.2	Variable Streckenkosten	45
4.3.3	Variable Lohnkosten	45
4.3.4	Umsatz	46
4.3.5	Gewinn/Verlust, Marge	46
4.3.6	Ausblick bis 2022	46
4.4	COVID-19	47
4.5	Optimierungspotentiale	49
4.5.1	Wirtschaftliche Potentiale	49
4.5.2	Technische Potentiale	50
5	Simulationsmodell zur Bewertung prädiktiver Flottenstrategien	53
5.1	Architektur des Simulationsmodells	53
5.2	Strategien zur Fahrgastvermittlung	55
5.2.1	Sektorvermittlung – Referenzstrategie	56
5.2.2	Globales Bipartites Matching (GBPM)	57
5.2.3	Nearest Taxi Nearest Request (NTNR)	58
5.3	Rebalancing Strategien	59
5.3.1	Dezentrales, individuelles Rebalancing – Referenzstrategie	60
5.3.2	Prädiktive, gewinnmaximierende Rebalancing Strategie (PRLP)	62
5.4	Modell zur räumlich-zeitlichen Prädiktion der Kundennachfrage	66
5.4.1	Allgemeine Anforderungen an das Prädiktionsmodell	67
5.4.2	Architektur Prädiktionsframework	67
5.4.3	Modellierung von Zeitreihen als Supervised Learning Problem	67
5.4.4	Vorgehen zur Modellauswahl	69
5.4.5	Teilmodelle	69
5.4.6	Zusammenfassung	75

5.5	Anpassung der Flottengröße	75
6	Simulationsszenarien und Ergebnisse	77
6.1	Allgemeine Randbedingungen	77
6.2	Referenzszenario/Validierung	81
6.2.1	Parameter	81
6.2.2	Flottenbezogene Kennwerte	81
6.2.3	Fahrtbezogene Kennwerte	84
6.2.4	Kundenbezogene Kennwerte	85
6.2.5	Fazit	86
6.3	Änderung der Vermittlungsstrategie	87
6.3.1	Szenarien	87
6.3.2	Ergebnisse	87
6.3.3	Fazit	89
6.4	Änderung der Rebalancingstrategie	90
6.4.1	Szenarien	90
6.4.2	Ergebnisse	90
6.4.3	Fazit	93
6.5	Optimierte Flottengröße	94
6.5.1	Ergebnisse	94
6.5.2	Fazit	96
7	Diskussion	97
7.1	Allgemeine Bewertung	97
7.1.1	Datengrundlage	97
7.1.2	Nachfrageprädiktion	98
7.1.3	Simulationsmodell	98
7.1.4	Kostenmodell/Erlösmodell	99
7.2	Forschungsfragen	99
7.3	Handlungsempfehlungen, Möglichkeiten zur technischen Umsetzung und Weiterentwicklung	102
7.4	Relevanz	103
7.4.1	Wissenschaftlich	103
7.4.2	Gesellschaftlich	103
7.4.3	Gewerblich	104
8	Zusammenfassung und Ausblick	105
	Abbildungsverzeichnis	i

Tabellenverzeichnis	v
Vorveröffentlichungsliste	xxiii
Betreute Studienarbeiten	xxv

Abkürzungsverzeichnis

AMoDeus	engl. autonomous mobility-on-demand simulator
ARIMA	engl. autoregressive integrated moving average
ARMA	engl. autoregressive moving average
CNN	engl. convolutional neuronal network
ConvLSTM	engl. convolutional long short-term memory
DARP	engl. dial a ride problem
DiDi	Didi Chuxing Technology Co. (Fahrdienstleister)
DFR	engl. distributed feedback rebalancing
DQN	engl. deep Q-network
DVRP	engl. dynamic vehicle routing problem
FCFS	engl. first come first served
FFNN	engl. feedforward neuronal network
FFR	engl. feedforward fluidic optimal rebalancing policy
FFTVR	engl. feedforward time-varying rebalancing policy
FIFO	engl. first in first out
GBPM	engl. global bipartite matching
GBRT	engl. gradient boosted regression tree
GP	Gauß Prozess
GRU	engl. gated recurrent unit
HA	engl. historical average
HW	Holt-Winters Modell
ILP	engl. integer linear problem
ITS	engl. intelligent transportation systems
KDD	engl. knowledge discovery in databases
LP	engl. linear problem
LR	lineare Regression
LSTM	engl. long short-term memory
LZW	Lempel-Zov-Welch Modell
MaaS	engl. Mobility as a Service
MAE	engl. mean absolute error
MATSim	engl. Multi-Agent Transport Simulation
MC	engl. Markov Chain
MDN	engl. Mixture Density Network
MFAR	engl. model free adaptive rebalancing
MILP	engl. mixed integer linear problem
MLP	engl. multi layer perceptron
MoD	engl. mobility on demand
MPC	engl. model predictive control
MSE	engl. mean square error

NIT	engl. nearest idle taxi
NTNR	engl. nearest taxi nearest request
OD	engl. origin-destination
OECD	engl. organisation for economic cooperation and development
ÖPNV	öffentlicher Personennahverkehr
OSM	OpenStreetMap
PBefG	Personenbeförderungsgesetz
POI	engl. point of interest
PRLP	engl. predictive rebalancing linear optimization policy
RHC	engl. receding horizon control
RL	engl. reinforcement learning
RMSE	engl. root mean square error
RNN	engl. recurrent neural network
SARIMA	engl. seasonal autoregressive integrated moving average
STL	engl. seasonal and trend decomposition using Loess
TBATS	engl. trigonometric seasonality, Box-Cox transformation, ARMA errors, trend and seasonal components
TNC	engl. transportation network company
VAT	Wert der Zeit (engl. value of time)
VRP	engl. vehicle routing problem

Formelzeichen

Formelzeichen	Einheit	Beschreibung
$\beta_{v,zenrtum}$	-	Verhältnis Anzahl freier Fahrzeuge innerhalb des Zentrums über Anzahl aller freien Fahrzeuge
$\hat{\beta}_{v,zenrtum}$	-	Sollwert $\beta_{v,zenrtum}$
B	-	Menge aller Randgebiete (Rebalancing)
b_i	-	Gebiet i der Menge B
$\gamma(t)$	-	Gewichtungsfaktor der Rebalancing Zielfunktion
c	-	Konfidenzintervall
c_{reb}	€	Durch Rebalancing verursachte Kosten
c_{ij}	€	Kosten pro Fahrt von g_i nach g_j
c_{fix}	€	Fixkosten pro Fahrzeug
c_{lohn}	€/h	Lohnkosten
c_{km}	€/km	Variable Streckenkosten
d_i^t	-	Anzahl an Anfragen innerhalb g_i zum Zeitpunkt t
δ_b^{SD}	-	Lokale Differenz von Angebot und prädizierter Nachfrage für alle Gebiete der Menge B
e_{basis}	€/Fahrt	Grundfahrpreis
e_{var}	€/km	Variabler Fahrpreis
G	-	Menge aller Rasterzellen (Rebalancing)
g_i	-	Gebiet i der Menge G
i	-	Allgemeiner Index
j	-	Allgemeiner Index
k	-	Anzahl Cluster
λ	€/Fahrt	Wichtungparameter – Wert der Zeit
m	-	Periodendauer der saisonalen Komponente eines SARIMA Modells
M	-	Matching – Untermenge eines Graphen bei dem keine zwei Kanten einen Knoten gemeinsam haben
n	-	Allgemeiner Index

p_{loss}	€	Durch Nichterfüllung entstehender Erlösausfall
$\mathbb{P}_t(i j)$	-	Wahrscheinlichkeitsfunktion möglicher Start-Ziel-Paare
R	-	Menge an Anfragen
r_i	-	Anfrage i der Menge R
r_{ij}^t	-	Anzahl Rebalancing-Flüsse von g_i nach g_j zum Zeitpunkt t
S	-	Menge der Vermittlungssektoren
s_i	-	Sektor i der Menge S
s_i^t	-	Anzahl an verfügbaren Fahrzeugen innerhalb g_i zum Zeitpunkt t
T	-	Prognosehorizont
Δt	s	Zeitintervall
t_{wait}	s	Wartezeit eines Kunden
$t_{\text{wait,max}}$	s	Maximal tolerierte Wartezeit eines Kunden
$t_{\text{disp,max}}$	s	Maximal tolerierte Vermittlungsdauer eines Kunden
T_{disp}	s	Periodendauer Fahrgastvermittlung
T_{reb}	s	Periodendauer Rebalancing
T_{fs}	s	Periodendauer für die Anpassung der Flottengröße
$t_{\bar{i}j}$	-	erwartete Fahrzeit von g_i nach g_j
t_{pickup}	s	Einstiegsdauer pro Kunde
t_{dropoff}	s	Ausstiegsdauer pro Kunde
V	-	Menge an Fahrzeugen
v_i	-	Fahrzeug i der Menge V
w_i	-	Kantengewicht der Kante i eines Graphen
\bar{x}_{grid}	m	Kantenlänge des Rasters G
\bar{x}_{border}	m	Breite des Randbereichs B
x_i	-	Anzahl frei werdender Fahrzeuge im Zielgebiet g_i
\mathbf{x}	-	Beschreibenden Variablen des Vorhersageproblems
$x(t)_{\text{active}}$	-	Anzahl aktiver Fahrzeuge zum Zeitpunkt t
$\hat{x}(t)_{\text{active}}$	-	Sollwert Anzahl aktiver Fahrzeuge zum Zeitpunkt t
x_{hi}	0 1	Eingangsvektor Vorhersagemodell Stunde des Tages
x_{di}	0 1	Eingangsvektor Vorhersagemodell Wochentag
x_{FA}	0 1	Eingangsvektor Vorhersagemodell Faschingsferien
x_{OS}	0 1	Eingangsvektor Vorhersagemodell Osterferien
x_{PF}	0 1	Eingangsvektor Vorhersagemodell Pfingstferien

x_{SO}	0 1	Eingangsvektor Vorhersagemodell Sommerferien
x_{HE}	0 1	Eingangsvektor Vorhersagemodell Herbstferien
x_{WI}	0 1	Eingangsvektor Vorhersagemodell Winterferien
x_{PH}	0 1	Eingangsvektor Vorhersagemodell Gesetzlicher Feiertag
x_{oktFest}	0 1	Eingangsvektor Vorhersagemodell Oktoberfest
x_{temp}	°C	Eingangsvektor Vorhersagemodell Temperatur
x_{percep}	mm	Eingangsvektor Vorhersagemodell Niederschlag
x_{hum}	%	Eingangsvektor Vorhersagemodell Luftfeuchtigkeit
$x_{g,\text{event}}$	-	Eingangsvektor Vorhersagemodell öffentliche Veranstaltung
$x_{g,\text{OEPNV}}$	0 1	Eingangsvektor Vorhersagemodell Verspätung ÖPNV
\mathbf{y}	-	Zielgrößen des Vorhersageproblems
$y(t)$	-	Beobachtungswert zum Zeitpunkt t
$\hat{y}(t)$	-	Prognosewert zum Zeitpunkt t

1 Einleitung

1.1 Motivation

Mobilität gilt als Schlüsselfaktor für Wohlstand und Lebensqualität. Sie prägt unseren Alltag und Gewohnheiten, sie bestimmt wo wir arbeiten, wo wir wohnen und ist ein entscheidendes Bindeglied zwischen ländlichen Regionen und urbanen Zentren. Die damit verbundene Infrastruktur beeinflusst maßgeblich das Aussehen unserer Lebensräume [1].

Im Jahr 2005, wurden nach einem Bericht der Vereinten Nationen, in Städten weltweit täglich 7,5 Milliarden Wege zurückgelegt. Der Stadtverkehr ist dabei für 40 % der Treibhausgasemissionen des Personenverkehrs verantwortlich [2]. Für das Jahr 2050 wird ein Anstieg der Personenkilometer um das Drei- bis Vierfache im Vergleich zu 2000 erwartet [2, 3]. Die OECD geht zudem von einer Verdopplung des allgemeinen Gütertransportaufkommens 80 % bis 2050 aus [2].

Bereits heute sind jedoch die Verkehrssysteme vielerorts durch das zunehmende Verkehrsaufkommen überlastet. München beispielsweise gilt seit Jahren als Stauhauptstadt Deutschlands. Ein durchschnittlicher Autofahrer verbrachte hier im Jahr 2019 87 Stunden im Stau [4]. Experten sind sich einig, dass dieses Problem nicht allein durch einen weiteren Ausbau der Verkehrsinfrastruktur behoben werden kann [5, 6]. Von vielen Seiten wird daher ein radikaler Mobilitätswandel gefordert [1, 3, 6].

Zukünftige Mobilitätssysteme müssen dabei im Vergleich zu heutigen in der Lage sein, vor allem die vorhandene Infrastruktur effizienter und nachhaltiger zu nutzen. Intelligente, vernetzte und geteilte Mobilitätsdienstleistungen sollen hierbei vor allem in urbanen Räumen wesentlich zur Entlastung beitragen [7]. Es wird erwartet, dass der Markt für engl. Mobility as a Service (MaaS) mit einer Marktkapitalisierung von 9 Billionen USD bis zum Jahr 2030 überproportional wachsen wird und neue Marktteilnehmer hochkompetitiv um Marktanteile ringen werden [8].

Der weltweit höchstbewertete Anbieter für Fahrdienstleistungen Uber verzeichnete z. B. im Jahr 2018 91 Millionen aktive Nutzer, 3,9 Millionen registrierte Fahrer und über 10 Milliarden vermittelte Fahrten weltweit [9]. Uber und andere global agierende, plattformgetriebene Mobilitätsanbieter greifen dabei tief in etablierte Dienstleistungssektoren ein und setzen lokal etablierte Anbieter und deren Geschäftsmodelle unter Druck. Vor allem das klassische Taxigewerbe sieht sich von dem aggressiven Vorgehen neuer Ridesourcing-Anbieter bedroht [10] [11, S. 37–39].

In einem solch kompetitiven und hochdynamischen Marktumfeld entscheiden intelligente, effiziente und nachhaltige Strategien für den Betrieb der Fahrzeugflotte über Erfolg und Niedergang. Gleichzeitig eröffnet eine zunehmende Digitalisierung und Vernetzung der Fahrzeugflotten neue Möglichkeiten der Optimierung [12]. Anhand von Echtzeit-Telemetriedaten lassen sich beispielsweise wertvolle Informationen für die Vorhersage zukünftiger Ereignisse gewinnen und sich der Betrieb der Fahrzeugflotte darauf ausrichten [13–16]. Es wird in diesem Zusammenhang erwartet, dass sich der weltweite Markt für Flottenmanagementlösungen zwischen 2019 und 2023 von 15,9 Milliarden USD auf 31,5 Milliarden USD verdoppelt [17].

1.2 Zielsetzung

Diese Arbeit hat das Ziel, geeignete Maßnahmen zur Optimierung vermittlungsbasierter Fahrdienstleistungen zu identifizieren, diese in einer optimierten, prädiktiven Flottenstrategie zu bündeln und deren Wirksamkeit am Beispiel des Münchner Taxiverkehrs zu evaluieren.

Zu Beginn sollen dabei in einer Potentialanalyse die Stärken und Schwächen gegenwärtiger Abläufe und Prozesse im Münchner Taxigewerbe identifiziert und Optimierungspotentiale offengelegt werden.

Grundlage hierfür bildet die kontinuierliche Erhebung eines Referenzdatensatzes einer Münchner Taxiflotte über einen Zeitraum von fünf Jahren. Dieser Datensatz soll hinsichtlich zeitlicher, räumlicher und externer Einflussfaktoren untersucht und deren Wirkungen auf das Angebot- und Nachfrageaufkommen dargestellt werden. Darüber hinaus sollen relevante Systemindikatoren für den operativen Betrieb identifiziert und analysiert werden. Aus aktuellem Anlass sollen darüber hinaus zudem die Auswirkungen der globalen COVID-19 Pandemie auf das Taxigewerbe untersucht werden.

Aufbauend auf den gewonnenen Erkenntnissen sowie einer ausführlichen Analyse des Stands der Technik soll im weiteren Verlauf eine optimierte, prädiktive Flottenstrategie erarbeitet werden. Dazu müssen folgende Teilprobleme adressiert und deren Teillösungen kombiniert werden:

- Die Vermittlung von Fahrzeugen zu Kunden (Vermittlungsstrategie),
- die Vorhersage der zukünftigen Kundennachfrage bzw. des Angebots an zur Verfügung stehenden Fahrzeugen (Prädiktion),
- das Verhalten und die Repositionierung unbesetzter Fahrzeuge (engl. Rebalancing),
- sowie die Anzahl an benötigten Fahrzeugen, um eine gewünschte Servicequalität zu gewährleisten (engl. Fleetsizing).

Zentrale Frage dieser Untersuchung ist, inwiefern die Vorhersage der zukünftigen Kundennachfrage dazu genutzt werden kann, die Effizienz (z. B. Flottengröße, Flottenkilometer) und Servicequalität (Kundenwartezeit, Verfügbarkeit) in Ridesourcing-Anwendungen zu erhöhen.

Hierzu wird ein Vorhersagemodell entwickelt, das in der Lage ist, die Anzahl an zukünftig zu erwartenden Aufträgen örtlich und zeitlich vorherzusagen. Diese Information soll anschließend genutzt werden, um freie Fahrzeuge proaktiv an Orte hoher zukünftiger Nachfrage umzuverteilen. Es wird erwartet, dass hierdurch Wartezeiten für den Kunden reduziert werden können, und zusätzlich die allgemeine Flottenauslastung verringert werden kann. In der Folge wird vermutet, dass durch optimierte Vermittlungs- und Rebalancingstrategien eine geringere Anzahl an Fahrzeugen benötigt wird, um ein vergleichbares oder sogar erhöhtes Serviceniveau zu erreichen.

Die Bewertung möglicher Optimierungsmaßnahmen soll im Rahmen einer Simulationsstudie erfolgen. Es wird angestrebt, dazu das Nachfrage- und Flottenverhalten über den Zeitraum von einem ganzen Jahr innerhalb eines Simulationsmodells realitätsnah abzubilden. Als Ausgangspunkt dient hierzu die agentenbasierte, makroskopische Verkehrssimulation MATSIM [18] zusammen mit dem darauf aufbauenden Simulationsframework für engl. mobility on demand (MoD)-Fragestellungen, AMoDeus [19]. Das Framework soll dazu im Verlauf dieser Arbeit um ein validiertes Referenzmodell für den Münchner Taxiverkehr, sowie um ein prädiktives Rebalancingmodell erweitert werden.

Als Ergebnis dieser Arbeit soll der Einfluss optimierter Strategien zur Fahrgastvermittlung, Rebalancing und Anpassung der Flottengröße in Bezug auf Kunden- und Betreiberrelevante Kenngrößen ermittelt und im Vergleich zur aktuell praktizierten Flottenstrategie des Anwendungsbeispiels München bewertet werden. Abschließend sollen die gewonnenen Erkenntnisse in konkrete Handlungsempfehlungen für das Taxigewerbe überführt werden.

2 Stand der Forschung und Technik

Das folgende Kapitel liefert eine Übersicht aktueller Forschungsarbeiten zum Thema Optimierung von vermittlungsbasierten Fahrdienstleistungen. Zu Beginn erfolgt eine allgemeine Einordnung der Begriffe Taxi bzw. Ridesourcing im Kontext moderner MoD Systeme. Im weiteren Verlauf werden wesentliche Akteure und Systembestandteile näher erläutert und deren Wechselwirkungen aufgezeigt. Zudem werden Herausforderungen vor dem Hintergrund aktueller Marktentwicklungen aufgeführt.

Anschließend werden Methoden zur Optimierung von Taxi- und Ridesourcing-Diensten aus der Forschungslandschaft zusammengefasst. Ziel ist es, bisherige Arbeiten in den Bereichen Strategien zur Fahrgastvermittlung, Prädiktion des Mobilitätsbedarfs, Strategien zur Verteilung unbesetzter Fahrzeuge (Rebalancing), sowie der Optimierung der Flottengröße zusammenzufassen. Als Ergebnis der Literaturanalyse werden am Kapitelende Themenstellung und Forschungsfragen dieser Dissertation abgeleitet.

2.1 Taxi/Ridesourcing - Einordnung und Begriffsdefinition

Die bedarfsbedingte, gelegentliche Beförderung von Personen hat ihren Ursprung bereits in der Antike. War die Beförderung in Sänften lange Zeit exklusiv der herrschenden Oberschicht vorbehalten [20, S. 630], entwickelten sich im frühen 19. Jahrhundert erste Unternehmen, die eine gewerbliche Beförderung von Personen anboten. Beispielsweise unterhielt der Unternehmer Israel Moses Henschel in Berlin bereits im Jahr 1827 150 Pferdekutschen (Droschken) zur Personenbeförderung [21]. Der Name Taxi geht auf das Ende des 19. Jahrhunderts von Friedrich Wilhelm Gustav Bruhn erfundene Gerät zur Ermittlung des Fahrpreises, das Taxameter, zurück [22]. Im Folgenden hat sich der Begriff "Taxi" auch international als Begriff für die spontane/gelegentliche Beförderung von Personen mit einem gewerblich betriebenen Fahrzeug etabliert. Mit dem Aufkommen neuer, digitaler Mobilitätsangebote, haben sich zur Differenzierung vom klassischen Taxigewerbe neue Begriffe für unterschiedliche Ausprägungsarten der Personenbeförderung entwickelt [23, S. 27, 24]. Auf Grund der unübersichtlichen und zum Teil widersprüchlichen Begriffsdefinition in internationalen Veröffentlichungen [25, S. 14] erfolgt zu Beginn eine allgemeine Einordnung und Begriffsdefinition für Taxi- und ähnliche geartete Angebote zur Personenbeförderung.

2.1.1 Terminologie

Mobility on demand (MoD)

Shaheen et al. [23, S. 18] definieren MoD als: *"... a new concept based on the principle that transportation is a commodity where modes have economic values that are distinguishable in terms of cost, journey time, wait time, number of connections, convenience, and other attributes. ... MOD refers to a network of safe, affordable, and reliable transportation options when, where, and how travelers want it."*

Das US-Verkehrsministerium [26] definiert MoD als: *"MOD is an innovative, user-focused approach which leverages emerging mobility services, integrated transit networks and operations, real-time data, connected*

travelers, and cooperative Intelligent Transportation Systems ITS to allow for a more traveler-centric, transportation system- of-systems approach, providing improved mobility options to all travelers and users of the system in an efficient and safe manner."

MoD beschreibt also ein Mobilitätskonzept, das auf dem Grundsatz der bedarfsorientierten Mobilitätserfüllung basiert. In diesem Konzept wird die Erfüllung einer Transportaufgabe in einem offenen Markt als Dienstleistung angeboten, in dem sich Dienstanbieter und Kunden in einem Angebot/Nachfrage Verhältnis gegenüber stehen. Kunden können dabei aus einem breiten Angebot an Dienstleistungen auswählen, um die zu erfüllenden Transportaufgabe optimal und bedarfsorientiert zu erledigen. Die Auswahl eines entsprechenden MoD Dienstes hängt dabei von mehreren Kriterien – z. B. dem Beförderungsgut (Mensch/Ware), der gewünschten Ankunfts-/Abfahrtszeit, der Verfügbarkeit des Dienstes an Start und Zielort, des benötigten Transportmittels, sowie individueller Präferenzen und Gewohnheiten – ab (Abbildung 2.1). Beispiele für MoD Anbieter sind z. B. Taxi, private Chaffeurdienste, Kurierdienste, Car-/Bikesharing, eScooter aber auch der klassische ÖPNV.

Mobility as a Service (MaaS)

Die MaaS ALLIANCE [27] definiert MaaS als: *"Mobility as a Service (MaaS) is the integration of various forms of transport services into a single mobility service accessible on demand. A MaaS operator facilitates a diverse menu of transport options to meet a customer's request, be they public transport, ride-, car- or bike-sharing, taxi or car rental/lease, or a combination thereof. For the user, MaaS can offer added value by using a single application to provide access to mobility with a single payment channel instead of multiple ticketing and payment operations. (...)"*

Ergänzend hierzu definieren Vij et al. [28] MaaS mit: *"MaaS systems offer consumers access to multiple transport modes and services, owned and operated by different mobility service providers, through an integrated digital platform for planning, booking, and payment."*

Der Begriff MaaS beschreibt also eine übergeordnete Dienstleistung, die unterschiedliche Mobilitätsdienste für den Kunden in einem einzelnen, integrierten Mobilitätsangebot bündelt.

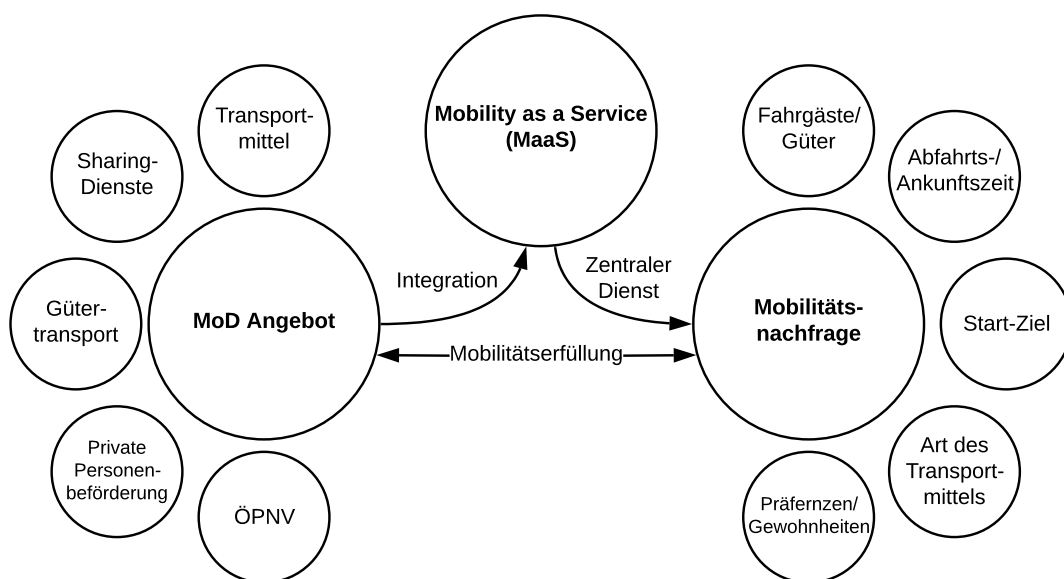


Abbildung 2.1: Zusammenhang zwischen Angebot und Nachfrage in MaaS/MoD Systemen in Anlehnung an [23, S. 3].

Taxi

Unter dem Begriff Taxi versteht man im Allgemeinen ein *"(von einem Berufsfahrer gelenktes) Auto, mit dem man sich (besonders innerhalb einer Stadt) befördern lassen kann."* [29]. Unter Taxi wird im deutschen und internationalen Sprachgebrauch aber auch der Personentransport mit anderen Transportmitteln wie z. B. Flugtaxi, Wassertaxi und Motorradtaxi verstanden.

In Deutschland gilt das Taxi nach §46 Personenbeförderungsgesetz (PBefG) als öffentliches Verkehrsmittel des Gelegenheitsverkehrs. Dieser wird in §47 PBefG weiter reglementiert. Der *"Verkehr mit Taxen ist [demnach] die Beförderung von Personen mit Personenkraftwagen, die der Unternehmer an behördlich zugewiesenen Stellen bereithält und mit denen er Fahrten zu einem vom Fahrgast bestimmten Ziel ausführt. Der Unternehmer kann Beförderungsaufträge auch während einer Fahrt oder am Betriebsitz entgegennehmen"*.

Die weitere regulative Ausgestaltung des Taxibetriebs obliegt der jeweiligen Landes- bzw. Kommunalverwaltung. Dies beinhaltet beispielsweise die Festsetzung des Taxitarifs, die Definition eines Pflichtfahrgebietes, als auch die Vergabe von Konzessionen. Für Taxiunternehmen gilt zudem eine Beförderungspflicht innerhalb des definierten Pflichtfahrbereichs. Des Weiteren wird in §46 PBefG in Orten mit mehr als 50 000 Einwohner eine Mischkonzession für den gleichzeitigen Betrieb eines Fahrzeugs im Taxiverkehr, Mietwagenverkehr und/oder gebündelten Bedarfsverkehr (Ridepooling) explizit ausgeschlossen.

In Deutschland betrug die Anzahl an genehmigten Fahrzeugen im Taxiverkehr im Jahr 2016 53 302 Fahrzeuge [11, S. 12]. In der Landeshauptstadt München waren im Jahr 2018 3336 Taxikonzessionen vergeben [11, S. 65].

Mietwagen

Der Verkehr mit Mietwagen beschreibt nach §49 PBefG *"... die Beförderung von Personen mit Personenkraftwagen, die nur im ganzen zur Beförderung gemietet werden und mit denen der Unternehmer Fahrten ausführt, deren Zweck, Ziel und Ablauf der Mieter bestimmt und die nicht Verkehr mit Taxen nach § 47 und nicht gebündelter Bedarfsverkehr nach § 50 sind"*.

Ferner dürfen von Mietwagenbetreibern *"... nur Beförderungsaufträge ausgeführt werden, die am Betriebsitz oder in der Wohnung des Unternehmers eingegangen sind. Nach Ausführung des Beförderungsauftrags hat der Mietwagen unverzüglich zum Betriebsitz zurückzukehren, es sei denn, er hat vor der Fahrt von seinem Betriebsitz oder der Wohnung oder während der Fahrt einen neuen Beförderungsauftrag erhalten."*

Dabei sind Mietwagenbetriebe im Gegensatz zu Taxis sowohl von der Betriebspflicht (§21 PBefG), als auch von der Beförderungspflicht (§22 PBefG) ausgenommen. Mietwagen sind in ihrer Preisgestaltung frei, §51a PBefG sieht jedoch vor, zum Schutz von öffentlichen Verkehrsinteressen tarifbezogene Regelungen und Mindestbeförderungsentgelte festzulegen.

Geschäftsmodelle neuer Mobilitätsdienste wie Uber, Lyft oder FreeNow basieren unter anderem auf einer flexiblen Preisgestaltung (engl. surge pricing) in Abhängigkeit von Angebot und Nachfrage. Im Gegensatz zu anderen Märkten wie z. B. den USA, wo auch Privatpersonen Fahrdienste über die genannten Vermittlungsplattformen anbieten können, dürfen kommerzielle Fahrten gemäß PBefG nur von gewerblichen Anbietern durchgeführt werden. In Deutschland werden Fahraufträge dieser Anbieter deshalb zum überwiegenden Teil durch Mietwagenunternehmen durchgeführt.

Ridesourcing

Die Begriffe Ridesourcing bzw. Ridehailing kommen aus dem amerikanischen Sprachgebrauch und beschreiben bedarfsorientierte Mobilitätsangebote, bei denen Kunden (Taxi)Fahrten in Echtzeit, meist über eine Smartphone App, buchen können.

So beschreiben beispielsweise Rayle et al. [30]: *"Ridesourcing allows travellers to request a ride in real-time through a smartphone application, which communicates the passenger's location to nearby drivers. After a driver accepts a ride request, the passenger can view the vehicle's real-time location and estimated arrival time."*

Konnte man vor allem im amerikanischen Raum, wo man Taxis in Großstädten üblicherweise ausschließlich per Handzeichen am Straßenrand bestellte, mit den Begriffen Ridesourcing und Ridehailing moderne, App-basierte Fahrdienste vom klassischen Taxigewerbe abgrenzen, ist diese Definition auf den deutschen Markt nicht unmittelbar anwendbar.

Im deutschsprachigen Raum war es bereits vor Aufkommen von App-basierten Fahrdiensten üblich, Fahrzeuge bei einer örtlichen Vermittlungszentrale per Telefon oder mittels Rufsäule zu bestellen. Diese leitete, ähnlich wie bei App-basierten Systemen heute, Aufträge an über Datenfunk vernetzte Taxis weiter. Auch der Einsatz von GPS-Technik war bereits weit vor Beginn der Smartphone-Ära in Telematiksystemen von Taxis verbaut. Mit der Vermittlungs-App myTaxi war es bereits im Jahr 2012 in Deutschland [31] möglich, Taxis per Smartphone zu bestellen und zu bezahlen. Seit 2015 existiert mit taxi.eu eine europaweit vernetzte App zur Buchung von Taxis in mehr als 140 Städten und einem Vermittlungsvolumen von 180 Mio. Fahrten im Jahr [32].

Weiter beschreiben Rayle et al. [30]: *"Unlike taxis, ridesourcing services (...) typically use drivers who lack a commercial vehicle license, drive their personal vehicle, and work part-time."* Trifft diese Definition auf das Geschäftsmodell bekannter Ridesourcingdienste wie Uber und Lyft z. B. auf dem amerikanischen Markt zu, ist diese Aussage auf den deutschen/europäischen Markt auf Grund gesetzlicher Regelungen nicht gültig (PBefG).

Auch die Definition des Forschungs-Informationssystem Mobilität und Verkehr [33] ist nicht zutreffend: *"Unter Ridesourcing wird eine dynamische Verknüpfung von Fahrtangebot und Fahrtwunsch verstanden, die es Reisenden ermöglicht, Autofahrten in Echtzeit von potenziellen Anbietern über eine Smartphone-App anzufordern. ... Der größte Unterschied zu traditionellen Taxis liegt dabei hauptsächlich im Einsatz von Smartphone-Apps und dem damit verbundenen dynamischen Verknüpfungsalgorithmus."*

Aus Sicht des Autors bedarf es daher einer neuen Definition des Begriffs Ridesourcing:

"Ridesourcing bzw. Ridehailing beschreibt eine bedarfsorientierte Form der Mobilitätsdienstleistung, bei der Kunden und Fahrtenanbieter durch den Einsatz von Informations- und Kommunikationssystemen von einem Dienstleister einander vermittelt werden."

2.1.2 Akteure

Nach der begrifflichen Einordnung werden für das weitere Verständnis von Taxi-/Ridesourcing-Diensten im folgenden Abschnitt relevante Akteure und deren Interaktion näher erläutert.

Kunden

Kunden in einem Taxi-/Ridesourcingdienst sind einzelne oder mehrere Personen mit einem Fahrtwunsch. Dieser ist durch die Eigenschaften Start-/Zielort, Abholzeitpunkt und die Art des gewünschten Transportmittels charakterisiert (Taxi, Mietwagen, Limousine, Van etc.) [24, S. 3]. Kundenrelevante Zielkriterien lassen

sich sowohl in quantitativen (z. B. Fahrpreis, Wartezeit) als auch in qualitativen (z. B. Verfügbarkeit, Komfort) Kennwerte abbilden [34, 35].

Fahrdienstleister

Fahrdienstleister sind in der Regel selbständige Einzelunternehmer oder Mehrwagenbetriebe, die eine Beförderungsdienstleistung auf dem Mobilitätsmarkt anbieten und untereinander in Konkurrenz stehen. Sie nehmen Aufträge direkt von Kunden oder nach Vermittlung durch einen externen Dienstleister entgegen. In der internationalen Literatur wird hierfür häufig der Begriff engl. transportation network company (TNC) verwendet [23, S. 26]. In Deutschland unterliegen gewerbliche Fahrdienstleister dem PBefG und benötigen eine Konzession. Die Angebotsstruktur auf dem deutschen Fahrdienstleistungsmarkt ist heterogen und von einer Vielzahl an Anbietern durchsetzt. Im Jahr 2016 waren in Deutschland insgesamt 20 932 Taxi- und 8321 Mietwagenunternehmen registriert [11, S. 68]. 73,6 % der Taxibetriebe, waren dabei Unternehmen mit nur einem Fahrzeug. 11,6 % der Unternehmen betrieben zwei Fahrzeuge und 14,3 % drei oder mehr Fahrzeuge [11, S. 68].

Vermittlungsdienstleister

In modernen Ridesourcing Systemen bilden Vermittlungsdienstleister die zentrale Schnittstelle und übernehmen die Auftragsvermittlung zwischen Kunde und Fahrdienstleister. Hierzu nimmt der Vermittlungsdienstleister Aufträge mittels App, Telefon oder Rufsäule entgegen und leitet diese an verfügbare Fahrzeuge in seinem Netzwerk weiter. Der Vermittlungsablauf erfolgt dabei automatisiert auf Basis von Heuristiken oder Optimierungsverfahren (Abschnitt 2.2.1) Der Vermittlungsdienstleister erhält hierfür von den angeschlossenen Fahrdienstleistern eine Provision [36] und/oder eine feste monatliche Gebühr.

Der Vermittlungsdienstleister stellt außerdem entsprechende Apps bzw. Telematiksysteme zur Verfügung, über die die Standorterfassung von Fahrzeugen und die Kommunikation zum Fahrer erfolgen kann. Schon vor dem Aufkommen national und international agierender Ridesourcing-Anbieter übernahmen diese Aufgabe im europäischen Markt lokal organisierte Taxizentralen. Beispiele für Vermittlungsdienstleister sind z. B. Uber, Lyft, Didi, aber auch lokale Vermittlungszentralen wie z. B. in München IsarFunk oder die Taxi München eG.

Im Gegensatz zur Vermittlung von Taxifahrten, bei denen der Fahrpreis sich nach einem festgelegten Taxitarif berechnet, übernehmen Vermittlungsdienstleister bei der Vermittlung von Mietwägen in den meisten Fällen auch die Preisbildung (dynamic Pricing/surge Pricing)[37, S. 1–2][38].

Vergleicht man die Effizienz von neu aufkommenden Ridesourcing Diensten zeigt sich, dass diese auf Grund von effizienten Vermittlungsalgorithmen eine höhere Flottenauslastung als das herkömmliche Taxigewerbe erreichen [39]. Während ein Taxi in San Francisco auf 44 % der zurückgelegten Strecke keinen Fahrgast befördert, beträgt dieser Wert bei Uber/Lyft nur circa 20 % [40, S. 15].

2.1.3 Hintergründe und aktuelle Entwicklungen

Fanden moderne Fahrdienstleister und -vermittler bei Kunden auf Grund niedriger Preise und einem einfachen Bestellprozess per App hohen Anklang, sorgten die Entwicklungen innerhalb der Taxibranche von Beginn an für Kontroversen und Widerstand. Vermehrt war diesbezüglich in nationaler und internationaler Berichterstattung von Streiks [41–44], Ausschreitungen [45] und Gerichtsprozessen [46, 47] zu lesen. Dieser Abschnitt gibt eine Einordnung aktueller Entwicklungen und zeigt Herausforderungen für das klassische Taxigewerbe auf.

Gründe für einen regulierten Taximarkt

Der Taximarkt ist in dem meisten Ländern gesetzlich reguliert. Diese Regulation dient nach Cooper und Mundy [48] zur Sicherung von Qualitätsstandards (Zustand der Fahrzeuge, einheitliches Aussehen, Barrierefreiheit), der Beschränkung des Angebots (Anzahl an Konzessionen, Dienstleistungspflichten) und somit der Sicherstellung eines wirtschaftlichen Betriebs (Fahrpreisvorgabe). Harding et al. [38] greifen diese Einordnung auf und formulieren drei wesentliche Probleme, die eine Regulierung des Taximarktes bedingen:

Das Vertrauensgut-Problem (engl. The Credence Good Problem): Waren oder Dienstleistungen, deren Qualität ein Kunde erst nach dem Kauf feststellen kann, werden als Vertrauensgut bezeichnet. Diese Definition trifft nach [49] auf eine Taxifahrt zu. Der Fahrgast kann die Beziehung zwischen Qualität und Quantität der Dienstleistung (Komfort und Länge einer Taxifahrt) und seinem Preis (Fahrpreis) erst nach dem Ende der Fahrt bemessen. Dieser Umstand öffnet einem Anbieter die Möglichkeit, minderwertige Dienstleistungen auf dem Markt anzubieten bzw. zu hohe Preise dafür zu verlangen. Im Gegensatz dazu ist für einen einzelnen Fahrer nicht mit einem Anstieg der Fahrgastzahlen zu rechnen, wenn dieser seine Preise senkt oder die Qualität seiner Dienstleistung verbessert, weil ein einzelner Betreiber kein ausreichend starkes Signal aussenden kann, um den Markt zu differenzieren. In der Folge wären Fahrgäste nur bereit sein, den Preis für das marktbeherrschende (mittelmäßige) Dienstleistungsniveau zu zahlen. Diese Tendenz verdrängt höhere Qualität aus dem Markt und führt langfristig zu einer Abnahme der Dienstleistungsqualität. [38]

Das Problem des offenen Marktes (engl. The open access problem): Beobachtungen in US Metropolen zeigen, dass mit einem Wegfall der Angebotsbegrenzung durch Konzessionsvergabe eine Vielzahl neuer Anbieter auf den Taximarkt drängen [38]. Dies wird durch die niedrigen Anfangskapitalkosten (Fahrzeugschaffung) für den Markteintritt zusätzlich begünstigt. Im Vergleich hierzu belaufen sich die Kosten für eine Taxilizenz in internationalen Metropolen von 25 000 £ in England [50] bis zu zwischenzeitlich 1 000 000 \$ in New York [51]. Durch die lokal begrenzte Angebots-/Nachfragesituation können durch den unreglementierten Eintritt neuer Anbieter Preise lokal beeinflusst werden. Geht der Anstieg des Angebots nicht mit einem entsprechenden Anstieg der Nachfrage einher, sinkt die Markteffizienz. Für Betreiber bedeutet dies in Folge einen Umsatzrückgang bei gleichbleibenden Kosten [38, 52]. Eine mögliche Folge dessen ist – wie im deutschen Fernbusmarkt zu beobachten –, dass nach einer kurzfristigen Erhöhung der Anzahl an Anbietern langfristig eine Marktkonsolidierung auf wenige, preisbestimmende Anbieter erfolgt [53, S. 10]. Eine weitere Konsequenz in Folge einer zunehmenden Anzahl an Anbietern ist das steigende Verkehrsaufkommen in strukturell bereits aus-/überlasteten Innenstädten [54–57].

Das Problem des dünn besiedelten Marktes (engl. The “thin market” problem): Ein dünn besiedelter Markt hat eine geringe Anzahl von Käufern und Verkäufern. Dies verringert die Wahrscheinlichkeit, dass Anbieter und Käufer zueinander finden, wodurch die Gesamtzahl der Transaktionen auf dem Markt niedrig bleibt. Die Nachfrage im Taxigewerbe ist typischerweise örtlich dünn gestreut und es gibt eine geringe Anzahl an lokalen Anbietern. Anstatt Betreibern eine flexible Preisgestaltung zu ermöglichen, um die unterschiedlichen Fahrtkosten (Stadtfahrt, Fahrt in einen Vorort) oder die aktuelle Angebots- und Nachfragesituation widerzuspiegeln, werden fixe Fahrpreisvorgaben durchgesetzt, um mögliche Preisschwankungen zu glätten, was nach [38] eine typische Reaktion auf einen dünn besiedelten Markt ist. [38, 58]

Für einen umfassenden Überblick zu Formen und Auswirkungen von Regulierungsmaßnahmen im internationalen Vergleich sei auf [59] verwiesen.

Einfluss von Uber und Co.

Galten die drei formulierten Probleme für den konventionellen Taximarkt, sind diese durch die Belegung des Marktes und Geschäftsmodelle aufkommender Anbieter zukünftig zu hinterfragen [38]. Unternehmen,

Politik, sowie Wissenschaft beschäftigen sich aktuell mit der Fragestellung, inwiefern der Markt für Fahrdienstleistungen liberalisiert oder weiter reguliert werden soll.

Geschäftsmodell

Das Geschäftsmodell aufstrebender Ridesourcing Plattformen, wie Uber, Lyft und FreeNow basiert auf der App-basierten Vermittlung von Fahr- und Transportdienstleistungen. Hierfür erhält der Plattformbetreiber vom durchführenden Fahrdienstleister anteilig eine Provision auf Basis des erzielten Fahrpreises. Die Preisbildung wird dabei ebenfalls durch den Plattformbetreiber bestimmt. Durch sie ist es dem Plattformbetreiber möglich, Angebot und Nachfrage gezielt über den Preis zu beeinflussen [37, S. 1–2][38].

Diese Art des Plattformmodells ist für Betreiber besonders lukrativ, da es sich einfach skalieren lässt, schnell auf internationale Märkte angepasst und ausgerollt werden kann [60] und das unternehmerische Risiko für Anschaffungs- und Unterhaltskosten der benötigten Fahrzeuge vollständig auf die Fahrdienstunternehmen ausgelagert ist.

Mit ihrem Geschäftsmodell treten international agierende Ridesourcing-Plattformen in direkten Wettbewerb zu lokalen Vermittlungszentralen und indirekt in Konkurrenz zu Taxiunternehmen selbst, weil der vormals beschränkte Markt für Fahrdienstleistungen nun durch weitere Anbieter bedient wird.

Angst vor Marktdominanz und Preisbestimmung

Eines der meist aufgeführten Argumente gegen eine Liberalisierung des Fahrdienstmarktes ist die Befürchtung einer langfristigen Marktdominanz und Preisbestimmung eines oder weniger Plattformanbieter in Folge einer mittelfristigen Marktkonsolidierung [61, 62]. Dabei fürchtet vor allem das Taxigewerbe mit möglichen Kampfpreisen finanziell gut ausgestatteter Konzerne während der Konsolidierungsphase nicht mithalten zu können. Darüber hinaus haben Taxibetriebe, auf Grund des vorgegebenen Tarifs, diesbezüglich keine Reaktionsmöglichkeiten. Kritiker führen des Weiteren an, dass die öffentliche Daseinsvorsorge in einem liberalen, selbst regulierenden Markt in nachfrageschwachen und somit betriebswirtschaftlich unrentablen Zeiten nicht aufrecht erhalten werden kann [11, S. 37]

Kritik an illegalen Betriebs- und Arbeitsbedingungen

Ridesourcing-Plattformen stehen in Deutschland vor allem in der Kritik, gesetzliche Regelungen zur Beförderung von Personen zu umgehen. Wie in Absatz 2.1.1 beschrieben, gelten für Mietwagenbetriebe in Abgrenzung zum Taxiverkehr gesetzliche Einschränkungen. So dürfen Aufträge nur am Unternehmenssitz bzw. einem Ersatzstandort entgegengenommen werden, zudem besteht eine Rückkehrpflicht. Taxiverbände werfen Uber vor, gegen diese und weitere gesetzliche Regelungen zu verstoßen und damit den Wettbewerb unlauter zu verzerren [46, 47, 61].

Für weitere Kritik sorgen international die Arbeits- und Lohnbedingungen bei Fahrern von Ridesourcing-Diensten [63–66]. Kritiker führen an, dass sich Ridesourcing-Plattformen ihrer unternehmerischen Verantwortung entziehen, indem sie mit ihrem Geschäftsmodell Dumpinglöhne und Arbeitnehmersausbeutung gezielt fördern [11, S. 38].

Innovationstreiber und Marktbelebung

Neben Ängsten und Kritik kann aufkommenden Ridesourcingdiensten gleichzeitig aber auch ein positiver Effekt auf die Marktbelebung und den Innovationsdrang innerhalb der Branche bescheinigt werden. Durch die Vermittlung mittels App wurden neue Kundengruppen angesprochen und der Bestell- und Bezahlvorgang vereinfacht [38, 67]. Weltweit wird daher bis 2025 von einem jährlichen Umsatzwachstum von 11 % für Ridesourcing- und Taxi-Dienstleistungen ausgegangen [67].

War das herkömmliche Taxigewerbe durch den regulierten Markt nur in geringem Maße zu technischen Innovationen gezwungen, ist nach dem Aufkommen moderner App-Vermittler ein deutlicher Innovationschub zu erkennen. Sowohl der verstärkte Einsatz von Elektromobilität [11, S. 29], als auch die Entwicklung einer europaweiten Vermittlungsapp für Taxidienste [32] wurden durch die zunehmende Konkurrenz angestoßen bzw. beschleunigt. Es ist zu erwarten, dass der gesteigerte Wettbewerb auch in Zukunft weitere Innovationen zur Steigerung der Effizienz hervorbringt.

2.2 Methoden zur Optimierung von Ridesourcing Diensten

Wie im vorherigen Abschnitt gezeigt, herrscht aktuell auf dem Markt für Ridesourcing-Dienste wegen des gesteigerten Wettbewerbs ein hoher Innovationsdruck, um durch Effizienzsteigerungen Kostenvorteile zu erwirken. Für die Optimierung von Ridesourcing Diensten können in der Forschungslandschaft vier für das weitere Vorgehen relevante Teilprobleme identifiziert werden:

1. Strategien zur Vermittlung zwischen Fahrgast und Fahrzeug (engl. dispatching),
2. die Prädiktion von Angebot und Nachfrage (engl. demand/supply prediction),
3. die optimale räumlich-zeitliche Verteilung der Fahrzeugflotte innerhalb des Geschäftsgebiets (engl. Rebalancing)
4. die Bestimmung der optimalen Flottengröße (engl. fleet sizing).

Einen umfassenden Überblick der Forschungslandschaft geben an dieser Stelle die Arbeiten von Kümmel [68] (Taxigewerbe, Vermittlungsstrategien, Rebalancing), Ritzinger et al. [69] (engl. vehicle routing problem (VRP), engl. dynamic vehicle routing problem (DVRP)), Pillac et al. [70] (DVRP) und Klöppel [71] (VRP und Flottensimulation). Diese Arbeit greift relevante Inhalte aus diesen Vorarbeiten auf und ergänzt diese im Kontext neuer Forschungsergebnisse.

2.2.1 Vermittlungsstrategien

Zentrales Element eines Ridesourcing Diensts ist die Vermittlungsstrategie. Sie bestimmt die Zuordnung von freien Fahrzeugen zu eingehenden Kundenanfragen. Diese können entweder im Voraus bekannt sein, z. B. im Falle einer Vorbestellung oder spontan auftreten. Die Zuordnung kann von einer zentralen Einheit (z. B. Vermittlungszentrale) vorgegeben werden, oder dezentral durch die Entscheidungen einzelner Akteure (Fahrer/Kunden) erfolgen. Das hierbei zu Grunde liegende Optimierungsproblem wird im Bereich der Operational Research als VRP bezeichnet [72]. Sind dabei, wie im Fall eines Taxidienstes, Fahrten und verfügbare Fahrzeuge im Vorhinein nicht bekannt, wird das Problem weiter als DVRP bzw. engl. dial a ride problem (DARP) spezifiziert [69, 70]. Ziel der Optimierung ist dabei vorrangig, die Wartezeit des Fahrgastes zu minimieren, um ein größtmögliches Servicelevel zu erreichen. Zur Lösung des Problems haben sich in der Praxis vielfältige Methoden, von einfachen Heuristiken über mathematische Optimierungsverfahren bis zu hin zu Deep-Learning-Methoden, etabliert [70].

Heuristiken

Heuristiken liefern regelbasierte Strategien zur Lösung von Optimierungsproblemen. Der Einsatz von Heuristiken kann dabei die benötigte Rechenzeit im Vergleich zu mathematischen Lösungsverfahren, mit der Einschränkung einer nicht garantierten optimalen Lösung, deutlich reduzieren [73]. Aufgrund ihrer vergleichsweise einfachen Anwendung und Erklärbarkeit finden Heuristiken auch aktuell noch in großem Umfang Anwendung bei der Fahrgastvermittlung.

Die naheliegendste Regel zur Vermittlung von Fahrgästen ist die Methode engl. first come first served (FCFS) bzw. engl. first in first out (FIFO). Hierbei werden die an einer zentralen Stelle eingehenden Kundenanfragen sequenziell freien Fahrzeugen zugeordnet [68, S. 15]. Die Auswahl der Fahrzeuge beschränkt sich dabei in der Regel auf das Taxi mit dem kürzesten Anfahrtsweg engl. nearest idle taxi (NIT). Lee et al. [74] konnten zeigen, dass unter Berücksichtigung von Echtzeitverkehrsinformationen über die Auswahl des Taxis mit der kürzesten Anfahrtszeit in 210 von 300 Fällen eine kürzere Wartezeit für den Kunden erreicht werden kann.

Sobald die Anzahl der verfügbaren Fahrzeuge kleiner wird als die Anzahl der offenen Anfragen, nehmen Anfahrtswege bei der Zuweisung von Kunden nach FIFO tendenziell zu. Um dies zu vermeiden, schlagen Maciejewski und Bischoff [75] vor, zu diesen Zeiten die Vermittlungsstrategie umzukehren. Anstatt für einen Kunden das nächste freie Taxi zu ermitteln, wird für das als nächstes frei werdende Taxi der nächstgelegene Kunde ermittelt – engl. nearest taxi nearest request (NTNR). In der Folge werden in dieser Zeit Kunden priorisiert, die sich in der Nähe von frei werdenden Taxis befinden. Kunden, die in dieser Zeit ungünstig positioniert sind, erfahren dadurch wesentlich höhere Wartezeiten oder bekommen gar kein Fahrzeug zugewiesen. Maciejewski und Bischoff [75] konnten zeigen, dass durch den Einsatz von NTNR auch bei steigendem Ungleichgewicht von Anfragen zu verfügbaren Fahrzeugen die mittlere Wartezeit aller Kunden auf einem niedrigen Niveau gehalten werden kann.

Sequenzielle, irreversible, regelbasierte Verfahren wie FIFO oder NTNR bergen den Nachteil, dass zukünftige Änderungen des Systemzustands nicht berücksichtigt werden. Wird beispielsweise zum Zeitpunkt t_0 das örtliche nächste Fahrzeug F_0 einem Kunden zugeordnet und kurz darauf zum Zeitpunkt t_1 ein weiteres Fahrzeug F_1 in unmittelbarer Nähe des Kunden frei, bedingt die sequenzielle Vermittlung, dass der Kunde trotzdem Fahrzeug F_0 zugewiesen bekommt, obwohl F_1 den Kunden schneller erreichen könnte als F_0 [76][68, S. 45].

Zur Lösung des Problems schlagen Maciejewski et al. [77] vor, Fahrzeuge, die in Kürze frei werden, bereits in der Vermittlung zu berücksichtigen. Zwingend erforderlich ist dabei, dass das Fahrtziel und die voraussichtliche Ankunftszeit aller Fahrzeuge zum Zeitpunkt der Vermittlung bekannt ist. Verma und Vo [78] verwenden in einem vergleichbaren Ansatz ein Vorhersagemodell zur Prädiktion zukünftig frei werdender Fahrzeuge.

Global optimierende Vermittlungsmethoden

Wie gezeigt, weist die regelbasierte, sequenzielle und irreversible Vermittlung von Fahrten Nachteile auf. Das zum Zeitpunkt der Entscheidung scheinbare Optimum kann sich im weiteren Verlauf sowohl für Fahrgäste (längere Wartezeiten), als auch für Fahrer und Flottenbetreiber (längere Leerfahrten) als nachteilig herausstellen. Global optimierende Vermittlungsmethoden versuchen, den sich zeitlich ändernden Systemzustand zu berücksichtigen, um eine langfristig optimale Lösung für das Gesamtsystem zu ermitteln.

Ein möglicher Ansatz an dieser Stelle ist es, den Lösungsraum für die Vermittlung von Kunde zu Fahrzeug zu vergrößern. Eingehende Kundenanfragen werden dazu nicht sequenziell bearbeitet, sondern mit weiteren Anfragen innerhalb eines definierten Zeitintervalls Δt zusammengefasst. Anstatt einer $1 \times n$ Zuordnung (1 Kunde zu n Fahrzeugen bzw. 1 Fahrzeug zu n Kunden) wird eine optimale Lösung für die Zuordnung $m \times n$ (m Kunden zu n Fahrzeugen, bzw. m Fahrzeugen zu n Kunden) innerhalb des Zeitintervalls Δt gesucht. Der Parameter Δt muss dabei so groß gewählt werden, dass genügend Anfragen für die Vermittlung zusammengefasst werden können, aber so klein, dass durch die Pufferung der Anfragen selbst keine Verzögerung für den Kunden auftritt [79].

Lineare Optimierung/Bipartites Matching

Das Problem der Zuordnung von m Fahrgästen zu n freien Fahrzeugen lässt sich allgemein als lineares Optimierungsproblem darstellen. In der diskreten Mathematik kann das Problem ferner als bipartiter Graph beschrieben werden [80, S. 99]. Die Knoten des Graphen repräsentieren dabei die Menge an Aufträgen und Fahrzeugen, die Kanten mögliche Zuordnungen von Kunden und Fahrzeugen. Über die Gewichte des Graphen lässt sich das Optimierungskriterium festlegen. Verwendete Lösungsverfahren des bipartiten Matchings sind z. B. die ungarische [81] oder Min-Cost-Flow Methode [82, S. 197]. Bipartites Matching kann im Rahmen einer retrospektiven Betrachtung auch verwendet werden, um die Frage nach einer optimalen Flottengröße zu beantworten (2.2.4).

Zhan et al. [79] untersuchen die Effizienz des New Yorker Taxigewerbes im Hinblick auf die Kosten der Fahrzeugbetreiber. Der Fokus liegt dabei auf der Minimierung von Anfahrtswegen und Leerlaufzeiten von Taxifahrern durch bipartites Matching. Wichtungskriterium dazu ist eine Kostenfunktion aus Anfahrtszeit und -weg. In Kombination mit einer reduzierten Flottengröße wurde gezeigt, dass theoretisch bis zu 90 % der Zeit, in der ein Taxi unbesetzt ist und bis zu 87 % der Leerkilometer eingespart werden können. Zhan et al. [79] nutzen in ihrer Analyse Zeitintervalle bis zu $\Delta t = 15$ Min. Fraglich sind an dieser Stelle die Auswirkungen Wartezeit und Akzeptanz der Kunden, sowie tatsächliche Wechselwirkungen bei der Betrachtung kürzerer Zeitintervalle.

Vazifeh et al. [13] wählen als Optimierungsziel die Kundenwartezeit. Dem Umstand, dass der Verkehrsfluss in Realität über den Tag variiert, wird durch die Berücksichtigung historischer Fahrtzeiten Rechnung getragen. Im Gegensatz zu Zhan et al. [79] wählen Vazifeh et al. [13] außerdem eine kürzere Zeitkonstante von $\Delta t = 1$ Min. Ebenfalls am Beispiel New York zeigen sie, durch den Einsatz von bipartiten Matching und unter Annahme einer vollständig bekannten Nachfrage, die notwendige Fahrzeugflotte um 40 % reduziert werden kann, ohne dass dadurch für den Kunden eine längere Wartezeit entsteht.

Hörl et al. [83] vergleichen am Beispiel autonomer Taxis in Zürich die Leistungsfähigkeit eines heuristischen Ansatzes (NTNR [75]) mit dem des bipartiten Matchings. Im untersuchten Szenario war dabei bipartites Matching sowohl in Zeiten niedrigen Bedarfs, als auch zu Spitzenzeiten der Methode NTNR im Bezug auf die Zielgröße Kundenwartezeit stets überlegen.

Miao et al. [84] wählen einen robusten Optimierungsansatz für die Fahrgastvermittlung. Optimierungsziel ist die Minimierung der Leerfahrtdistanz unter Berücksichtigung von Unsicherheiten in der zukünftigen Taxinachfrage. Lohnt es sich, durch die gezielte Vermittlung von Fahrten Taxis aktiv umzuverteilen, weil am Zielort möglicherweise eine Anschlussfahrt wartet? Auswertungen zeigen, dass unter dem entworfenen robusten Vermittlungsverfahren die durchschnittliche Distanz für Leerfahrten am Beispiel New York um 10 % reduziert werden kann.

Reversible Vermittlungsverfahren

Wurde eine Zuordnung von Fahrgast zu Fahrzeug festgelegt, wird diese im realen Betrieb in der Regel beibehalten. Es ist fraglich, welche Akzeptanz Taxifahrer einer reversiblen Vermittlung entgegenbringen würden, wenn sich während der Anfahrt Auftragsort und Fahrtziel fortlaufend ändern. Aus globaler Sicht kann es jedoch durchaus sinnvoll sein, flexibel auf geänderte Rahmenbedingungen reagieren zu können.

Durch eine fortlaufende Neuordnung von Taxis und Fahrgästen zeigen Billhardt et al. [85], dass im Vergleich zu FIFO und NTNR unter hoher Nachfrage kürzere Wartezeiten und geringere Leerdistanzen erzielt werden können. Damit Taxifahrer keine Fahrten verlieren, erfolgt eine Neuordnung nur zwischen Fahrzeugen, die sich bereits in Anfahrt zu einem Kunden befinden. Zu vergleichbaren Ergebnissen kommen auch Kümmel [68], Hyland und Mahmassani [86] durch eine fortlaufende Neuzuweisung von Anfragen, gestützt durch mathematische Optimierung.

Maschinelles Lernen

Neben klassischen Optimierungsverfahren eignen sich auch maschinelle Lernverfahren zur Vermittlung von Kunden und Fahrzeugen.

Der chinesische Ridesourcing Dienst Didi [87] verwendet für die Vermittlung von Fahrgästen ein selbstlernendes Verfahren. Basierend auf historischen Daten werden Vermittlungsentscheidungen als sequenzielles Entscheidungsproblem modelliert. Im Realvergleich konnte mit diesem Ansatz der Bruttoumsatz der Gesamtflotte um bis zu 5 % gesteigert werden [88].

Stable Matching

Verfahren der Kategorie des Stable Matching versuchen, ähnlich zu linearen Optimierungsverfahren, eine optimale Zuordnung zwischen zwei Gruppen zu ermitteln. In allen bisher vorgestellten Ansätzen wurde davon ausgegangen, dass Vermittlungsentscheidungen von einer zentralen Instanz ermittelt und von Fahrzeugen ohne Entscheidungsmacht umgesetzt werden. In den meisten realen Einsatzszenarien können jedoch Taxifahrer selbst entscheiden, ob sie einen Fahrauftrag annehmen oder nicht. Es gilt daher nicht nur, eine global optimierte Lösung zu finden, sondern eine, die sowohl von Fahrern, als auch Kunden akzeptiert wird. [68, S. 37]

Kümmel [68] untersucht unter dem Gesichtspunkt einer stabilen Lösung drei mögliche Ansätze für Vermittlungsstrategien: 1. die gebündelte Vermittlung von Kundenanfragen – ähnlich zu [79, 83]; 2. die kontinuierliche Neuordnung aller offenen Anfragen; sowie 3. die kontinuierliche Neuordnung zeitlich naher Anfragen. Die Ergebnisse zeigen, dass alle gewählten Strategien besser sind als FCFS. Besonders zu Zeiten starker Nachfrage können jedoch nur wenige Neuordnungen vorgenommen werden. In Bezug auf die Kundenwartezeit konnte im Referenzbeispiel San Francisco eine Verbesserung um bis zu 5 % erreicht werden.

Wie wahrscheinlich ist es, dass eine eingehende Anfrage an einen Taxifahrer vermittelt werden kann? Zhang et al. [89] treffen basierend auf einer Wahrscheinlichkeitsabschätzung eine Vorauswahl, welche Taxifahrer am ehesten gewillt sind, einen spezifischen Kundenauftrag auszuführen. Im Realeinsatz konnte nachgewiesen werden, dass durch dieses Vorgehen Fahrten schneller vermittelt werden können.

Dezentrale Vermittlungsmethoden

Im Gegensatz zu einer zentralen Vermittlungsstrategie, bei der Aufträge zentral gesammelt und zugewiesen werden, werden bei dezentralen Vermittlungsverfahren Entscheidungen eigenständig zwischen Kunden und Fahrern abgestimmt. Dieser Entscheidungsprozess kann sowohl isoliert, als auch in Abstimmung mit anderen Akteuren erfolgen. Seow et al. [90][91] schlagen dazu ein verhandlungsbasiertes Vorgehen vor. Anfragen werden dabei jeweils an Gruppen von Fahrzeugen vermittelt und von diesen in Abstimmung untereinander verteilt. Im untersuchten Referenzbeispiel konnte die Wartezeit für den Kunden um 33 % reduziert werden.

2.2.2 Prädiktion von Angebot und Nachfrage

Ein weiteres Teilproblem der Optimierung von Ridesourcing Diensten ist die Vorhersage von Angebot (Anzahl verfügbarer Fahrzeuge) und Nachfrage (Anzahl Kundenanfragen). Dadurch kann zum Beispiel die Positionierung von Fahrzeugen (wann wird wo eine hohe Nachfrage erwartet und wie viele Fahrzeuge positioniert man dort vorab) [92–95], oder die Schichtplanung (wann werden wie viele Fahrer benötigt) optimiert werden. Prognosemodelle versuchen dabei, aus Beobachtungen den zeitlichen Verlauf (z. B. Anzahl Kundenanfragen pro Zeitschritt), die räumliche Verteilung (z. B. Ort der Kundenanfrage) oder den räumli-

chen und zeitlichen Verlauf einer Größe (z. B. Anzahl Kundenanfragen pro Zeitschritt und Ort) vorherzusagen. Der folgende Abschnitt gibt eine Übersicht methodischer Grundlagen sowie Anwendungsbeispiele in Ridesourcing-Systemen.

Methoden der Zeitreihenvorhersage

Eine Zeitreihe ist eine zeitlich abhängige Folge von Beobachtungen [96] – z. B. der zeitliche Verlauf besetzter und freier Fahrzeuge oder die Anzahl an Kundenanfragen pro Zeitschritt (Abbildung 2.2). Zeitreihen können dabei aus einer einzelnen Variable (z. B. die stündliche Anzahl an Taxifahrten) oder aus mehreren Variablen (Bsp. Wetterbeobachtung mit den Messwerten Temperatur, Niederschlag etc.) bestehen. Man spricht an dieser Stelle dann von univariaten bzw. multivariaten Zeitreihen [97, S. 13].

Im Kontext des maschinellen Lernens wird die Zeitreihenvorhersage in die Klasse des überwachten Lernens (engl. supervised learning) eingeordnet und weiter als Regressionsproblem beschrieben. Im Folgenden werden zur weiteren Einordnung gängige Verfahren zur Zeitreihenprognose kurz vorgestellt. Für eine detaillierte Beschreibung der Verfahren sei auf die im weiteren Verlauf genannte Literatur verwiesen.




Abbildung 2.2: Beispiele für Zeitreihen in Ridesourcingsystemen: Links: Angebot an Fahrzeugen, Rechts: Kundennachfrage im Zeitraum 2.–7. Juli 2018.

Naive Vorhersage/Gleitender Mittelwert

Die einfachste Art der Vorhersage stellt die naive Prognose dar. In diesem Fall wird angenommen, dass der aktuell bekannte Wert $y(t)$ auch dem zukünftigen Wert $\hat{y}(t+1)$ entsprechen wird [98, S. 159]. Eine erweiterte Form der naiven Prognose stellt das Verfahren des gleitenden Mittelwerts dar. Hierbei wird der zukünftige Wert auf Basis des Mittelwerts n vergangener Zeitschritte berechnet:

$$\hat{y}(t+1) = \frac{1}{n} \sum_{i=0}^{n-1} y(t-i). \quad (2.1)$$

Aufgrund ihrer beschränkten Komplexität werden naive Vorhersagemethoden in der Praxis vor allem als Referenzmodell verwendet.

Komponentenmodelle

Komponentenmodelle betrachten eine Zeitreihe als einen aus mehreren Komponenten zusammengesetzten Prozess. Der Prozess wird dazu in möglichst einfache Teile zerlegt, die in die Zukunft extrapoliert werden können. Zur Vorhersage werden die Prognosen einzelner Komponenten anschließend wieder additiv oder multiplikativ miteinander verrechnet. Komponentenmodelle sind dadurch in der Lage, Trends, Saisonalitäten, zyklische und irreguläre Komponenten abzubilden [99, S. 41]. Die Identifikation relevanter Komponenten-

ten sowie passender Teilmodelle erfordert in der Praxis oft zusätzliches Domänenwissen und manuellen Anpassungsaufwand. Taylor und Letham [100] stellen zur Vereinfachung dieses Prozesses beispielsweise mit Prophet ein Framework zur vereinfachten Modellierung und Anpassung zur Verfügung.

Autoregressive Modelle

Ein universelles Modell zur Prognose stationärer Zeitreihen ist nach Vogel [99, S. 77] das Modell des autoregressiven, gleitenden Mittelwerts (engl. autoregressive moving average (ARMA)). Es wird bei dieser Klasse von Modellen davon ausgegangen, dass zukünftige Werte einer Zeitreihe unmittelbar von Beobachtungen vergangener Zeitschritte abhängen. Der Prozess kann durch lineare Differentialgleichungen mit konstanten Koeffizienten für stationäre Zeitreihen beschrieben werden [101, S. 47]. Auch nicht lineare Prozesse können durch Differenzieren in eine stationäre Zeitreihe überführt werden und als engl. autoregressive integrated moving average (ARIMA) [101, S. 158] Prozess abgebildet werden. Besitzt die Zeitreihe zusätzlich eine saisonale Komponente, kann der Prozess mit Hilfe eines engl. seasonal autoregressive integrated moving average (SARIMA) Verfahrens modelliert werden [101, S. 177–183].

Neuronale Netze

Neben klassischen Methoden liegt der Fokus aktueller Forschungsarbeiten auf der Entwicklung und Anwendung von neuronalen Netzen zur Vorhersage domänenspezifischer Zeitreihen [97, 102, 103] [104, S. 462]. Durch die fortwährend wachsende verfügbare Datenmenge, die Steigerung der Rechenleistung und neue Erkenntnisse bezüglich empfohlener Vorgehensweisen, verzeichnen neuronale Netze einen deutlichen Anstieg ihrer Popularität.

Einen umfassenden Überblick zu existierenden Netzarchitekturen und deren Anwendung in der Vorhersage von Zeitreihen geben Torres et al. [105] und Brownlee [97]. Dieser Abschnitt fasst grundlegende Aussagen für das weitere Verständnis dieser Arbeit zusammen. Für weiterführende Erläuterungen sei auf die beiden Veröffentlichungen und auf die dort aufgeführte Grundlagenliteratur verwiesen.

Neuronale Netze bieten im Gegensatz zu herkömmlichen Methoden Vorteile bei der Vorhersage von Zeitreihen, weil diese robust gegenüber fehlenden Daten sind, nicht lineare Zusammenhänge abbilden, zeitliche Abhängigkeiten im Laufe des Trainingsprozesses selbst erlernen und multivariate Eingangsdaten einfach verarbeiten können [97, S. 3–5]. Des Weiteren führt Gamboa [103, S. 1] als entscheidenden Nachteil herkömmlicher Methoden an: *“Existing techniques often depended on hand-crafted features that were expensive to create and required expert knowledge of the field”*.

Neuronale Netze können entsprechend ihres Aufbaus in vorwärtsgerichtete, engl. feedforward neuronal network (FFNN), und rekurrente, engl. recurrent neural network (RNN), Netze unterteilt werden [104, S. 465]. Beispiele für vorwärtsgerichtete Netzarchitekturen zur Vorhersage von Zeitreihen sind mehrschichtige Perzeptrone (engl. multi layer perceptron (MLP)) und faltende neuronale Netze (engl. convolutional neuronal network (CNN)).

Das MLP stellt eine einfache Netzarchitektur dar, die eine direkte Abbildungsfunktion zwischen Eingangs- und Ausgangsschicht approximiert [97, S. 4]. Ähnlich wie herkömmliche Methoden der Zeitreihenvorhersage haben MLP den Nachteil, dass zeitliche Abhängigkeiten der Zeitreihe bereits im Voraus bei der Entwicklung des Modells in der Eingangsschicht festgelegt werden müssen. Diese sind in der Regel unbekannt und müssen durch eine detaillierte Analyse herausgearbeitet werden [97, S. 5].

CNN wurden ursprünglich für die Bildverarbeitung entwickelt [106]. Diese Art von Netzen ist in der Lage, mittels Faltung und Pooling relevante Merkmale des Eingangsvektors selbst zu extrahieren [105, S. 11]. Netze dieser Art benötigen damit keine umfassende Voranalyse bzgl. der zeitlichen Abhängigkeiten innerhalb der Zeitreihe, bieten aber dieselben Vorteile wie MLP. [97, S. 6]

Rekurrente neuronale Netze unterscheiden sich von gewöhnlichen FFNN durch eine Rückführung von Werten innerhalb der Netzstruktur. In RNN existieren zusätzliche Verbindungen zu seitlich und rückwärts gerichteten Neuronen. Dadurch durchlaufen Informationen ausgewählte Neuronen des Netzes mehrfach. Durch diese Rückführung vergangener Werte ist das Modell in der Lage, zeitliche Abhängigkeiten in Sequenzen zu erlernen und diese dynamisch anzupassen [97, S. 6–7] [105, S. 8–9]. Ein bekanntes Problem bei RNN mit einer hohen Anzahl an Schichten ist das, durch die Rückführung induzierte, Problem des verschwindenden Gradienten (engl. vanishing gradient problem) während des Trainingsprozesses.

Eine häufig hierfür genutzte Architektur sind engl. long short-term memory (LSTM) Netze [107]. Deren Architektur bietet zwei entscheidende Vorteile: Sie löst das bekannte Problem des verschwindenden Gradienten, das bis dahin das Training tiefer RNN verhinderte, und sie ermöglicht es, sowohl langfristige als auch kurzfristige Abhängigkeiten der Eingangssequenz zu erlernen.

So konstatieren Malhotra et al. [108, S. 1]: *“Because of this ability to learn long term correlations in a sequence, LSTM networks obviate the need for a pre-specified time window and are capable of accurately modelling complex multivariate sequences.”*

Vorhersage räumlicher Zeitreihen

Neben dem rein zeitlichen Verlauf erfordern bestimmte Fragestellungen in der Vorhersage zusätzlich eine räumliche Komponente. So ist es im Fall von Ridesourcing-Systemen nicht nur relevant, wann wie viele Personen ein Fahrzeug benötigen, sondern zusätzlich an welchem Ort (Abbildung 2.3).

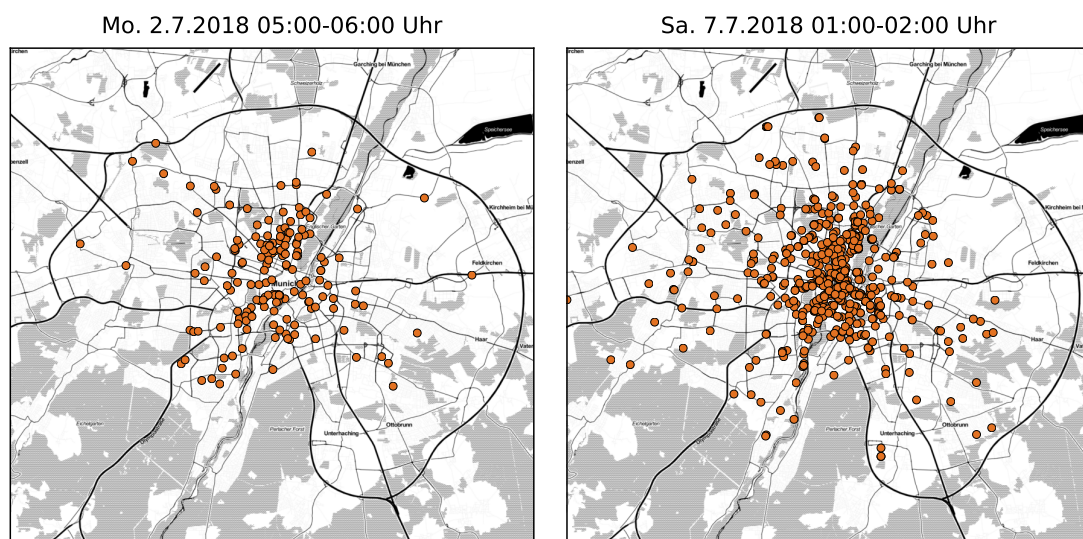


Abbildung 2.3: Beispiel räumlich/zeitlich veränderlicher Abfahrtsorte (orange) von Taxifahrten in München (Karte: Stamen Desing ). Daten: OpenStreetMap, unter ODbL).

Hierzu müssen die Beobachtungen sowohl zeitlich als auch räumlich diskretisiert werden. Dafür eignen sich hierarchische Rasterformate [109–111], die eine schnelle und gleichmäßige Unterteilung des Untersuchungsgebiets ermöglichen.

Die nun räumlich separierten Beobachtungen können anschließend als eigenständige Zeitreihen betrachtet und mit den zuvor genannten Methoden verarbeitet werden. Ein Nachteil dieses Vorgehens ist, dass die Anzahl der Modelle und damit auch die benötigte Trainings-/Rechenzeit proportional mit der Anzahl an unterteilten Gebieten anwächst. Außerdem bleiben potenzielle räumlich-zeitliche Abhängigkeiten zwischen einzelnen Gebieten unberücksichtigt.

Alternativ können hierzu spezielle Netzarchitekturen wie CNN-LSTM oder engl. convolutional long short-term memory (ConvLSTM) [112] verwendet werden. Diese können räumlich zwei-dimensionale Zeitreihen direkt verarbeiten und sind darüber hinaus in der Lage, räumliche Wechselwirkungen zwischen einzelnen Gebieten zu erlernen [97, S. 133].

Anwendungen

In der praktischen Anwendung sind in der Forschungslandschaft einige Beispiele für den Einsatz von Prognosemodellen bei der Optimierung von Ridesourcing-Systemen zu finden. Tabelle 2.1 zeigt eine Auswahl aktueller Forschungsarbeiten:

Tabelle 2.1: Zeitreihenvorhersage in ihrer Anwendung bei Ridesourcing Datensätzen

Quelle	Szenario	Daten	Zeitraum	Zeitliche Auflösung	Räumliche Auflösung	Methode(n)
Moreira-Matias et al. [113] Moreira-Matias et al. [16]	Porto, Odivelas, Loures	Taxi	01.08.2011 – 01.04.2012	1 h	Taxistände	ARIMA, Poisson Modell
Davis et al. [114]	Bangalore	Taxi	2 Monate	1 h	Geohashes, 1,2 km×0,6 km	STL, TBATS, LR, HW
Zhao et al. [115]	New York	Taxi	1 Monat	1 h	Häuserblocks	MC, LZW, MLP
Markou et al. [116]	New York	Taxi, Events	01.01.2013 – 30.06.2016	1 h	Veranstaltungsorte	GP, LR
Xu et al. [117]	New York	Taxi, Wetter	01.01.2013 – 30.06.2016	5 – 60 min	Geohashes, 153 m×153 m	LSTM, MDN
Yao et al. [118]	Guangzhou	DiDi, Wetter, Feiertage	01.02.2017 – 26.03.2017	30 min	20×20-Grid, 700 m×700 m	DMVST-Net: CNN, LSTM
Chu et al. [119]	New York	Taxi	01.01.2009 – 30.06.2015	10 min	28×20-Grid, 220 m×170 m	MultiConvLSTM
Ke et al. [120]	Hangzhou	DiDi, Wetter, Verkehr	01.11.2015 – 01.11.2016	1 h	7×7-Grid, 4,77 km×4,81 km	FCL-Net: ConvLSTM
Wang et al. [121]	Chengdu	DiDi	01.11.2016 – 30.11.2016	1 h	74×74-Grid, 1 km× 1 km	DeepSTCL: ConvLSTM
Davis et al. [122]	Bangalore, New York	Taxi	01.01.2016 – 29.02.2016	1 h	Geohashes, 1,2 km×0,6 km Voronoi-Einteilung	LSTM, ARIMA, ConvLSTM, GraphLSTM
Zhou et al. [123]	New York	Taxi	01.01.2009 – 01.01.2015	1 h	64×64-Grid, 5 km×5 km	Attention Based ConvLSTM
Liao et al. [124]	New York	Taxi, Wetter, Feiertage	01.07.2014 – 30.07.2016	1 h	32×32-Grid, 200 m×400 m	ST-ResNet, FCL-Net: CNN bzw. ConvLSTM
Vanichrujee et al. [125]	Bangkok	Taxi	01.01.2016 – 30.06.2016	1 h	POIs Radius 200 m	LSTM,GRU, XGBoost
Tong et al. [126]	Peking Hangzhou	DiDi, Wetter, Events, POIs	23.02.2016 – 14.04.2016	1 h	k. A.	HA, MC, ARIMA, GBRT, HP-MSI, LinUOTD

Ein direkter Vergleich der vorgestellten Methoden ist auf Grund unterschiedlicher Datensätze, Diskretisierungen und Fehlermaße nur eingeschränkt möglich. Jedoch lässt sich verallgemeinert aus der Literaturrecherche zusammenfassen:

- **Datenmenge:** Der Umfang der verwendeten Datensätze variiert je nach Studie stark. Die abgedeckten Zeiträume reichen von Monaten bis hin zu mehreren Jahren. Gerade bei kurzen Zeiträumen ist kritisch zu hinterfragen, ob eine ausreichende Datenmenge für das Training und die Validierung der Modelle vorliegt.
- **Exogene Einflussfaktoren:** Am häufigsten werden Wetterdaten als zusätzliche Eingangsdaten verwendet. In der Mehrzahl der Studien kann jedoch damit keine wesentliche Verbesserung der Vorhersage erreicht werden. Des Weiteren werden zeitlich-semantische Informationen wie Tageszeit und Wochentag als zusätzliche Parameter in mehreren Modellen verwendet. Diese zeigen, je nach Verfahren, einen positiven Einfluss. Weitere Studien fokussieren sich auf den Zusammenhang zwischen Veranstaltung und engl. point of interest (POI) und können damit lokal bessere Ergebnisse in der Vorhersage erreichen.
- **Räumliche Diskretisierung:** Bei der räumlichen Auflösung des jeweils untersuchten Gebiets unterscheiden sich die Studien stark. Die verwendeten Zellengrößen reichen von 153 m bis zu 5 km. Hierbei sind besonders kleine räumliche Diskretisierungen als kritisch einzuschätzen. Es ist zu erwarten, dass bei derart kleinen Diskretisierungen selbst bei insgesamt hohen Fahrgastzahlen wie in New York nicht genügend Daten pro Zeitreihe zur Verfügung stehen. Anhand der angegebenen Fehlermaße lässt sich in den meisten Studien nicht erkennen, ob das Modell auch sinnvolle Vorhersagen tätigt. Beispielsweise würde ein Modell, das nur Werte nahe Null vorhersagt, in einem derartigen Fall gute Fehlermaße erreichen, obwohl die Vorhersage unbrauchbar ist.
- **Zeitliche Diskretisierung:** In den meisten Studien beträgt der Prognosehorizont 60 min, ohne eine nähere Begründung dafür zu nennen. Ähnlich wie bei einer zu kleinen räumlichen Diskretisierung sind die Ergebnisse von Studien mit kleinen Prognosehorizonten kritisch zu hinterfragen. Auch an dieser Stelle besteht die Vermutung, dass die gezeigten Modelle in Wirklichkeit unbrauchbare Prognosen liefern.
- **Methoden:** Die aktuell am häufigsten verwendeten Methoden für die räumlich/zeitliche Vorhersage der Nachfrage in Ridesourcingsystemen sind LSTM und ConvLSTM. Im direkten Vergleich mit herkömmlichen Prognoseverfahren zeigen diese tendenziell leicht bessere Ergebnisse, aber auch herkömmliche Verfahren liegen hier in derselben Größenordnung. Der größte Vorteil in der Verwendung neuronaler Netze liegt in der geringeren Rechenzeit und der niedrigeren Komplexität bei der Vorverarbeitung der Eingangsdaten.

2.2.3 Rebalancingstrategien

Unter dem Begriff Rebalancing wird im Kontext von Ridesourcing-Systemen die bedarfsorientierte Umverteilung von Fahrzeugen verstanden. Durch eine asymmetrische Verteilung von Quell- und Zielorten in Ridesourcingsystemen entsteht ohne weiteren Ausgleich langfristig ein örtliches Ungleichgewicht von Angebot und Nachfrage [127, S. 10].

In herkömmlichen Taxisystemen liegt dieser Entscheidungsprozess bei dem einzelnen Fahrer. Dieser entscheidet in der Regel auf Basis persönlicher Erfahrung und individueller Einschätzung des Nachfrageaufkommens, wohin er sich nach dem Ende einer Fahrt begibt, um auf den nächsten Kunden zu warten. Als Entscheidungsunterstützung wurden in [92, 95, 128] sogenannte "Recommender Systeme" untersucht, welche Taxifahrern Orte vorschlagen, an denen zukünftig eine hohe Nachfrage zu erwarten ist. Systeme dieser Art bergen jedoch die Gefahr, dass diese selbst zu einem Ungleichgewicht von Angebot und Nachfrage

führen. Nämlich dann, wenn sich zu viele Fahrzeuge auf Grund der Empfehlung an Orten potenziell hoher Nachfrage sammeln.

Ein anderer Forschungsstrang setzt sich mit dem koordinierten Rebalancing von Fahrzeugen auseinander (Tabelle 2.2). Ähnlich wie bei der Fahrgastvermittlung werden hier durch eine zentrale Entscheidungsinstanz Rebalancing Aktionen vorgegeben. Durch diesen Ansatz kann im Gegensatz zu dem sonst selbstoptimierenden Verhalten ein globales Optimum für die Gesamtflotte bestimmt werden [129].

Tabelle 2.2: Literaturübersicht koordinierter Rebalancing Verfahren

Quelle	Jahr	Szenario	Rebalancing Intervall	Räumliche Diskretisierung	Prädiktiv	Methode(n)
Pavone et al. [129]	2012	-	k. A.	Stationsbasiert	○	ILP
Smith et al. [130]	2013	-	k. A.	Stationsbasiert	○	FFR
Miao et al. [131]	2016	San Francisco	10 bis 60 min	4×4-Grid 2,25×2,25 km	●	ILP, RHC
Spieser et al. [132]	2016	Singapur	15 min	k-means 30 Stationen	●	LP FFTVR
Zhang et al. [133]	2016	-	k. A.	Stationsbasiert	●	MILP RHC
Oda und Joe-Wong [15]	2018	New York	30 min	43×44-Grid 800×800 m	●	RHC, DQN
Wallar et al. [134]	2018	New York	30 s	Isochron-Voronoi	○	ILP
Chuah et al. [135]	2018	Singapur	1 min	k-means	○	LP
Xu et al. [136]	2018	New York	5 bis 15 min	Grid (997 Zellen)	○	MILP
Albert et al. [137]	2019	San Francisco	k. A.	k-means	○	DFR, FFR
Dandl et al. [14]	2019	New York	5 bis 60 min	Grid 0,34 bis 2,7 km	●	ILP, RHC
Ruch et al. [12][138]	2019	San Francisco Chicago Zürich	k. A.	k-means	○	MFAR FFR
Tsao et al. [139]	2019	San Francisco	15 min	k-means ($k=25$)	●	ILP, RHC
Mao et al. [127]	2020	New York	15 min	NYC Taxisektoren	●	RL
Deng et al. [140]	2020	New York	100 s	NYC Taxisektoren	○	RL

Das sich daraus ergebende Optimierungsproblem kann nach unterschiedlichen Zielgrößen ausgerichtet sein. In der Regel handelt es sich dabei um lineare Optimierungsprobleme (LPs). Deren Formulierung erfordert eine Diskretisierung von Angebot und Nachfrage in Raum und Zeit. Das Ziel der Optimierung ist dabei in der Regel die Minimierung des lokalen Ungleichgewichts von Angebot und Nachfrage und lässt sich um weitere Zielkriterien erweitern (Bsp. minimale Rebalancingdistanz [129], maximaler Gewinn [15]). Weiter lassen sich die in der Literatur vorhandenen Ansätze in prädiktive und reaktive Rebalancing-Methoden unterteilen. Prädiktive Ansätze beziehen in ihre Entscheidung Prognosen (Abschnitt 2.2.2) des zukünftigen Systemverhaltens mit ein. Reaktive Ansätze nutzen für die Optimierung lediglich Informationen des aktuellen bzw. vergangener Zeitschritts/e.

Reaktive Rebalancing Ansätze

Pavone et al. [129] stellen in ihrer Arbeit eine reaktive, zeit-invariante Methode engl. feedforward fluidic optimal rebalancing policy (FFR) vor, die das Ungleichgewicht von Fahrzeugen an Stationen in Echtzeit durch

Lösung eines engl. integer linear problem (ILP) ausgleicht. Spieser et al. [132] erweitern den FFR-Ansatz in ihrer Arbeit und berücksichtigen auch den zeitlich variablen Einfluss des Nachfrageverlaufs (engl. feed-forward time-varying rebalancing policy (FFTVR)). Auch Albert et al. [137] und Ruch et al. [138] verwenden die FFR-Methode in ihrer Simulationsstudie für San Francisco, Chicago und Zürich und vergleichen sie mit eigenen Rebalancing Strategien.

Die von Ruch et al. [138] vorgestellte "+1 Methode" basiert auf der Annahme, dass in Gebieten mit hoher Nachfrage auch zukünftig weitere Abfahrten stattfinden werden. Wenn möglich, wird nach dieser Strategie ein weiteres freies Fahrzeug zum Startort einer Kundenfahrt geschickt, sobald die zugehörige Anfrage einem anderen Fahrzeug zugewiesen wurde. Im Vergleich zur Methode FFR [129] werden mit der "+1 Methode" geringere Wartezeiten für Kunden erreicht, jedoch bei einer höheren Fahrdistanz der Fahrzeugflotte.

Prädiktive Rebalancing Ansätze

Prädiktive Rebalancing Ansätze basieren in der Regel auf einer modell-prädiktiven Regelung (engl. model predictive control (MPC)). Bei einer MPC wird die Zielfunktion über mehrere Zeitschritte in der Zukunft optimiert und das Ergebnis der Optimierung für den aktuellen Zeitschritt als Sollwertvorgabe vom Regler übernommen [141, S. 76–77].

Miao et al. [131] zeigen, dass mit einem Mehrziel-Optimierungsverfahren in Form eines MPC-Ansatzes die Effizienz des Taxiverkehrs in San Francisco gesteigert werden kann. Zielgrößen der Optimierung sind dabei die Gesamt-Leerfahrt-Strecke der Fahrzeugflotte, sowie das lokale Gleichgewicht von Angebot und Nachfrage. Als Nebenbedingung berücksichtigt der Ansatz eine Vorhersage des Fahrtziels auf Basis historischer OD-Matrizen. Die Ergebnisse der Studie zeigen am Beispiel von San Francisco, dass durch die gewählte Rebalancing Strategie die durchschnittliche Gesamt-Leerfahrts-Strecke um 52 % reduziert und das Verhältnis zwischen Angebot und Nachfrage um bis zu 45 % verbessert werden kann.

Oda und Joe-Wong [15] wählen als Zielfunktion ihres MPC-Ansatzes die Maximierung des Gesamtgewinnes. Dazu umfasst die Zielfunktion die gewichtete Summe abgelehnter Anfragen abzüglich der gesamten Rebalancingkosten. Ein Prognosemodell in Form eines neuronalen Netzes dient dabei zur Vorhersage der zukünftigen lokalen Nachfrage. Eine groß angelegte Simulationsstudie (2,8 Millionen Fahrten und 8000 Fahrzeuge) zeigt, dass diese Strategie die Ablehnungsrate und die durchschnittliche Wartezeit im Vergleich zu einer einfachen Heuristik auf lokaler Ebene senkt.

Dandl et al. [14] integrieren Vermittlungsstrategie und prädiktives Rebalancing in ein lineares Optimierungsmodell. Die verwendete Zielfunktion besteht aus vier Komponenten (Leerfahrt-Distanz, vermittelte Anfragen, erwartetes Nachfrage-/Angebots-Ungleichgewicht, Kundenwartezeit) und minimiert die Gesamtkosten des Flottenbetreibers. Die Autoren merken selbst kritisch an, dass das Modell sensitiv bezüglich der gewählten Parameter der einzelnen Kostenfunktionen ist. Die Vorhersage der Kundennachfrage erfolgt wie in [16, 113, 142] über ein Poisson-Modell. In einer Simulationsstudie am Beispiel von San Francisco wurden zudem die Einflüsse des Rebalancingintervalls und der Größe der räumlichen Diskretisierung untersucht. Die besten Ergebnisse wurden mit einer Zellgröße von 0,34 km×0,34 km erreicht. Die durchschnittliche Wartezeit konnte damit von 1,95 min auf 1,77 min reduziert werden. Eine Variation des Rebalancingintervalls zeigte keinen Effekt.

Weitere, an dieser Stelle nicht näher ausgeführte, prädiktive Rebalancing-Strategien können Tabelle 2.2 entnommen werden. Zusammenfassend lässt sich feststellen:

- Die Ergebnisse zeigen unabhängig voneinander, dass durch den Einsatz koordinierender Rebalancing Strategien die Effizienz und Servicequalität in Ridesourcing Systemen gesteigert werden kann.
- Hierbei zeigen besonders prädiktive Ansätze Vorteile gegenüber reaktiven Strategien.

- Häufig werden Vermittlungs- und Rebalancingstrategien kombiniert betrachtet. Eine differenzierte Betrachtung der Einzeleinflüsse fehlt.
- Häufig dient als Vergleichsgrundlage eine Strategie ohne Rebalancing, jedoch nicht das reale Verhalten von Taxifahrern.
- Der Einflussfaktor Verkehr wird in den meisten Studien vernachlässigt oder stark vereinfacht.
- Alle Studien gehen von einer konstanten Flottengröße aus und vernachlässigen den ebenfalls zeitlich invariablen Verlauf des Angebots.

2.2.4 Flottengröße

Für Fahrdienstunternehmen stellen die Kosten für die Anschaffung und den Betrieb (Fahrerlohn, Wartung und Verschleiß) der eingesetzten Fahrzeuge den Hauptteil der Kosten im Unternehmen dar (Unterkapitel 4.3). Aus betriebswirtschaftlicher Sicht ist deshalb die Frage nach der benötigten Anzahl an Fahrzeugen und deren Einsatzplanung von besonderer Relevanz. Gleichzeitig können durch die Anzahl an verfügbaren Fahrzeugen Kundenkriterien wie Wartezeit oder Verfügbarkeit direkt beeinflusst werden. Den daraus resultierenden Konflikt von hoher Flottenauslastung auf Betreiberseite und hoher Fahrzeugverfügbarkeit auf Kundenseite gilt es mit einer geeigneten Strategie zur Anpassung der Flottengröße bzw. Einsatzplanung zu lösen. Spieser et al. [143] leiten daraus zwei wesentliche Fragestellungen bei der Ermittlung der optimalen Flottengröße ab:

- **Minimale Flottengröße:** Wie viele Fahrzeuge werden mindestens benötigt, um die vorhandene Nachfrage dauerhaft bedienen zu können?
- **Performance-optimale Flottengröße:** Wie viele Fahrzeuge werden mindestens benötigt, um ein definiertes Maß an Servicequalität sicherzustellen (Wartezeit, Verfügbarkeit etc.)?

Minimale Flottengröße

Die theoretisch minimal benötigte Anzahl an Fahrzeugen lässt sich bei vollständig bekannter Nachfrage mittels bipartitem Matching bestimmen. Dabei wird ermittelt, wie viele Fahrzeuge benötigt werden, wenn alle Fahrten optimal in die Routen einzelner Fahrzeuge integriert werden. Da im Gegensatz zu vergleichbaren Fragestellungen in der Logistik- und Transportplanung die Nachfrage bei Ridesourcing-Systemen nicht vorab bekannt ist, kann diese Methode in der Regel nur rückblickend für vergangene Zeiträume angewandt werden. Ungeachtet dessen, zeigt eine derartige Analyse das theoretisch mögliche Optimum, bei vollständiger Kenntnis aller aktueller und zukünftiger Systemzustände.

So ermittelten Vazifeh et al. [13] am Beispiel New Yorks, dass durch eine optimale Fahrtvermittlung 40 % weniger Taxis eingesetzt werden müssten, ohne dass für Kunden daraus längere Wartezeiten entstünden. Dieses Potential reduziert sich nach [13] auf 30 %, wenn man, wie in der Realität, von einer unbekanntem zukünftigen Nachfrage ausgeht. Zu einem vergleichbaren Ergebnis kommen [144], indem sie mit Hilfe eines Netzwerkfluss-Modells zeigen, dass 72 % der aktuellen Flotte ausreichen würden, um die Nachfrage abzudecken.

Durch einen alternativen Ansatz ermitteln Spieser et al. [143] für die Stadt Singapur auf Basis der Warteschlangentheorie die Mindestanzahl an benötigten Fahrzeugen, um die Kundennachfrage nachhaltig bedienen zu können.

Performance-optimale Flottengröße

Des Weiteren wurde in Simulationsstudien [12, 14, 83, 143, 145, 146] gezeigt, welchen Einfluss die Flottengröße auf Kennzahlen wie Kundenwartezeit, Ablehnungsrate oder Fahrzeugverfügbarkeit darstellt.

Bischoff und Maciejewski [145] untersuchen am Beispiel Berlin, wie viele Fahrzeuge benötigt werden, um den Individualverkehr durch autonome Shuttles zu ersetzen. Dabei zeigen sie die Auswirkungen von möglichen Flottengrößen von 50 000 und 25 000 auf die Kennwerte Wartezeit und Flottenauslastung. Hörl et al. [83] zeigen in einer vergleichbaren Studie am Beispiel Zürich zusätzlich die zu erwartenden Kosten für den Flottenbetrieb in Abhängigkeit der Flottengröße. Klöppel [71] ermittelt am Beispiel eines Ride-Pooling-Systems in München und Singapur neben der benötigten Anzahl an Fahrzeugen zusätzlich die benötigte Fahrzeugkapazität.

Am Beispiel des Taxiverkehrs in Zürich, Chicago und San Francisco untersuchten Ruch et al. [12] ebenfalls mit einer Simulationsstudie den Einfluss verschiedener Flottengrößen auf die Effizienz von Vermittlungs- und Rebalancing-Strategien. In jeder der drei untersuchten Städte konnte gezeigt werden, dass durch den Einsatz optimierter Vermittlungs- und Rebalancingstrategien die Flottengröße reduziert werden kann, ohne dass daraus Nachteile in Bezug auf die Servicequalität zu erwarten sind. Für Zürich wurde gezeigt, dass mit der "+1 Methode" mit einer 53 %-Flotte eine um 2 % kürzere Wartezeit im Vergleich zur aktuellen Strategie erreicht werden kann. Die repräsentative Aussagekraft dieses Ergebnisses ist jedoch kritisch zu hinterfragen, da die für die Simulation verwendeten Eingangsdaten nur einen einzelnen Tag umfassen.

Zusammenfassend kann für die Optimierung der Flottengröße festgestellt werden:

- Die theoretische benötigte Mindestanzahl an Fahrzeugen kann retrospektiv durch die Methode bipartites Matching ermittelt werden.
- Die Mehrzahl der aufgeführten Studien untersucht den Einfluss der Flottengröße auf Basis von Leistungskennzahlen durch den Einsatz von Flottensimulationen.
- Mit Ausnahme von [13] gehen alle dem Autor bekannten Studien dabei in der Simulation von einer konstanten Anzahl an Fahrzeugen aus. Schwankungen im Angebotsverlauf, wie sie in der Realität zu beobachten sind, werden nicht berücksichtigt.
- In allen Anwendungsbeispielen wird deutlich, dass aktuelle Ridesourcing-Systeme Überkapazitäten aufweisen.
- Die Reduktion der Flottengröße stellt dabei ein wirksames Mittel dar, um die Effizienz von Ridesourcing-Diensten zu erhöhen und Kosten zu senken.

2.3 Ableitung der Themenstellung

In den vorherigen Abschnitten wurden wesentliche Grundlagen zur Funktionsweise und mögliche Ansätze zur Optimierung von Ridesourcing-Systemen vorgestellt. Der folgende Abschnitt greift die Ergebnisse der Literaturanalyse auf und zeigt vorhandene Forschungslücken auf. Im weiteren Verlauf werden daraus die zentralen Forschungsfragen dieser Arbeit definiert und der zu ihrer Beantwortung gewählte Lösungsansatz vorgestellt.

2.3.1 Forschungslücken im Stand der Technik

In Unterkapitel 2.2 wurden vier wesentliche Pfade zur Optimierung von Ridesourcing Systemen vorgestellt und mögliche Methoden und Ansätze diskutiert. Für jedes der vier genannten Teilprobleme existieren umfangreiche Vorarbeiten, welche die generelle Wirksamkeit und das jeweilige Potential der verwendeten Methode unterstreichen. Trotz der umfangreichen Vorarbeiten und der hohen Dynamik auf diesem Wissensgebiet gibt es weiteren Forschungsbedarf bei der Anwendung dieser Methoden in realitätsnahen Szenarien. Dies umfasst dabei vor allem folgende Forschungslücken und Kritikpunkte am aktuellen Stand der Technik, welche im Rahmen dieser Arbeit adressiert werden sollen:

Vermittlungsstrategien

Das Potential unterschiedlicher Ansätze bei der Fahrgastvermittlung ist in der Literatur, wie in Abschnitt 2.2.1 dargestellt, eine bereits vielfach untersuchte Fragestellung. Ein Großteil der Studien basiert dabei auf den öffentlichen Taxi-Datensätzen aus New York [147] und San Francisco [148]. Ein Nachteil dieser Datensätze ist der Umstand, dass darin nur Informationen bezüglich durchgeführter Kundenfahrten enthalten sind. Sie enthalten keine Informationen über das Leerfahrtverhalten der Fahrzeuge, was eine Einschränkung darstellt. In der Folge können auf Grundlage der Daten keine Vergleichswerte zu den in Realität vorherrschenden Wartezeiten und Vermittlungsstrategien ermittelt werden. Die genannten Studien nutzen deshalb einfache Heuristiken statt des realen Systemverhaltens, um die Wirksamkeit der vorgestellten Methoden zu bewerten. Trotz der umfangreichen Forschungsarbeit auf diesem Gebiet ist deshalb nicht abschließend geklärt, wie hoch das Verbesserungspotential alternativer Vermittlungsmethoden im Vergleich zu dem realen Systemverhalten ist.

Nachfrageprädiktion

Im Bereich der Prädiktion von Angebot und Nachfrage (Abschnitt 2.2.2) wurde bereits in einer Vielzahl an Veröffentlichungen gezeigt, dass eine räumlich-zeitliche Vorhersage der Kundennachfrage auf Basis historischer Daten in Ridesourcing Systemen möglich ist. Ein besonderes Augenmerk liegt dabei aktuell auf der Entwicklung neuronaler Netzstrukturen. Auf Grund fehlender Beschreibungen in einzelnen Veröffentlichungen muss jedoch kritisch hinterfragt werden, ob für zeitlich kurze und räumlich fein aufgelöste Diskretisierungen tatsächlich sinnvolle Vorhersagen erreicht werden. Andere Studien verwenden, ohne weitere Begründung, übereinstimmend ein einstündiges Vorhersageintervall (Tabelle 2.1). Einzelne Studien konnten zeigen, dass die Genauigkeit der Vorhersage durch zusätzliche Eingangsdaten (z. B.: Veranstaltungen [149–151], Wetter [118, 124]) gesteigert werden kann. Ob sich diese Erkenntnisse auch auf andere Szenarien mit möglicherweise abweichendem Nutzerverhalten übertragen lassen, muss jedoch weiter untersucht werden. Es wird an dieser Stelle außerdem kritisiert, dass sich der überwiegende Teil der Studien ausschließlich auf die Vorhersagemethode selbst konzentriert, ohne dabei Anforderungen (Prognosehorizont, räumliche und zeitliche Diskretisierung) für den Einsatz in Vermittlungs- und Rebalancingstrategien zu berücksichtigen. Als Ausnahmen sind hierbei explizit [15, 127, 139] zu nennen.

Rebalancing

Abschnitt 2.2.3 zeigt das Potential prädiktiver, koordinierter Rebalancingstrategien in Bezug auf die Steigerung der Effizienz und Servicequalität in Ridesourcing Systemen. Kritisch ist an dieser Stelle jedoch festzustellen, dass die Mehrzahl der genannten Veröffentlichungen nicht zwischen Vermittlungs- und Rebalancingstrategie differenzieren, sondern diese kombiniert betrachten. Falls doch, wird die Wirksamkeit der jeweiligen Rebalancingstrategie mit einem System ohne Rebalancing verglichen. Das heißt, Fahrzeuge warten nach Ende einer Kundenfahrt am Zielort, bis eine neue Anfrage vermittelt wird. Wie bereits bei der Vermittlungsstrategie angemerkt, ist es an dieser Stelle wünschenswert, das reale Leerfahrtverhalten der Fahrzeuge als Referenz zu verwenden. Dies ist in den meisten Studien jedoch wegen der bekannten Einschränkungen der Datensätze nicht möglich.

Flottengröße

Das größte Potential zur Senkung der Betriebskosten stellt die optimierte Planung von Größe und Einsatz der Fahrzeugflotte dar. Der mit Ausnahme von [13] größte Kritikpunkt in bekannten Forschungsarbeiten ist aus Sicht des Autors dabei die Vernachlässigung von zeitlichen Schwankungen des Angebots an Fahrzeugen. Diese beeinflussen das Systemverhalten maßgeblich und dürfen deshalb für die Analyse von Ridesourcing-Systemen mit Fahrern nicht vernachlässigt werden.

Modellierung des Flottenverhaltens

Darüber hinaus können in den aufgeführten Studien in Übereinstimmung und Erweiterung zu Hörl et al. [83] folgende weitere allgemeine Schwächen bei der Modellierung und Simulation von Ridesourcing-Diensten identifiziert werden:

In der Mehrzahl der Studien werden Fahrten verworfen, falls diese in der Simulation zu hohe Wartezeiten aufweisen. Der Autor stimmt in dieser Ansicht Hörl et al. [83] zu und bekräftigt dessen Forderung, dass die Qualität von Vermittlungs- und Ridesourcing-Strategien immer auch im Hinblick auf die Erfüllbarkeit aller Kundenaufträge bewertet werden muss.

Einige Studien bilden das Flottenverhalten stark vereinfacht ab. Anstatt einer Modellierung des Straßennetzwerks und der zugehörigen dynamischen Verkehrssituation werden in diesen Fällen lediglich diskrete Fahrzeugzustände und gemittelte Reisezeiten berücksichtigt. Reale Randbedingungen wie Parkmöglichkeiten oder Standplätze werden in bekannten Forschungsarbeiten nicht berücksichtigt.

Untersuchungsszenarien

Simulationsszenarien bekannter Forschungsarbeiten decken in der Regel nur beschränkte Zeiträume (Ein Tag) oder ein Durchschnittsszenario eines längeren Beobachtungszeitraums ab. Da das Nachfrageverhalten in Ridesourcing Systemen sowohl im Wochen-, als auch im Jahresverlauf starken Schwankungen unterliegen kann, wäre es an dieser Stelle wünschenswert, langfristige Zeiträume zu untersuchen.

Bewertungskriterien

In der Literatur dienen vor allem Kundenkriterien und Effizienz Kennzahlen als Bewertungsgrundlage für den Vergleich verschiedener Flottenstrategien. Eine monetäre Betrachtung der Kosten des Flottenbetreibers ist nur in vereinzelt Arbeiten zu finden [12, 15].

Übertragbarkeit der Ergebnisse

Die Erkenntnisse bekannter Forschungsarbeiten stützen sich weitestgehend auf Anwendungsbeispiele aus nordamerikanischen und asiatischen Metropolen. Da sich deutsche bzw. europäische Städte sowohl in ihrer Siedlungsstruktur, als auch in den Nutzergewohnheiten und Regularien bei Ridesourcing Systemen wesentlich von nordamerikanischen und asiatischen Metropolen unterscheiden, besteht an dieser Stelle der Bedarf der Untersuchung von lokalen Szenarien.

2.3.2 Forschungsfrage

Wie in Unterkapitel 2.1 beschrieben, erfordern die aktuellen Entwicklungen auf dem Markt für Ridesourcing-Dienste von allen Mitbewerbern deutliche Effizienzsteigerungen, um langfristig konkurrenzfähig zu sein. Sowohl für den Münchner Taxiverkehr [142], als auch in anderen Beispielen [12, 13] wurde gezeigt, dass aktuelle, herkömmliche Taxisysteme unzureichend ausgelastet sind. In Unterkapitel 2.2 wurden vier wesentliche Optimierungspfade vorgestellt und Forschungslücken (Abschnitt 2.3.1) im Stand der Technik identifiziert.

Zentrale Fragestellung

Auf Basis der gesammelten Erkenntnisse leitet sich die zentrale Forschungsfrage dieser Arbeit ab, die am Beispiel des Münchner Taxiverkehrs erörtert werden soll:

Welche Maßnahmen sind geeignet, um die Effizienz von Ridesourcing-Systemen bei gleichzeitiger Einhaltung/Verbesserung der Servicequalität zu steigern?

Teilfragen

Aus dieser Fragestellung lassen sich folgende, weitere Teilfragen ableiten:

- Fahrgastvermittlung: Wie leistungsfähig sind aktuell in der Praxis eingesetzte Vermittlungsalgorithmen und welche Optimierungsmöglichkeiten gibt es?
- Rebalancing: Können Fahrzeuge durch Vorhersage der Kundennachfrage derart umverteilt werden, dass Anfahrtswege und -Zeiten reduziert werden können?
- Nachfrageprädiktion: Kann durch die Fusion mehrerer Datenquellen eine hohe räumliche und zeitliche Auflösung in der Vorhersage der Kundennachfrage erreicht werden?
- Flottengröße: Entspricht die Anzahl an derzeit in der Praxis eingesetzten Fahrzeugen der Anzahl tatsächlich benötigter Fahrzeuge? Wenn nicht, welche Optimierungspotentiale lassen sich identifizieren?
- Welchen Einfluss haben Vermittlungsstrategie, Rebalancingstrategie und Flottengröße auf Servicequalität und Betriebskosten der Fahrzeugflotte?

Abgrenzung

In Abgrenzung zu bekannten Arbeiten werden dabei die bestehenden Forschungslücken durch folgende Aspekte adressiert:

- Erstmals wird am Anwendungsbeispiel des Münchner Taxiverkehrs der Einfluss alternativer Vermittlungs- und Rebalancingstrategien im Rahmen einer Simulationsstudie untersucht.
- Im Gegensatz zu bekannten Arbeiten werden dazu auch die aktuellen Vermittlungs- und Rebalancingstrategien des Realsystems modelliert und als Vergleichsgrundlage herangezogen.
- In einem ganzheitlichen Ansatz werden dazu bekannte Methoden zur Lösung der genannten Teilprobleme aus dem Stand der Technik teilweise erweitert und miteinander kombiniert.
- In Erweiterung der Arbeit von Ruch et al. [19] wird zudem erstmalig das zeitlich variable Angebot an Fahrzeugen modelliert und dessen Einfluss untersucht.
- Entgegen bisherigen Studien deckt das Szenario dieser Arbeit den Untersuchungszeitraum eines ganzen Jahres ab und zeigt damit erstmalig die Wirksamkeit potenzieller Flottenstrategien unter saisonalen Nachfrageeinflüssen.

2.3.3 Vorgehen und Lösungsansatz

Das Vorgehen zur Beantwortung der genannten Forschungsfragen gliedert sich in vier Teilschritte: Der Datensammlung und -aufbereitung, einer Potentialanalyse des Münchner Taxiverkehrs, dem Aufbau und der Validierung eines Simulationsmodells zur Bewertung prädiktiver Flottenstrategien und einer abschließenden Simulationsstudie für das Anwendungsbeispiel des Münchner Taxiverkehrs.

Datensammlung und -aufbereitung

Grundlage dieser Arbeit bildet ein umfangreicher Bewegungsdatensatz einer Münchner Taxiflotte. Im Verlauf dieser Arbeit wurden dazu über den Zeitraum von fünf Jahren fortlaufend Daten des zentralen Vermittlungssystems einer Münchner Taxizentrale abgefragt, aufbereitet und analysiert [142]. Im Gegensatz zu anderen, öffentlich verfügbaren Datensätzen, enthält dieser Datensatz den gesamten Bewegungsverlauf der Fahrzeugflotte. Neben dem räumlich-zeitlichen Verlauf der Kundennachfrage lassen sich daraus auch Informationen bezüglich des Zustands einzelner Fahrzeuge im zeitlichen Verlauf extrahieren. Erstmals können damit auch der zeitlich-variable Verlauf des Angebots sowie das realitätsnahe Vermittlungs- und Rebalancingverhalten der Fahrzeugflotte abgebildet und validiert werden. Zusätzlich werden für die Untersuchung

externer Einflüsse auf das Nachfrageverhalten weitere Datensätze zu Veranstaltungen, Verspätungen im ÖPNV und dem Wetter erhoben und aufbereitet (Kapitel 3).

Potentialanalyse des Münchner Taxiverkehrs

In einer Analyse der vorhandenen Datenbasen (Kapitel 4) werden am Anwendungsbeispiel des Münchner Taxiverkehrs für den weiteren Verlauf der Arbeit relevante Zusammenhänge und Optimierungspotentiale erarbeitet. Die Analyse betrachtet dabei räumlich-zeitliche Dynamiken im Angebots- und Nachfrageaufkommen, den Einfluss externer Faktoren auf das Nachfrageverhalten, die Analyse wesentlicher Systemindikatoren, eine ausführliche Kosten- und Gewinnrechnung sowie die Auswirkungen der jüngsten Einschränkungen in Folge der COVID-19 Pandemie.

Simulationsmodell zur Bewertung prädiktiver Flottenstrategien

Ziel des weiteren Vorgehens ist die Entwicklung und Bewertung einer prädiktiven Flottenstrategie, die es ermöglicht, die Effizienz des aktuellen Systems, unter Beibehaltung bzw. Verbesserung der Servicequalität, zu steigern. Im Verlauf werden dazu Lösungsansätze bezüglich der in Unterkapitel 2.2 genannten Teilprobleme erarbeitet. Insbesondere wird in diesem Teil der Arbeit eine gewinnmaximierende, prädiktive Rebalancingstrategie und ein daraufhin optimiertes Modell zur Vorhersage des räumlich-zeitlichen Verlaufs der Kundennachfrage entwickelt.

Für die Bewertung möglicher Optimierungsmaßnahmen und Flottenstrategien wird das Münchner Szenario in einer agentenbasierten Simulation abgebildet. Diese Art der Modellierung erlaubt die größtmögliche Flexibilität, um das Verhalten einzelner Akteure zu bestimmen und Auswirkungen einzelner Verhaltensentscheidungen im globalen Zusammenhang zu bewerten. Hierzu wird auf die Vorarbeiten von Ruch et al. [19] zurückgegriffen und das Simulationsframework AMoDeus funktional um alle in dieser Arbeit entwickelten Flottenstrategien erweitert.

Simulationsstudie

In einer abschließenden Simulationsstudie wird die Leistungsfähigkeit der entwickelten Flottenstrategie im Vergleich zu Strategien aus dem Stand der Technik und des aktuellen Vermittlungs- und Rebalancing Verhaltens der Münchner Referenzflotte bewertet. Insgesamt werden dabei vier verschiedene Vermittlungsstrategien, drei verschiedene Rebalancingstrategien und acht verschiedene Flottengrößen für das Jahr 2019 untersucht und deren individueller Einfluss quantifiziert. Die Bewertung erfolgt dabei sowohl anhand von Kennwerten zur Bemessung der Servicequalität, als auch in Bezug auf Kosten und Umsatz der Fahrzeugflotte.

2.4 Aufbau der Arbeit

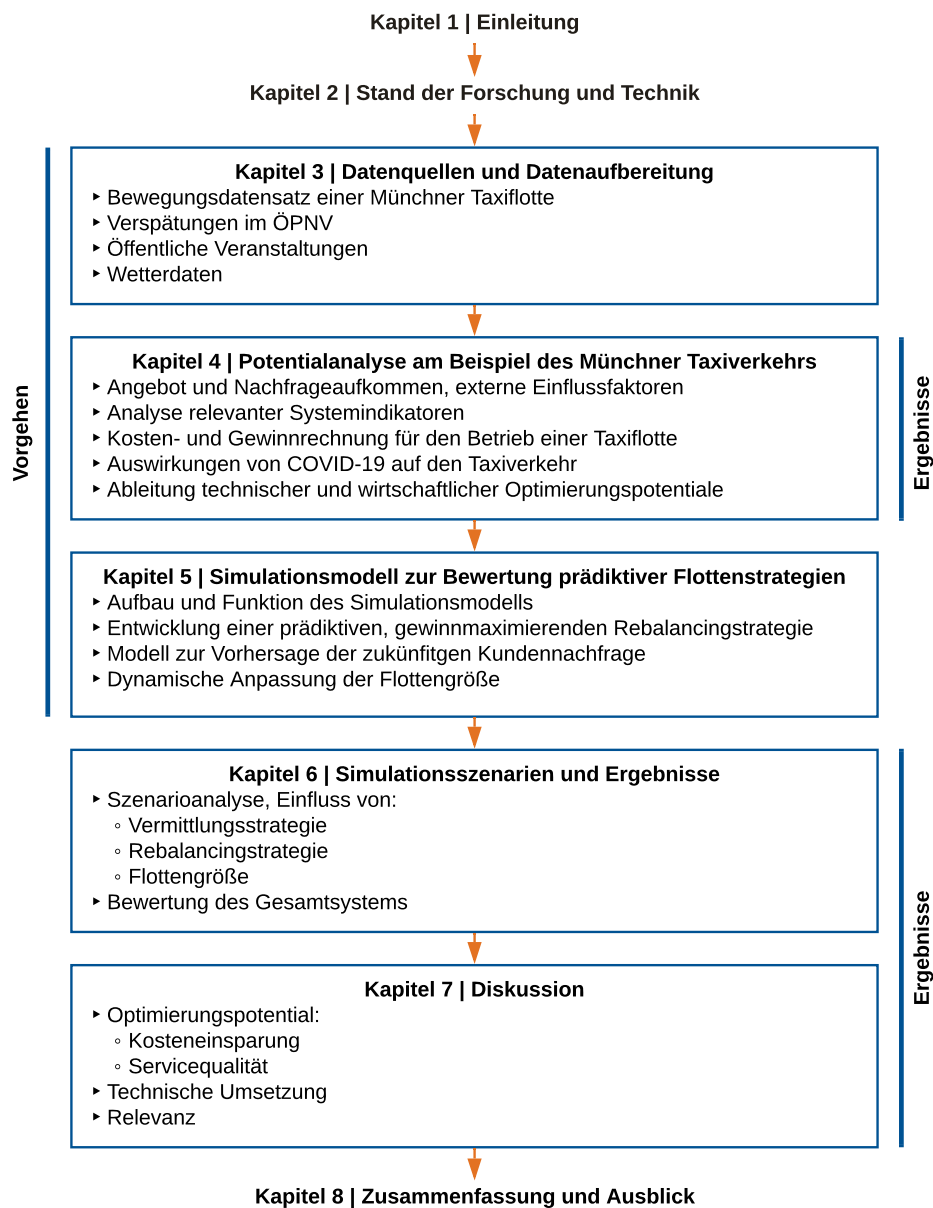


Abbildung 2.4: Aufbau der Arbeit

3 Datenquellen und Datenaufbereitung

Das folgende Kapitel beschreibt die in dieser Arbeit verwendeten Datenquellen sowie deren Aufbereitung. Primäre Datenquellen dieser Arbeit sind der Bewegungsdatensatz einer Münchner Taxiflotte, Verspätungsdaten des öffentlichen Nahverkehrs, Veranstaltungsdaten sowie Wetterbeobachtungen für den Großraum München. Das Vorgehen orientiert sich dabei an den Verarbeitungsschritten der Methode Knowledge Discovery in Databases (KDD) [152, S. 1–6].

3.1 Taxi Bewegungsdaten

Für den Zweck dieser Arbeit stellte eine Münchner Vermittlungszentrale vom 09.03.2015 bis 03.08.2020 Taxi-Bewegungsdaten bereit [142]. Der Datensatz umfasst die Bewegungsdaten von circa 490 Fahrzeugen – dies entspricht einem Anteil von circa 14,7 % aller 3400 zugelassen Taxis in München [153, S. 50]. In Summe wurden über den gesamten Auswertungszeitraum 52,9 Mio. Einzelfahrten, davon 11,6 Mio. Kundenfahrten mit einer Gesamtfahrdistanz von 151,4 Mio. km erfasst (Tabelle 3.1).

Tabelle 3.1: Zusammenfassung Taxi Bewegungsdaten

Beschreibung	Wert	Beschreibung	Wert
Erfassungszeitraum	09.03.2015-03.08.2020	Anzahl IDs	32 128 345
Anzahl Wochen	282	Anzahl Fahrten	52 960 383
Anzahl Streckensegmente	1 420 748 551	Anzahl Kundenfahrten	11 552 824
Aufzeichnungsrate Fahrzeugposition in s	18,06	Gesamte Fahrtstrecke in km	151 399 961
Max. gleichzeitig aktive Fahrzeuge	423	Besetzte Fahrtstrecke in km	83 917 083

Rohdaten

Alle Fahrzeuge der untersuchten Flotte sind mit einer Telematikeinheit ausgestattet und senden in regelmäßigen Abständen (~18,06 s) Daten über ihre aktuelle Position, Geschwindigkeit und ihren Vermittlungsstatus an den Vermittlungsserver der Taxizentrale. Die Telematikeinheit ist direkt mit dem Taximeter verbunden. Es werden somit auch Fahrten erfasst, die nicht über die Taxizentrale selbst vermittelt wurden (Bsp.: Direkteinsteiger, vermittelte Fahrten anderer Vermittlungs-Apps etc.). Die Bewegungsdaten werden in regelmäßigen Zeitabständen direkt über eine Schnittstelle des Vermittlungssystems abgefragt und zur weiteren Analyse und Aufbereitung in einer relationalen PostgreSQL [154] Geodatenbank gespeichert [142]. Diese verfügt über eine PostGIS [155] Erweiterung, die georeferenzierte Abfragen ermöglicht.

Die übermittelten Rohdaten beinhalten Streckensegmente einzelner Fahrzeuge. Eine Übersicht der erhaltenen Datenfelder ist in Tabelle 3.2 gezeigt. Aus Datenschutzgründen wechselt die ID einer Fahrt mit Beginn und Ende einer Auftragsfahrt. Die Bewegung eines einzelnen Fahrzeuges und damit das Verhalten eines einzelnen Fahrers kann so nicht über einen längeren Zeitraum nachvollzogen werden.

Tabelle 3.2: Übersicht Datenfelder Taxi Bewegungsdaten

Datenfeld	Beschreibung
ID	Anonymisierte Fahrt ID
STATUS	Vermittlungsstatus des Fahrzeuges
ZEITPUNKT	Zeitpunkt Eintreffen am Zielort des Segments
SEKUNDEN	Zeitdifferenz zwischen Abfahrts- und Zielort des Segments
METER	Entfernung zwischen Abfahrts- und Zielkoordinaten in m
ABFAHRT	Position des Abfahrtspunktes (WGS84)
ZIEL	Position des Zielpunktes (WGS84)
FAHRZIEL	Endgültiges Ziel der Kundenfahrt (WGS84)

Datentransformation und -Filterung

Zur weiteren Verwendung des Datensatzes werden die gespeicherten Rohdaten in einem nachgelagerten Prozess aufbereitet, transformiert und aggregiert. Dazu werden die einzelnen Fahrsegmente zu Einzelfahrten zusammengefasst und aus den Vermittlungszuständen einzelner Fahrzeuge die Zusammensetzung der Gesamtflotte bestimmt.

Fahrten

Auf Basis der erfassten Streckensegmente werden Fahrtabschnitte gemäß der in (Tabelle 3.3a) dargestellten Kategorien zusammengefasst und fortan als einzelne Fahrten betrachtet. Eine Fahrt beschreibt nach dieser Aggregation also immer eine bestimmte Aktion, die durch das Taxi ausgeführt wird (Bsp. Anfahrt zum Kunden oder Rückfahrt zum Warteplatz). Zusätzlich werden aus den Rohdaten weitere Metadaten (Start- und Endzeitpunkte, Start- und Endkoordinaten, Fahrzeit, Distanz, Kosten (Tabelle 4.4)) und der geschätzte Umsatz gemäß [156] berechnet und in einer Datenbanktabelle zur weiteren Analyse gespeichert. Zusätzlich wird der Datensatz um Datenfehler bereinigt. Hierzu werden die in Tabelle 3.3b genannten Filterkriterien angewendet. In Summe werden dadurch 8,7 % der extrahierten Fahrten auf Grund unplausibler Werte oder einer unzureichenden Zahl an Datenpunkten herausgefiltert und fortan nicht mehr berücksichtigt.

Tabelle 3.3: Datentransformation und Filterung

(a) Fahrtypen aggregierter Fahrten		(b) Filterkriterien und Anteil gefilterter Fahrten	
Status	Beschreibung	Filterkriterium	Anteil
Approach	Anfahrt zu einem Kundenauftrag	Weniger als sechs GPS-Punkte	5,3 %
Occupied	Besetzt mit einem/mehreren Kunden	Fahrdistanz \leq 250 m	4,3 %
Rebalancing	Rückfahrt zum nächsten Warteplatz	Fahrdistanz \geq vierfache Luftliniendistanz	2,0 %
Idle	Wartend am Warteplatz	Fahrdistanz \geq 100 km	0,05 %
Waiting at pickup	Wartend auf Kunden am Abholstandort	Fahrdauer \leq 60 s	2,1 %
		Durchschnittsgeschwindigkeit $\geq 35 \frac{\text{m}}{\text{s}}$	0,02 %
		Alle Kriterien kombiniert	8,7 %

Flottenstatus

Der Flottenstatus gibt Aufschluss über die Zusammensetzung der Vermittlungszustände der Fahrzeugflotte zu einem bestimmten Zeitpunkt – Wie viele Fahrzeuge befinden sich zum Zeitpunkt X im Status Y? (Abbildung 4.11). Hierzu wird in einem weiteren Transformationsschritt zu diskreten Zeitpunkten der aktuelle Status aller Fahrzeuge bestimmt und gemäß den in 3.3a genannten Kategorien zusammengefasst. Das Diskretisierungsintervall beträgt hierfür 5 min.

Bekannte Einschränkungen

Das für die Vermittlung und Datenerfassung verbaute Telematiksystem der Taxizentrale kann durch den Fahrer manuell abgeschaltet werden. In diesem Fall werden keine Bewegungsdaten an den Vermittlungsserver übertragen und sind somit nicht im Datensatz enthalten. Des Weiteren werden durch die manuelle Abschaltung Fehler bei der Betrachtung von Einzelfahrten induziert. Als Resultat können für betreffende Fahrten fälschliche Start-/Zielorte und Fahrdistanzen bzw. -dauern angenommen werden.

In Expertengesprächen wurde berichtet, dass manche Taxifahrer das System gerade in nachfragestarken Zeiten abschalten, weil sie in dieser Zeit genügend Aufträge über Direktanrufe oder andere Vermittlungskanäle erhalten und zusätzliche Anfragen über die Taxizentrale als störend empfinden. Die genaue Anzahl an Fahrern mit diesem Verhalten konnte im Rahmen dieser Arbeit nicht näher ermittelt werden. Der Einfluss auf die Ergebnisse dieser Arbeit ist jedoch als gering einzuschätzen, weil sich dadurch Beobachtungen bei Angebot und Nachfrage gleichermaßen reduzieren.

3.2 ÖPNV Verspätungen

Um den Einfluss von Ausfällen und Verspätungen auf das Nachfrageverhalten im Taxiverkehr zu untersuchen (Abschnitt 4.1.4), wurden im Rahmen dieser Arbeit im Zeitraum zwischen 06.05.2019 und 10.06.2021 Echtzeit-Abfahrtsinformationen von S- und U-Bahn in München mittels Web-Abfrage erhoben. Tabelle 3.4 zeigt eine Übersicht des erhobenen Datensatzes. So konnten für die Analyse insgesamt 12,24 Mio. Abfahrten von 15 Linien an 223 Haltestellen ausgewertet werden. Für eine ausführliche Beschreibung und Analyse des Datensatzes sei auf die entsprechende Veröffentlichung [157] verwiesen.

Tabelle 3.4: Überblick ÖPNV Verspätungsdatensatz aus [157]

Beschreibung	S-Bahn	U-Bahn
Anzahl Stationen	125	98
Anzahl Linien	7	8
Beobachtungen	4 566 500	7 683 766
Mittlere Verspätung in min	1,168	0,837
Maximale Verspätung in min	354	1431
Ohne Verspätung	2 131 051	3 890 972
Verspätungen [1,3[min	1 601 061	2 894 220
Verspätungen [3,6[min	618 356	759 421
Verspätungen [6,∞[min	216 032	139 153

3.3 Öffentliche Veranstaltungen

Der in dieser Arbeit verwendete Veranstaltungskalender (Abschnitt 4.1.4, [158]) wurde als Auszug des öffentlichen Veranstaltungsverzeichnisses [159] von der Landeshauptstadt München für diese Arbeit zur Verfügung gestellt. Der Datensatz umfasst 126 419 Veranstaltungen für den Großraum München im Zeitraum von 01. Januar 2014 bis 31. August 2019 mit den in Tabelle 3.5 aufgeführten Datenfeldern. Im Rahmen der Datenaufbereitung werden zur Kategorisierung des Veranstaltungsortes zusätzliche Datenfelder generiert. Mittels Reverse-Geo-Coding werden hierzu zusätzlich die Geokoordinaten des Veranstaltungsortes, sowie die Art des Veranstaltungsortes mit Hilfe des Tools MAGIS [160] auf Basis von OpenStreetMap Daten [161] bestimmt. Abbildung 3.1 gibt einen Überblick der häufigsten Veranstaltungsorte/-Kategorien.

Tabelle 3.5: Übersicht Datenfelder Veranstaltungsdatensatz

Datenfeld	Beschreibung
termin	Beginn der Veranstaltung
event_name	Veranstaltungsname
eintrag_name	Name des Veranstaltungsortes
adresse	Adresse des Veranstaltungsortes
plz	Postleitzahl des Veranstaltungsortes
ort	Ort der Veranstaltung
osm_amenity	OSM Kategorie des Veranstaltungsortes
geom	Geokoordinaten des Veranstaltungsortes




Abbildung 3.1: Links: Top 10 Veranstaltungsorte, Rechts: Top 10 OSM-Kategorien des Veranstaltungsdatensatzes

3.4 Wetter

Die in dieser Arbeit verwendeten Wetterbeobachtungen (Abschnitt 4.1.4) wurden vom Meteorologischen Institut der LMU München [162] zur Verfügung gestellt. Der Datensatz enthält für den Zeitraum zwischen 01.01.2015 und 31.12.2019 minütliche Messwerte zu Temperatur, aktuelle Niederschlagsmenge und der kumulierten Sonnenscheindauer für die Messstation München, Theresienstraße 37. Eine weitere Datenverarbeitung und -Filterung ist auf Grund der vorhandenen Datenqualität nicht nötig.

4 Potentialanalyse am Beispiel des Münchner Taxiverkehrs

In diesem Kapitel wird das Optimierungspotential in Ridesourcing-Systemen am Beispiel des Münchner Taxiverkehrs analysiert und bewertet.

Der vorliegende Mobilitätsdatensatz einer Münchner Taxiflotte (Kapitel 3) wird in diesem Abschnitt hinsichtlich zeitlicher, räumlicher und externer Einflussfaktoren untersucht und deren Wirkungen auf das Angebot- und Nachfrageaufkommen dargestellt. Darüber hinaus werden für den operativen Betrieb relevante Systemindikatoren identifiziert und analysiert. In einem kurzen Exkurs wird im Rahmen der Datenanalyse gezeigt, welche Auswirkungen die globale COVID-19 Pandemie auf die Mobilitätsnachfrage zu Beginn der Pandemie aufweist.

Darauf aufbauend erfolgt im weiteren Verlauf des Kapitels die Bewertung des technisch-/wirtschaftlichen Potentials einer optimierten (prädiktiven) Flottenstrategie. Diese bildet die argumentative Grundlage des weiteren Vorgehens in dieser Arbeit.

4.1 Angebot- und Nachfrageaufkommen

4.1.1 Zeitliche Analyse

Zu Beginn der Datenanalyse wird der zeitliche Verlauf des Angebots- und Nachfrageaufkommens untersucht. Abbildung 4.1 zeigt die stündliche mittlere Anzahl an Fahrten (Nachfrage) und aktiven Fahrzeugen (Angebot), sowie deren 10. und 90. Quantil für den Auswertungszeitraum zwischen 09.03.2015 und 01.01.2020 (Langzeiteffekte in Bezug auf das Nachfrage- und Angebotsvolumen innerhalb des Auswertungszeitraums wurden untersucht. Es konnten keine signifikanten Effekte nachgewiesen werden). Es ist zu erkennen, dass sowohl der zeitliche Verlauf des Angebots als auch der Kundennachfrage einem regelmäßigen, zyklischen Muster folgt.

Saisonalitäten

Die Anzahl aktiver Fahrzeuge steigt von Mo.-Fr. nach dem Schichtwechsel (zwischen 04:00–06:00 Uhr) kontinuierlich auf das Tagesmaximum. Dieses wird im Intervall 09:00–10:00 Uhr erreicht. Die Anzahl an aktiven Fahrzeugen nimmt im weiteren Tagesverlauf kontinuierlich bis 22:00 Uhr ab. Nach einem kurzen Anstieg von 22:00–00:00 Uhr sinkt die Anzahl auf das Tagesminimum zwischen 05:00 und 06:00 Uhr. Samstags ist zu beobachten, dass das Tagesmaximum erst in den Abendstunden erreicht wird und das Angebot ansonsten auf einem niedrigen Niveau bleibt. An Sonn- und Feiertagen ist das Angebot an Fahrzeugen auf einem konstanten niedrigen Niveau.

Analog dazu kann für die Kundennachfrage beobachtet werden, dass diese ihr tägliches Minimum zwischen 04:00–05:00 Uhr morgens erreicht. Die Nachfragekurve steigt anschließend kontinuierlich an, bis sie zwi-

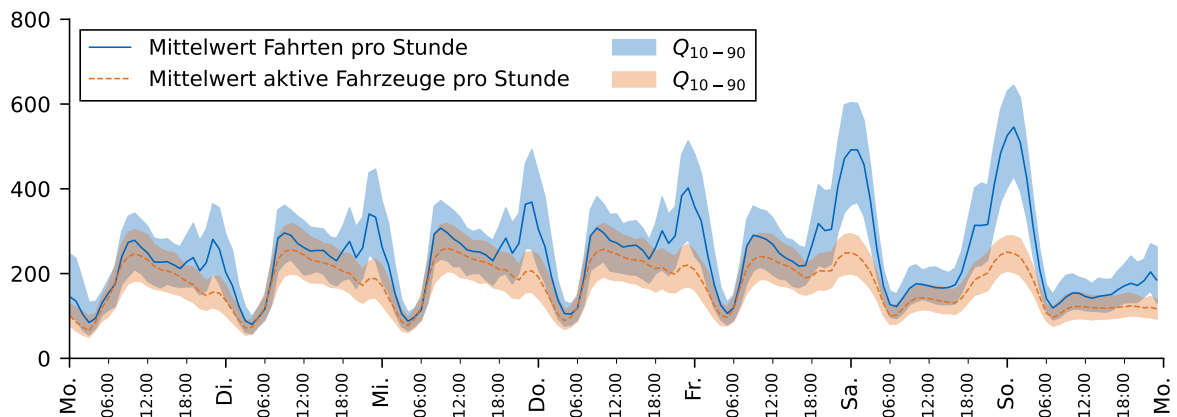


Abbildung 4.1: Zeitlicher Verlauf des Angebots- und Nachfrageaufkommens. Stündliche Mittelwerte, sowie 10. und 90. Quantil für den Auswertungszeitraum 09.03.2015-01.01.2020

sehen 08:00 und 09:00 Uhr ihren ersten Hochpunkt erreicht. Die Nachfrage sinkt im weiteren Tagesverlauf leicht ab und steigt anschließend auf ihr Tagesmaximum zwischen 22:00–00:00 Uhr – Freitags und Samstags zwischen 23:00–03:00 Uhr. Im direkten Vergleich der Wochentage (Abbildung 4.2) wird deutlich: Die Gesamtzahl an Fahrten steigt kontinuierlich von Montag bis Freitag an. Während der Nachfrageverlauf in der ersten Tageshälfte einen ähnlichen Verlauf zeigt, ist zu erkennen, dass die Nachfrage in der zweiten Tageshälfte im Verlauf der Woche zunimmt. Es kann angenommen werden, dass dieser Effekt auf die zunehmende Anzahl an Veranstaltungen und gesellschaftlichen Aktivitäten (Theater-, Restaurant-, Konzert- und Clubbesuche) im Wochenverlauf zurückzuführen ist.

An Wochenenden und Feiertagen kann in der ersten Tageshälfte eine gleichmäßige Nachfrage auf niedrigem Niveau beobachtet werden. Samstags steigt die Nachfrage in der zweiten Tageshälfte stark an und erreicht in der Nacht auf Sonntag zwischen 01:00–02:00 Uhr im Mittel den wöchentlichen Höchstwert von 545,73 Fahrten pro Stunde. Der nachfragestärkste Tag ist Freitag mit einem Anteil von 17,9 % der wöchentlichen Fahrten, der nachfrageschwächste Tag ist Sonntag mit einem Anteil von 8,8 %. Die für München gezeigten Ergebnisse bestätigen die vergleichbarer Studien in anderen Städten [163–167].

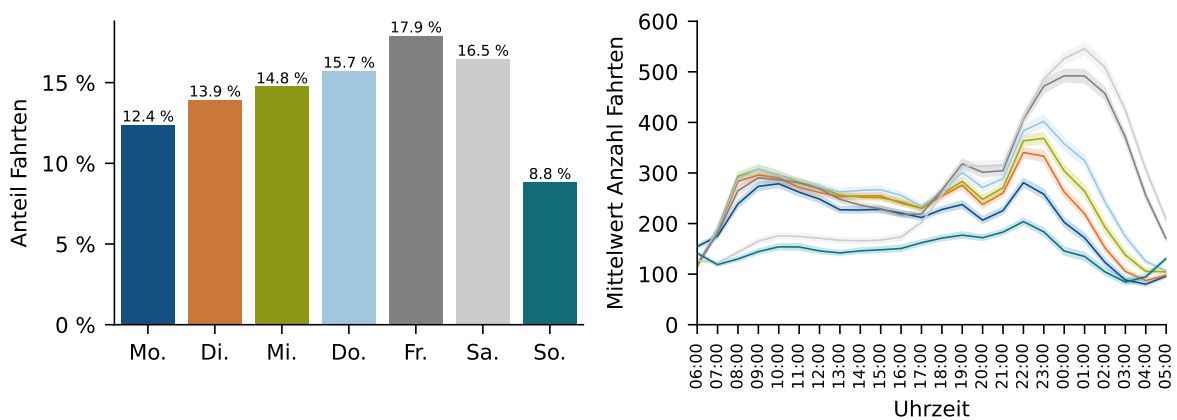


Abbildung 4.2: Links: Relativer Anteil Fahrten pro Wochentag. Rechts: mittlere, stündliche Anzahl an Fahrten pro Wochentag (Konfidenzintervall 0.95). Auswertungszeitraum: 09.03.2015-01.01.2020

Clusteranalyse

Neben täglich bzw. wöchentlich wiederkehrenden Mustern im Nachfrageverhalten, sind weitere Saisonalitäten im Jahresverlauf zu erwarten. Um deren Einfluss zu untersuchen, werden die wöchentlichen Zeitreihen einer Clusteranalyse unterzogen. Ziel ist es, innerhalb des 5-Jahres-Datensatzes Zeiträume zu identifizieren, die ein ähnliches charakteristisches Verhalten aufweisen. Als Clusterverfahren wird hierzu die Methode k-Means [168, 169] in der Implementierung für Zeitreihen [170] verwendet. Die Anzahl an Clustern, k , wurde iterativ bestimmt und beträgt im gezeigten Fall $k = 4$. Abbildung 4.3 zeigt den zeitlichen Verlauf der mittleren Nachfrage der Cluster und deren Konfidenzintervall. Von 248 untersuchten Wochen werden 108 dem Cluster C_3 (hellblau) zugeordnet. Der Nachfrageverlauf folgt dem zuvor beschriebenen, durchschnittlichen Verlauf und ist auf einem mittleren Niveau. Eine allgemein geringere Nachfrage kann für den Cluster C_1 in 65 Wochen beobachtet werden. C_0 (61 Wochen) zeigt im Vergleich zu C_3 an allen Tagen in der zweiten Tageshälfte eine deutlich höhere Kundennachfrage. C_2 zeigt in 14 von 248 Wochen eine stark erhöhte Kundennachfrage. Als Besonderheit kann hier auch eine atypische Nachfrage Samstags (1. Tageshälfte) und sonntags (ganztägig) beobachtet werden.

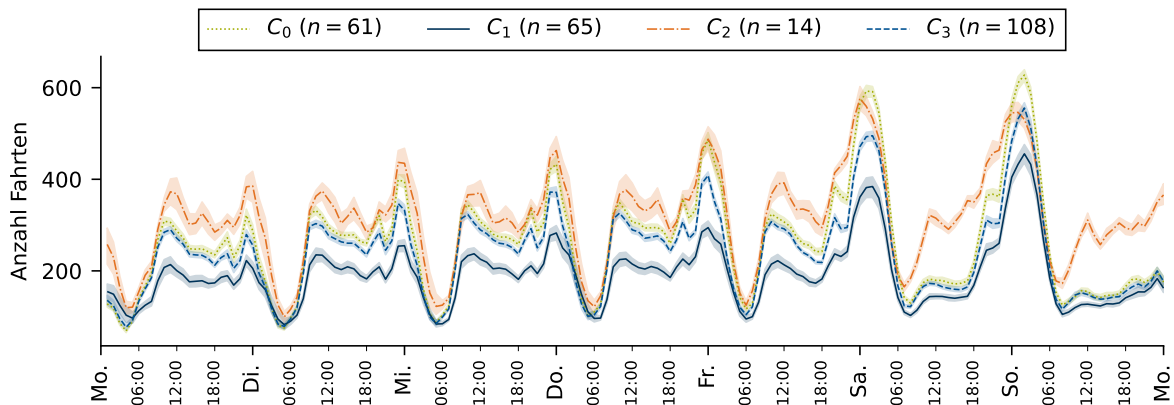


Abbildung 4.3: k-Means Clusteranalyse des wöchentlichen Nachfrageverlaufs ($k = 4$). Mittlere Anzahl an Fahrten, Konfidenzintervall ($c = 0,95$). Auswertungszeitraum: 09.03.2015-01.01.2020

Abbildung 4.4 zeigt die Summe der Kundenaufträge pro Woche für das Jahr 2019, sowie deren Zuordnung bezüglich der vorangegangenen Clusteranalyse. Diese lassen sich im Kontext saisonaler Ereignisse weitergehend interpretieren.




Abbildung 4.4: Kummulierte Anzahl an Fahrten pro Kalenderwoche in 2019. Zuordnung der Clusteranalyse aus Abbildung 4.3.

Das Münchner Oktoberfest, mit 6,3 Millionen Besuchern im Jahr 2019 das größte Volksfest der Welt [171], stellt die Stadt und deren öffentliches Verkehrssystem jedes Jahr Ende September vor eine logistische Herausforderung. Die erhöhte Nachfrage in den Kalenderwochen 39 und 40 und damit der Cluster C_2 lässt sich eindeutig darauf zurückführen.

Der ebenfalls überdurchschnittlich nachfragestarke Cluster C_0 kann in KW3, KW15 sowie KW48-KW51 beobachtet werden. Die Zeiträume dieser Beobachtungen überlappen sich ebenfalls mit Großveranstaltungen. So fanden von 14. bis 19. Januar (KW 3) die Weltleitmesse BAU (250.000 Besucher) [172], von 8. bis 14. April (KW 15) die weltweit größte Messe für Baumaschinen, bauma, (620.000 Besucher) [173] und von 26. November bis 31. Dezember das Winter-Tollwoodfestival (690.000 Besucher) [174] statt. Eine zusätzliche Nachfragesteigerung in der Vorweihnachtszeit ist nach [175] in Folge von Weihnachtsfeiern in Betrieben und Vereinen zu beobachten.

Betrachtet man die Zeiträume des nachfrageschwachen Clusters C_1 , ist zu erkennen, dass diese zum überwiegenden Teil in den Zeitraum der bayrischen Schulferien bzw. Wochen mit Brückentagen (KW 22,37) fallen. In diesen Zeiten herrscht eine insgesamt unterdurchschnittliche Kundennachfrage. Als Grund hierfür wird die insgesamt geringere Anzahl an öffentlichen Veranstaltungen, sowie ein insgesamt geringeres Mobilitätsaufkommen vermutet.

Die zeitliche Analyse des Angebots- und Nachfrageverhaltens zeigt, dass beide Verläufe wiederkehrende Muster aufweisen. Die an dieser Stelle identifizierten saisonalen Faktoren (Tag, Uhrzeit, Ferien, Großveranstaltungen) kommen als Prädiktoren für die Vorhersage der Kundennachfrage in Betracht und müssen im Rahmen der Modellentwicklung weiter untersucht werden.

4.1.2 Räumliche Analyse

Neben dem zeitlichen Einfluss auf das Nachfrageverhalten sollen im zweiten Schritt nun räumliche Abhängigkeiten analysiert werden. Dazu werden die Abfahrts- und Ankunftsorte mit Hilfe eines uniformen Rasters diskretisiert. Für die nachfolgenden Auswertungen wird das Rasterformat H3 [109] mit hexagonalen Zellen in der Auflösung 8 (Fläche: $0,74 \text{ km}^2$, Kantenlänge: 461 m) verwendet.

Abbildung 4.5 zeigt die räumliche Verteilung der Abfahrts- und Ankunftsorte in logarithmischer Farbskala. Es ist zu erkennen, dass sich sowohl Startpunkte (96,70 %), als auch Endpunkte (89,42 %) überwiegend innerhalb des Münchner Stadtgebiets (weiß) befinden. Die Verteilung der Start- und Zielorte konzentriert sich auf das Stadtzentrum rund um den Münchner Hauptbahnhof und die nördlichen Ausfallsstraßen im Stadtteil Schwabing. In Richtung der Stadtgrenzen nimmt die Anzahl an beobachteten Abfahrten ab. Neben dem Stadtzentrum zeigen außerdem die Münchner Messe am östlichen Stadtrand und der Flughafen München im Nord-Osten erhöhte Ankunfts- und Abfahrtszahlen. Im Gegensatz zu den Startorten zeigt sich, dass bei den Zielorten auch Gebiete innerhalb der angrenzenden Gemeinden häufiger auftreten.

Ein für des Taxigewerbe wichtiger Umsatzstandort ist der Flughafen München. Durch die Entfernung zum Stadtzentrum und die, je nach Ausgangspunkt vergleichsweise schlechte Anbindung an öffentliche Verkehrsmittel, stellt das Taxi für Geschäftsreisende eine zeitlich günstige und komfortable Alternative dar. Außerhalb der Betriebszeiten öffentlicher Verkehrsmittel ist der Flughafen nur per Auto erreichbar. Abbildung 4.6 zeigt die räumliche Verteilung der Startorte von Fahrten mit dem Ziel Flughafen (links) und die Zielorte von Fahrten mit dem Abfahrtsort Flughafen (rechts). Zur übersichtlicheren Darstellung werden Zellen mit weniger als 100 Fahrten nicht dargestellt.

Fahrten mit dem Ziel Flughafen starten vor allem aus dem Stadtzentrum, der Parkstadt Schwabing und der Messe München. Zielorte von Fahrten ab Flughafen sind, neben den bereits genannten Quellorten, an den Flughafen angrenzende Gewerbegebiete in Freising, Hallbergmoos oder Schwaig.

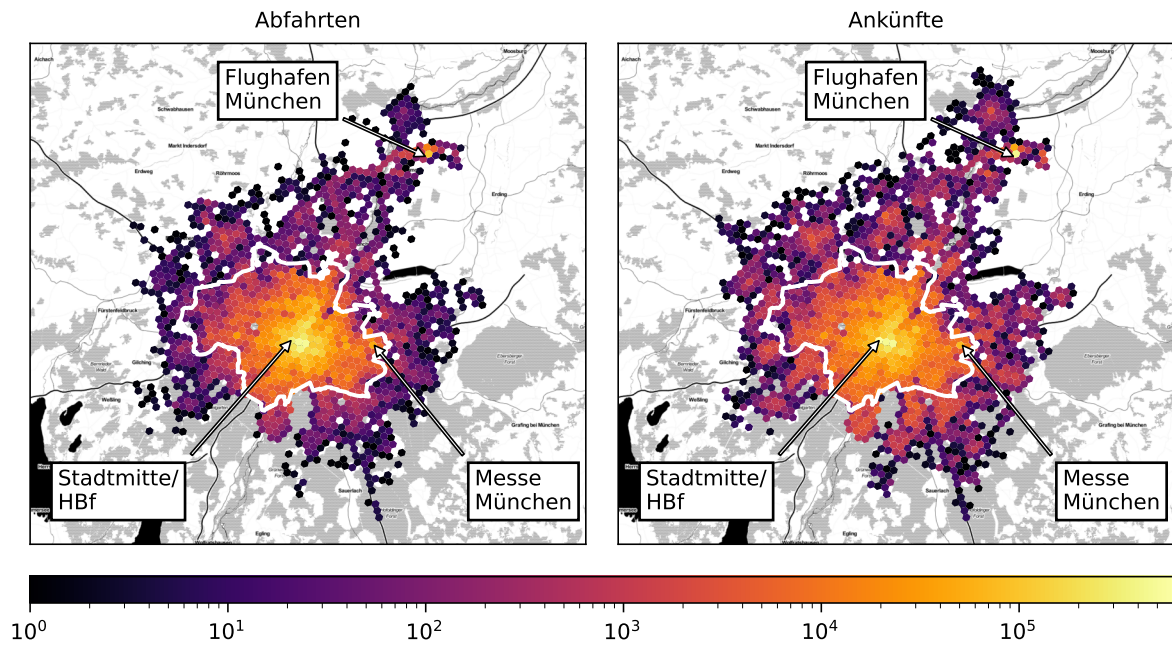


Abbildung 4.5: Heatmap Abfahrts- und Ankunftsorte im Auswertungszeitraum: 09.03.2015-01.01.2020 (Rasterformat H3 [109] - Auflösung 8, Karte: Stamen Design © ⓘ. Daten: OpenStreetMap, unter ODbL)

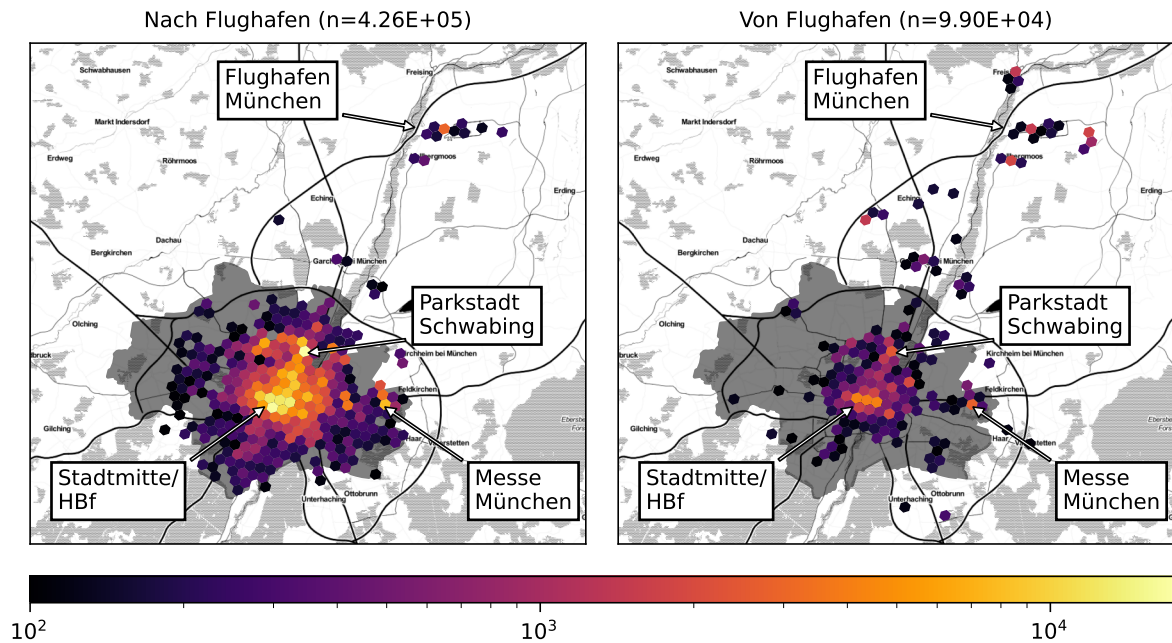


Abbildung 4.6: Heatmap Abfahrts- und Ankunftsorte von Fahrten zu/ab Flughafen München im Auswertungszeitraum: 09.03.2015-01.01.2020 (Rasterformat H3 [109] - Auflösung 8, Karte: Stamen Design © ⓘ. Daten: OpenStreetMap, unter ODbL))

Insgesamt wurden im Auswertungszeitraum 425 647 Fahrten (4,03 % aller Fahrten) mit dem Ziel- und 98 983 Fahrten (1,00 % aller Fahrten) mit dem Startort Flughafen registriert. Dieses Ungleichgewicht resultiert aus einem erheblichen Überangebot an Taxis am Münchner Flughafen. Dort konkurrieren neben Taxiunternehmen aus der Stadt auch Unternehmer aus dem Münchner Umland um lukrative Fahrten in das Stadtzentrum. Für Taxifahrer kann es hier zu Wartezeiten von mehreren Stunden kommen, bis sie in

der Warteschlange an vorderster Stelle stehen. Für Taxiunternehmer aus der Stadt – wie im Fall der untersuchten Testflotte – lohnt es sich deshalb in den meisten Fällen nicht, lange Wartezeiten am Flughafen in Kauf zu nehmen. Anstatt zu warten, kehren diese Fahrzeuge ohne Fahrgast wieder in die Stadt zurück. Aus diesem Grund kann die tatsächliche Kundennachfrage für den Flughafen auf Basis dieses Datensatzes nur unzureichend abgebildet werden, was auch im weiteren Verlauf dieser Arbeit berücksichtigt wird.

4.1.3 Räumlich-zeitliche Analyse

In den bisherigen Auswertungen wurden der örtliche und zeitliche Einfluss auf das Nachfrageverhalten stets getrennt voneinander betrachtet. Durch die Kombination beider Einflussgrößen lassen sich räumlich-zeitliche Abhängigkeiten im Nachfrageverhalten darstellen. Hierzu werden die Nachfrageverläufe jeder Auswertungszelle einer zeitlichen Clusteranalyse unterzogen. Für die Analyse werden alle Zellen aus dem Auswertungszeitraum einbezogen, deren mittleres stündliches Nachfrageaufkommen größer/gleich einer Fahrt pro Stunde entspricht (55 von 1607 Zellen). Für die Clusterbildung werden die einzelnen Zeitreihen zusätzlich auf den Wertebereich $[0; 1]$ normiert. Die Clusterbildung erfolgt analog zu Abschnitt 4.1.1 mit der Methode k-Means. Die Clusteranzahl $k = 5$ wurde iterativ bestimmt.

Abbildung 4.7 und 4.8 zeigen die Ergebnisse der räumlich-zeitlichen Clusteranalyse des Nachfrageverhaltens. Die Cluster C_0 bis C_5 weisen folgende Eigenschaften auf:

- C_0 – **Durchschnittscluster/Mischnutzung**: Der Nachfrageverlauf dieser Zellen folgt dem charakteristischen Nachfrageverlauf der Durchschnittswoche der Gesamtnachfrage (Abbildung 4.1). 25 von 55 Zellen werden diesem Cluster zugeordnet.
- C_1 – **Kliniken/Industriegebiet**: Charakteristisch für diesen Cluster sind die Nachfragespitzen Dienstag bis Freitag am späten Vormittag. Die Nachfrage pendelt sich in der zweiten Tageshälfte auf ein gleichmäßiges Niveau ein und zeigt einen zweiten Anstieg zwischen 18:00–20:00 Uhr. In den Bereich dieses Clusters fallen neben Wohngebieten das Gebiet um den Münchner Hauptbahnhof, einige große Kliniken (Klinikum Schwabing, Städtisches Klinikum der LMU, Heckscherklinik) und Ärztehäuser sowie Industriegebiete (Bsp. Euroindustriepark).
- C_2 – **Nachtclubs/Gastronomie**: Der zeitliche Verlauf des Clusters C_2 fällt durch eine niedrige Nachfrage an Werktagen und eine hohe Nachfrage am Wochenende auf. Die Nachfragespitzen werden jeweils in den frühen Morgenstunden zwischen 00:00–04:00 Uhr in den Nächten von Freitag auf Samstag und von Samstag auf Sonntag erreicht. Montags bis freitags befindet sich die Nachfrage auf einem niedrigen Niveau und erreicht auch dort ihr Maximum nachts. In den Gebieten dieser Zellen (Sonnenstraße, Ostbahnhof, Pasing und Giesing) herrscht eine hohe Dichte an Gastronomie, Bars und Clubs.
- C_3 – **Business/Messe/Flughafen**: Der Schwerpunkt der Aktivität in Cluster C_3 konzentriert sich auf die Wochentage Montag bis Freitag. Nachfragespitzen sind hier ähnlich zu C_1 vormittags und am frühen Abend zu erkennen. Im Gegensatz zu C_1 ist am Wochenende nur eine sehr geringe Nachfrage zu erkennen. In das Gebiet dieses Clusters fallen große Münchner Gewerbegebiete (Domagapark, Parkstadt Schwabing, Arabellapark), sowie die Messe und der Flughafen München.
- C_4 – **Mischnutzung**: Cluster C_4 erreicht sein Tagesmaximum montags bis freitags zwischen 11:30–12:30 Uhr. Nach einem Rückgang auf ein mittleres Niveau am Nachmittag steigt die Nachfrage in den späten Abendstunden unter der Woche zwischen 22:30–00:00 Uhr nochmals an. Die Aktivität beschränkt sich am Wochenende auf die Nacht von Samstag auf Sonn-

tag. Den Rest des Wochenendes bleibt sie auf einem niedrigen Niveau. In Gebieten dieses Clusters befinden sich neben größtenteils Wohngebieten die Hauptstandorte der Ludwig-Maximilians-Universität und der Hochschule München. Im westlichen Stadtteil Bogenhausen sind außerdem mehrere Botschaften und Konsulate angesiedelt.

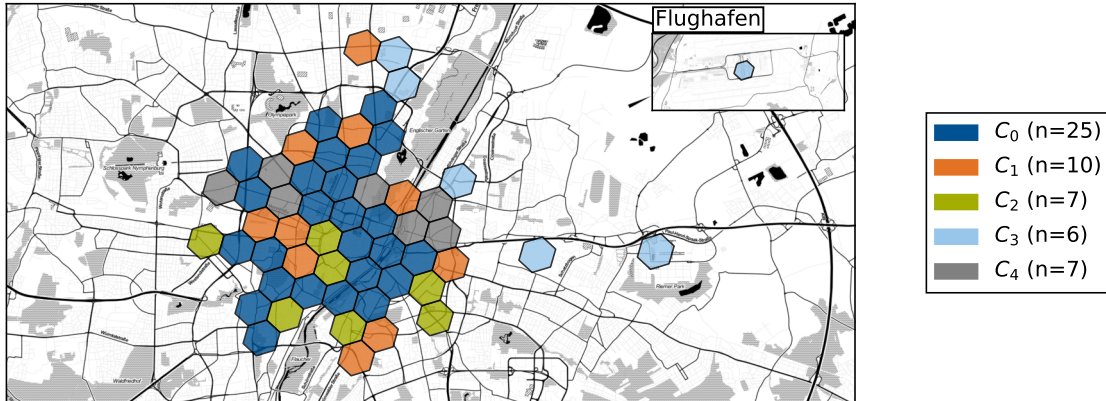


Abbildung 4.7: Räumliche Verteilung der Clusteranalyse (Auswertungszeitraum: 09.03.2015-01.01.2020; Rasterformat H3 [109] - Auflösung 8; Karte: Stamen Design © (i). Daten: OpenStreetMap, unter ODbL)




Abbildung 4.8: Nachfrageverlauf Clusteranalyse (Auswertungszeitraum: 09.03.2015-01.01.2020; Rasterformat H3 [109] - Auflösung 8; Karte: Stamen Design © (i). Daten: OpenStreetMap, unter ODbL)

4.1.4 Externe Einflussfaktoren auf das Nachfrageverhalten

Neben räumlichen und zeitlichen Abhängigkeiten besteht die Vermutung, dass das Nachfrageaufkommen im Taxigewerbe zusätzlich von externen Einflussfaktoren bestimmt wird. Im Folgenden werden mögliche Einflüsse durch Wetter, öffentliche Veranstaltungen sowie Verspätungen im öffentlichen Personennahverkehr untersucht.

Wetter

Einen wetterbedingten Einfluss auf das Nachfrageverhalten wurde für die Städte Montreal [176], New York [177, 178] und Shanghai [179] nachgewiesen. In Montreal betrug beispielsweise die Zunahme an Taxifahrten nach Regen bis zu 13,9 %. Die folgende Analyse untersucht, inwiefern ein ähnlicher Effekt auch für das Taxiaufkommen in München nachgewiesen werden kann. Die Analyse erstreckt sich über den Auswertungszeitraum 09.03.2015–31.12.2018. Dabei werden explizit nur die Wochentage Montag bis Freitag betrachtet. Feiertage und die Zeiträume von Großveranstaltungen (Bauma, Oktoberfest) werden zusätzlich von der Analyse ausgenommen, weil diese, wie bereits gezeigt, das Nachfrageverhalten stark beeinflussen.

Für die Analyse werden die beobachteten Fahrten auf stündlicher Basis diskretisiert. Die Wetterbeobachtungen werden auf Basis des gemessenen Niederschlags nach [180] in fünf Klassen eingeteilt: Kein Regen, leichter ($\leq 2,5 \frac{\text{mm}}{\text{h}}$), mäßiger (2,5 bis $10 \frac{\text{mm}}{\text{h}}$), starker (10 bis $50 \frac{\text{mm}}{\text{h}}$) und sehr starker ($>50 \frac{\text{mm}}{\text{h}}$) Regen. Anschließend werden pro Klasse der Mittelwert an Fahrten bestimmt und mit der Referenzklasse kein Regen verglichen. Abbildung 4.9 und Tabelle 4.1 fassen die Ergebnisse der Auswertung zusammen. Bezogen auf den Auswertungszeitraum wurden 19 732 h (82,90 %) ohne Niederschlag gemessen, 3945 h (16,58 %) regnete es leicht, 117 h (0,49 %) regnete es mäßig und 6 h (0,03 %) stark. Zu keiner Zeit wurde sehr starker Regen gemessen.

In Zeiten leichten Regens ist im Mittel eine Nachfragesteigerung von 4 % zu verzeichnen. Die größten Zuwächse sind in der ersten Tageshälfte zwischen 09:00–14:00 Uhr mit 6 bis 8 % und in der zweiten Tageshälfte von 19:00–23:00 Uhr mit 6 bis 11 % zu beobachten. Leichte Rückgänge in der Nachfrage (3 bis 4 %) sind zwischen 01:00–02:00 Uhr zu erkennen. Weitaus höhere Nachfrageschwankungen zeigen sich in Perioden mit mäßigem und starkem Regen. Hier können Nachfragezuwächse von bis zu 37 % bei mäßigem Regen bzw. 38 % für starken Regen beobachtet werden. Ebenfalls sind starke Nachfragerückgänge, um bis zu 21 % bei mäßigem Regen und 26 % bei starkem Regen festzustellen.




Abbildung 4.9: Einflussfaktor Wetter an Werktagen (Konfidenzintervall ($c = 0,95$), Auswertungszeitraum 09.03.2015–31.12.2018) nach [260]

Tabelle 4.1: Relative mittlere Änderung der Kundennachfrage in Folge von Niederschlag

Uhrzeit von bis	00:00 01:00	01:00 02:00	02:00 03:00	03:00 04:00	04:00 05:00	05:00 06:00	06:00 07:00	07:00 08:00	08:00 09:00	09:00 10:00	10:00 11:00	11:00 12:00
Leichter Regen	1,02	0,96	0,97	1,00	1,02	1,04	1,05	1,03	1,00	1,08	1,06	1,08
Mäßiger Regen	0,87	1,01	0,79	0,89	1,14	1,16	1,26	1,19	1,27	1,09	1,06	1,13
Starker Regen	-	-	-	-	-	-	-	-	-	-	-	-
Uhrzeit von bis	12:00 13:00	13:00 14:00	14:00 15:00	15:00 16:00	16:00 17:00	17:00 18:00	18:00 19:00	19:00 20:00	20:00 21:00	21:00 22:00	22:00 23:00	23:00 24:00
Leichter Regen	1,08	1,06	1,06	1,05	1,03	1,04	1,04	1,06	1,11	1,10	1,06	1,02
Mäßiger Regen	1,06	1,25	1,15	1,09	0,96	1,10	0,95	1,06	1,10	1,19	1,37	0,81
Starker Regen	0,84	-	-	0,99	1,34	1,38	-	-	0,74	-	-	-

Die Analyse zeigt, dass Nachfrageschwankungen bei schlechtem Wetter in ähnlichen Größenordnungen wie in [176, 177] auch für München gezeigt werden können. Auf Grund der Vielzahl an möglichen weiteren Einflussfaktoren kann im Rahmen dieser Untersuchung jedoch keine Ursache-Wirkbeziehung nachgewiesen werden. Vor allem die geringe Anzahl an Beobachtungen für Perioden starken und mäßigen Regens bergen Unsicherheiten (vgl. Konfidenzintervalle). Bezogen auf die Gesamtnachfrage kann der Einfluss des Wetters durch den geringen Anteil an Regentagen (18,1 % für München) als gering eingeschätzt werden (Abbildung 4.9).

Öffentliche Veranstaltungen

Wie bereits gezeigt, ist in Zeiten großer öffentlicher Veranstaltungen eine starke Änderung der Kundennachfrage zu beobachten. Während mehrtägigen Großereignisse wie das Oktoberfest oder die Bauma das Nachfrageverhalten der ganzen Stadt beeinflussen, wurde in Studien für New York [116, 149–151, 181] und Arizona [182] gezeigt, dass auch kleinere Veranstaltungen auf lokaler Ebene Änderungen im Nachfrageverhalten erzeugen. Um den lokalen Einfluss öffentlicher Veranstaltungen in München darzustellen, wurde in [158] eine Methode zur Anomalieerkennung in Zeitreihen auf Basis einer robusten Hauptkomponentenanalyse [183] auf den vorliegenden Datensatz angewandt. Es konnte gezeigt werden, dass in Zeiten örtlich lokaler Anomalien eine gehäufte Anzahl an Veranstaltungen zu beobachten ist. Für weitere Ergebnisse sei an dieser Stelle auf die entsprechende Veröffentlichung [158] verwiesen.

Verspätungen/Ausfälle im ÖPNV

Ein weiterer potentieller Einflussfaktor auf das Nachfrageverhalten sind Verspätungen oder Ausfälle im öffentlichen Personennahverkehr. So zeigen Yang und Gonzales [34] für den Taxiverkehr in New York eine Abhängigkeit der Taxinachfrage in Bezug auf die Nähe zu U-Bahn Stationen. Tyndall [184] zeigt Beispiele, die belegen, dass Ausfälle des öffentlichen Nahverkehrs die Nachfrage nach alternativen Verkehrsmitteln in der Stadt Vancouver erhöhen. Vande Walle und Steenberghen [185] bestätigen, dass sich Nutzer häufiger gegen die Nutzung des öffentlichen Nahverkehrs entscheiden, auch wenn nur Teilabschnitte der Strecke lange Wartezeiten zur Folge hätten.

Hierzu wurde in [157] der Einfluss von Verspätungen auf das Nachfrageverhalten für den Taxi- und Carsharing-Betrieb in München untersucht. Es konnte gezeigt werden, dass eine signifikante Erhöhung der lokalen Nachfrage aus Verspätungen von U- und S-Bahnen resultiert. Dabei ist im Taxiverkehr bei Verspätungen von mehr als 60 Minuten eine mittlere Steigerung der Nachfrage von 52,1 % möglich (Abbildung 4.10).

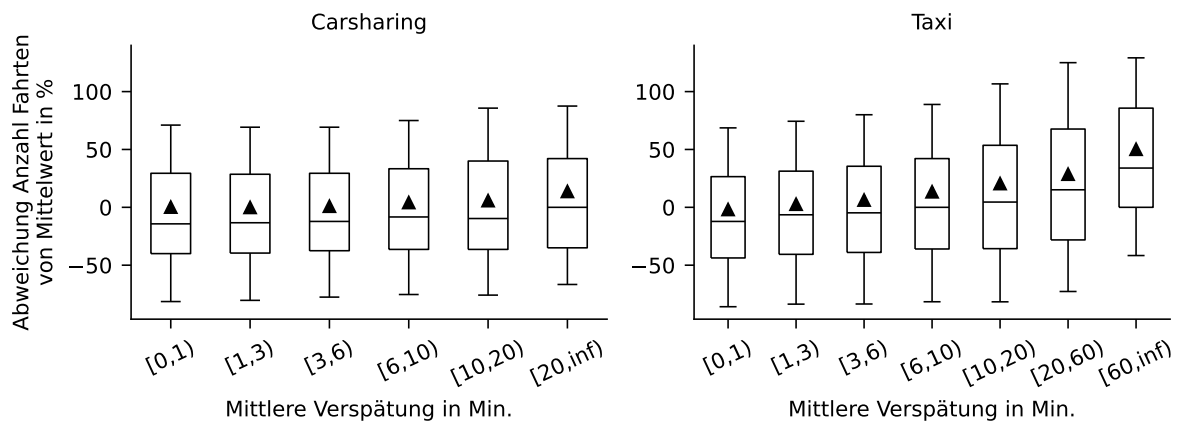


Abbildung 4.10: Auswirkungen von Verspätungen im S- und U-Bahnverkehr auf die Nachfrage bei Carsharing und Taxi nach [157].

4.2 Systemindikatoren

In den vorangegangenen Abschnitten wurde der räumliche und zeitliche Zusammenhang der Kundennachfrage dargestellt und diskutiert. Im Folgenden werden nun wesentliche Systemindikatoren analysiert, die den operativen Betrieb der Fahrzeugflotte charakterisieren.

4.2.1 Fahrtbezogene Kennwerte

Tabelle 4.2 zeigt die im Auswertungszeitraum beobachteten Fahrdistanzen und -dauern, aufgeschlüsselt nach Fahrtzweck. Ein durchschnittlicher Kunde legt im Mittel eine Distanz von 7,33 km zurück und benötigt für diese Strecke im Mittel 15,28 min. Der durchschnittliche Preis einer Taxifahrt im Auswertungszeitraum beträgt 17,35 €. Die durchschnittliche Anfahrdistanz für Fahrten, die über die Vermittlungszentrale bestellt werden, beträgt 1,74 km mit einer Dauer von 5,15 min. 50,50 % der aufgezeichneten Taxifahrten sind Auftragsfahrten, die über die Taxizentrale bestellt werden. Für den restlichen Anteil der Fahrten kann keine genauere Aussage getroffen werden. Die Fahrzeuge der Testflotte können auch Aufträge über Dritt- oder Direktvermittler entgegennehmen. In diesem Fall erfolgt keine Erfassung der Anfahrt über das Telematiksystem der Taxizentrale. Laut Linne und Krause [153, S. 12] verzeichnet München im nationalen Vergleich an dieser Stelle eine unterdurchschnittliche Quote an Funkvermittlungsaufträgen. Auch in dieser Studie kann jedoch auf Grund der mangelnden Datenlage keine weitere Aussage über das Verhältnis von Vermittlungsfahrten zu Einsteigerfahrten getroffen werden. Für Fahrten ohne Kundenbezug (Leerfahrten) legen die Fahrzeuge der Testflotte im Mittel 4,27 km zurück.

Tabelle 4.2: Fahrtbezogene Kennwerte der Münchner Referenzflotte im Auswertungszeitraum 09.03.2015-01.01.2020

Fahrtzweck	Parameter	Min.	Mittelwert	Median	Max.	Std.
Kundenfahrt	Distanz in km	0,25	7,33	4,50	99,33	8,75
	Dauer in min	1,02	15,28	12,65	146,95	10,13
	Fahrpreis in €	4,10	17,35	12,50	174,50	15,25
Anfahrt	Distanz in km	0,25	1,74	1,31	87,33	1,60
	Dauer in min	1,02	5,15	4,35	181,9	3,58
Leerfahrt	Distanz in km	0,26	4,27	2,08	99,46	6,56
	Dauer in min	1,02	10,51	6,28	187,5	15,79

4.2.2 Flottenauslastung

Abbildung 4.11 zeigt die mittlere Anzahl an Fahrzeugen nach deren Vermittlungsstatus im zeitlichen Verlauf der Durchschnittswoche. Im Mittel beträgt der Anteil an Fahrzeugen, die mit einem Kunden besetzt sind 42,4 %. 7,2 % der Zeit werden für die Anfahrt aufgewendet, 2,1 % der Zeit für den Warte- und Einstiegsvorgang. Aufsummiert entspricht dies einer mittleren zeitlichen Flottenauslastung von 51,7 % (Tabelle 4.3). Dies bedeutet im Umkehrschluss, dass mit einem Zeitanteil von 49,4 % eine erhebliche Kapazitätsreserve im System vorhanden ist.

Bezogen auf die Fahrtstrecke beträgt der Besetztanteil 58,8 % der Gesamtfahrtstrecke. 7,1 % entfallen für Anfahrt und 34,1 % für Rebalancing Aktionen (Tabelle 4.3).




Abbildung 4.11: Mittlere Anzahl an Fahrzeugen nach Vermittlungsstatus (Auswertungszeitraum: 09.03.2015-01.01.2020)

Tabelle 4.3: Mittlerer strecken- und zeitbezogener Anteil Fahrzeugstatus

	Anteil Strecke	Anteil Zeit
Vermittlungsstatus		
Frei	-	16,3 %
Rebalancing	34,8 %	31,9 %
Anfahrt	7,1 %	7,2 %
Wartend bei Kunde	-	2,1 %
Besetzt	58,8 %	42,4 %
Mittlere Flottenauslastung		51,7 %
Mittlere Flottenverfügbarkeit		49,4 %

4.2.3 Servicequalität

Nach [186, S. 24] beschreibt die Dienstleistungs- bzw. die Servicequalität als *"die Fähigkeit eines Anbieters, die Beschaffenheit einer primär intangiblen und der Kundenbeteiligung bedürftigen Leistung aufgrund von Kundenerwartungen auf einem bestimmten Anforderungsniveau zu erstellen. Sie bestimmt sich aus der Summe der Eigenschaften bzw. Merkmale von Dienstleistungen, mit denen bestimmte Anforderungen erfüllt werden."* Mögliche Kennwerte für die Bestimmung der Servicequalität im Taxigewerbe sind z. B. Wartezeit, Verfügbarkeit, Komfort und Zuverlässigkeit [187]. Für den weiteren Verlauf dieser Arbeit sind vor allem die Kennwerte Wartezeit und Verfügbarkeit relevant, weil diese direkt von der operativen Flottenstrategie beeinflusst werden können.

Abbildung 4.12 zeigt die relative sowie kumulative Verteilung der beobachteten Wartezeiten im Auswertungszeitraum. Die mittlere Wartezeit bis zum Eintreffen eines bestellten Taxis am Abholort beträgt 5,15 min.

In 95 % der Fälle liegt die Wartezeit unter 11,42 min. Abbildung 4.12 zeigt außerdem die Verteilung der gemessenen Einstiegsdauern zwischen Eintreffen des Fahrzeugs am Abholort und Fahrtbeginn. Im Mittel beträgt diese Zeitspanne 2,71 min.

Betrachtet man die mittlere Wartezeit im zeitlichen Verlauf (Abbildung 4.13), ist zu erkennen, dass diese abhängig von Tageszeit im Mittel zwischen 4 min und 6,5 min schwankt. Längere Wartezeiten sind in der Regel in den Nachfragespitzen morgens und abends zu erwarten. Setzt man diesen Verlauf in Bezug zur Anzahl an verfügbaren Fahrzeugen, ist zu erkennen, dass die Wartezeit mit abnehmender Fahrzeugverfügbarkeit steigt.

Wie in Abbildung 4.13 zu erkennen, ist eine Mindestverfügbarkeit an Fahrzeugen zu jeder Zeit gewährleistet.




Abbildung 4.12: Links: Relative Häufigkeitsverteilung Kundenwartezeit/Einstiegsdauer. Rechts: Kumulative Häufigkeitsverteilung Kundenwartezeit/Einstiegsdauer. (Auswertungszeitraum: 09.03.2015–01.01.2020)




Abbildung 4.13: Mittlere Kundenwartezeit (blau)/Anzahl an verfügbaren Fahrzeugen (orange) im Wochenverlauf mit Standardabweichung. (Auswertungszeitraum: 09.03.2015–01.01.2020)

4.3 Monetäre Kennwerte

Eine direkte monetäre Bewertung ist auf Basis des zur Verfügung stehenden Datensatzes nicht möglich. Dieser enthält weder die erzielten Fahrpreiserlöse, noch Informationen über die Zusammensetzung der Fahrzeugflotte (Anzahl Taxibetriebe, Informationen über Schichtbetrieb der Taxis etc.). Für die weitere Profitabilitätsbewertung wird daher vereinfacht angenommen, dass im Jahr 2019 eine Flotte von 490 Fahrzeugen (Anzahl angeschlossener Fahrzeuge der Vermittlungszentrale in 2019) von einem einzelnen Flottenbetreiber betrieben wird und dieser dazu Taxifahrer im sozialversicherungspflichtigen Angestelltenverhältnis

beschäftigt. Diese Annahme trifft nach [153, S. 44] für 45,4 % der in München operierenden Taxis zu, wenn gleich sich diese auf mehrere größere Taxiunternehmen aufteilen. Bevor die Ergebnisse weiter erläutert werden, werden im folgenden Absatz die Annahmen für fixe und variable Kosten präzisiert. Ziel ist es, die variablen Kosten (zeit- und entfernungsabhängig) sowie die Fixkosten für ein durchschnittliches Fahrzeug in München im Flottenbetrieb abzuschätzen. Die nachfolgend ermittelten Kennwerte sind in Tabelle 4.4 zusammengefasst.

4.3.1 Fixkosten pro Fahrzeug

Unter der Annahme einer Flotte mit 490 Fahrzeugen betragen die durchschnittlichen wöchentlichen Betriebsstunden pro Fahrzeug auf Basis des vorliegenden Datensatzes 59,6 h. Dies liegt 11 % unter dem in [153, S. 55] dargestellten Mittelwert von 67,0 h für professionelle Betriebe. Linne und Krause [153] beziffert die durchschnittlichen Fixkosten für ein professionell betriebenes Fahrzeug auf 9980 € pro Jahr. Im Vergleich dazu weist der Geschäftsbericht des Deutschen Taxiverbandes BZP 2018/2019 dagegen Fixkosten von 16 842 € pro Jahr aus [188, S. 97]. Hauptbestandteile der Fixkosten sind dabei die Abschreibung des Fahrzeugs (5875 €), die Kfz-Haftpflichtversicherung (3314 €), die Vollkaskoversicherung (1788 €) sowie Zinsen (1054 €) und Funkgebühren (1116 €) [188, S. 98]. Da beide Werte deutlich voneinander abweichen, wurde der Wert durch eine Expertenbefragung validiert [189]. Der Referenzwert des Branchenverbandes wurde dabei als zu hoch eingeschätzt. Für die weitere Berechnung wird daher der Mittelwert beider Quellen mit 13 262 € pro Jahr an Fixkosten für den Betrieb eines Fahrzeugs verwendet. Teilt man die Fixkosten durch die jährlichen Betriebsstunden, ergeben sich theoretische Fixkosten von 4,28 € pro Betriebsstunde (Tabelle 4.4).

4.3.2 Variable Streckenkosten

Die variablen Kosten für den Betrieb eines Fahrzeugs setzen sich nach [188] aus Kosten für Kraft- und Schmierstoffe, Fahrzeugpflege sowie Abnutzung, Wartung und Reparaturen zusammen. Für das Jahr 2019 werden hierfür im Geschäftsbericht des Bundesverbandes Taxi und Mietwagen e. V. variable Kosten in Höhe von 7042 € bezogen auf eine Jahresfahrleistung von 40 000 km angegeben [188]. Linne und Krause [153] geben im Gegensatz hierzu für das Jahr 2013 nicht weiter aufgeschlüsselte Betriebskosten in Höhe von 15 153 € bei einer Jahresfahrleistung von 67 637 km an. Wie bei den Fixkosten wird auf Grund des Expertengesprächs für die weitere Kostenabschätzung der Mittelwert der beiden Literaturwerte verwendet. Hieraus ergeben sich, auf die Fahrstrecke bezogene, variable Kosten in Höhe von 0,20 €/km.

4.3.3 Variable Lohnkosten

Im Jahr 2013, vor der Einführung des gesetzlichen Mindestlohns, lag der durchschnittliche Brutto-Stundenlohn für einen angestellten Taxifahrer in München bei 7,53 €/h [153, S. 66]. Seit 2015 ist für Arbeitnehmer im Taxigewerbe der gesetzliche Mindestlohn zu bezahlen. Dieser beträgt für das Jahr 2019 9,19 €/h (Zweite Verordnung zur Anpassung der Höhe des Mindestlohns vom 13. November 2018 (BGBl. I S. 1348)). Hinzu kommen für den Unternehmer weitere Lohnnebenkosten für Sozialabgaben (ca. 21 %), sowie Nacht- (25 %), Sonn- und Feiertagszuschläge (50 %) [190]. Hieraus ergeben sich unter Berücksichtigung der relativen Einsatzzeiten des Referenzdatensatzes als Abschätzung für das Jahr 2019 mittlere Arbeitgeberkosten in Höhe von 12,56 €/h.

In Summe ergeben sich damit jährliche Kosten für den Betrieb eines Fahrzeuges im Flotteneinsatz von 62 777 €. Dabei entfallen 62 % auf Lohnkosten, 17 % auf variable Streckenkosten und 21 % auf Fixkosten für das Fahrzeug.

4.3.4 Umsatz

Der erzielte Umsatzerlös lässt sich anhand der Mobilitätsdaten nachträglich berechnen. Grundlage für die Berechnung ist hierbei die 2019 gültige Münchner Taxitarifordnung [156]. Für die Referenzflotte ergibt sich daraus pro Fahrzeug ein Nettoerlös von 67 218 €/a. Bezogen auf die Kilometerleistung ergibt das einen Nettoerlös von 1,27 €/km. Dieser Wert liegt über dem Referenzwert von Linne und Krause [153] (1,05 €/km) und unter dem Referenzwert des BZP [188] (1,30 €/km).

4.3.5 Gewinn/Verlust, Marge

Auf Basis der berechneten Werte für Kosten und Erlöse lässt sich der Netto Gewinn/Verlust pro Fahrzeug berechnen. Während Linne und Krause [153] für das Jahr 2013 bei professionellen Betrieben mit mehr als 8 Fahrzeugen noch einen Nettoverlust von 133 €/a pro Fahrzeug notierten, ergibt sich für die untersuchte Referenzflotte für das Jahr 2019 ein Nettogewinn von 4440 €/a. Dies entspricht einer Marge von 6,60 %. Die berechneten Werte wurden im Rahmen eines Experteninterviews bestätigt [191].

Tabelle 4.4: Kostenabschätzung (netto) für den Betrieb eines Taxis im Flotteneinsatz im Jahr 2019 auf Basis von [153] [192]

*Wert nicht angegeben, übernommen aus [153], **Mittelwert aus [153] und [192], ***Bruttolohn inkl. Sozialversicherungsabgaben

	Einheit	BZP Einzelunternehmer 2019 [188]		Linne+Krause Flottenbetrieb 2013 [153]		Referenzdatensatz Flottenbetrieb 490 Fzg. 2019	
Kosten	€/a	51 962	100,00 %	69 609	100,00 %	62 778	100,00 %
Fixkosten	€/a	16 842	32,41 %	9 682	13,91 %	**13 262	21,13 %
Betriebsstunden pro Woche	h	*60,01		93,6		59,55	
Deckungsbeitrag	€/h	5,40		1,99		4,28	
Variable Streckenkosten	€/a	7 042	13,55 %	15 153	21,77 %	10 623	16,92 %
Fahrleistung	km/a	40 000		67 637		53 116	
Variable Streckenkosten	€/km	0,176		0,224		**0,200	
Variable Lohnkosten***	€/a	28 078	54,04 %	44 774	64,32 %	38 892	61,95 %
Variable Lohnkosten***	€/h	9,00		9,20		12,56	
Umsatz	€/a	51 962		69 476		67 218	
Umsatz pro Fahrtkilometer	€/km	1,30		1,05		1,16	
Gewinn/Verlust	€/a	-		-133		4440	
Marge	%	-		-0,19		6,60	

4.3.6 Ausblick bis 2022

Der gesetzliche Mindestlohn steigt schrittweise bis zum 1. Juli 2022 auf 10,45 €/h (+13,7 % im Vergleich zu 2019). Für den Flottenbetreiber resultiert dies in Arbeitnehmerkosten in Höhe von 14,28 €/h und einer Gesamtkostensteigerung von 8,5 %. Die Taxitarifordnung der Landeshauptstadt München wurde letztmalig am 1. März 2021 aktualisiert. Dabei wurde der Grundfahrpreis von 3,70 € auf 4,70 € angehoben. Die streckenabhängigen Kosten betragen nun pauschal 0,20 €/km. Abbildung 4.14 zeigt die Gewinn/Verlust Prognose für das Jahr 2022 in Folge von Lohnkostensteigerung und Fahrpreisanpassung unter Annahme konstanter Auftragslage für das Jahr 2022. Die steigenden Kosten können im Jahr 2022 bei gleichbleibender Auftragslage von den höheren Fahrpreisen kompensiert werden. In Summe ist im Jahr 2022 für dieselbe Flotte sogar ein zusätzlicher Gewinn von 2490 €/a pro Fahrzeug zu erwarten (Tabelle 4.5).




Abbildung 4.14: Wöchentlicher netto Gewinn/Verlust pro Fahrzeug. Links: 2019 (Lohnkosten: 12,56 €/h), Rechts: 2022 (Lohnkosten: 14,28 €/h)

Tabelle 4.5: Kostenentwicklung (netto) für den Betrieb eines Fahrzeugs im Flottenbetrieb (n=490 Fzg.) bis 2022 auf Basis des Referenzdatensatzes. **Mittelwert aus [153] und [192], ***Bruttolohn inkl. Sozialversicherungsabgaben

	Einheit	2019		Prognose 2022	
Kosten	€/a	62 778	100,00 %	68 104	100,00 %
Fixkosten	€/a	**13 262	21,13 %	**13 262	19,47 %
Variable Streckenkosten	€/a	10 623	16,92 %	10 623	15,60 %
Variable Lohnkosten***	€/a	38 892	61,95 %	44 219	64,93 %
Variable Lohnkosten***	€/h	12,56		14,28	
Umsatz	€/a	67 218		75 034	
Gewinn/Verlust	€/a	4440		6930	156,08 %

4.4 COVID-19

Am 27. Januar 2020 wurde in Deutschland zum ersten Mal das neuartige Corona Virus COVID-19 nachgewiesen. Im weiteren Verlauf des Jahres wird mit einer Vielzahl von Maßnahmen versucht, das Infektionsgeschehen einzudämmen. Erstmals wurde dazu am 16. März ein landesweiter Lockdown von 22. März bis 4. Mai 2020 beschlossen und das öffentliche Leben weitestgehend heruntergefahren [193]. Wie auch alle anderen Dienstleistungsbranchen ist das Taxigewerbe direkt durch den Lockdown betroffen. Wesentliche Nachfragetreiber wie Geschäftsreisen, Nachtaktivitäten, Messen und Flugverkehr wurden beinahe komplett eingestellt. Der Taxiverkehr selbst ist in seiner Funktion der öffentlichen Grundversorgung, abgesehen von verstärkt umzusetzenden Hygienemaßnahmen [194, 195], nicht durch den Lockdown reglementiert. Dieser Abschnitt analysiert auf Basis des vorliegenden Mobilitätsdatensatzes die Auswirkungen und Einschnitte für das Taxigewerbe am Beispiel der Münchner Testflotte.

Abbildung 4.15 zeigt den Verlauf der wöchentlichen Fahrtzahlen im Auswertungszeitraum 01.01.2019-30.06.2020. Es ist deutlich zu erkennen, dass in Folge der bundesweiten Maßnahmen und dem daraus folgenden Wegfall zentraler Nachfragefaktoren ein erheblicher Einbruch der Kundennachfrage zu erkennen ist. Dieser beginnt bereits am 16. März 2020, direkt nach Bekanntgabe der bundesweiten Maßnahmen und somit eine Woche vor deren in Kraft treten. Mit zunehmendem Rückgang der Infektionszahlen und kontrollierter Reduktion der Maßnahmen [196] erholt sich der Nachfrageverlauf zu Beginn des Sommers leicht, erreicht aber zu keinem Zeitpunkt das Vorjahresniveau. Ende Juni liegt dieser mit 20 043 Fahrten pro Woche immer noch 32,01 % unter dem wöchentlichen Maximum des Vergleichszeitraums im Jahr 2019 (29 478). Bezogen auf den gesamten Zeitraum seit Beginn des Nachfrageeinbruchs wurden 68,10 % weniger Fahrten als im Vergleichszeitraum 2019 durchgeführt.

Betrachtet man die Angebots- und Nachfrageentwicklung im Wochenverlauf (Abbildung 4.15) ist zu erkennen, dass der Rückgang der Kundennachfrage je nach Tageszeit unterschiedlich stark ausfällt. Befindet sich die Nachfrage in der ersten Tageshälfte noch auf einem Niveau von 49 %, erreicht sie in den Abendsstunden lediglich noch ein Niveau von 18 % bezogen auf den Vorjahreszeitraum. Die Anzahl aktiver Fahrzeuge beträgt im Zeitraum der Pandemie zwischen 24 bis 53 % des Vorjahreszeitraums. Auch hier sind vor allem in der zweiten Tageshälfte anteilig weniger Fahrzeuge im Einsatz. Jedoch reduziert sich die Anzahl an aktiven Fahrzeugen nicht im gleichen Maße wie die Anzahl an Fahrten. Lag die mittlere wöchentliche Flottenauslastung im Vergleichszeitraum 2019 noch bei 48 %, liegt diese im COVID-19 Zeitraum nur noch bei 32 %.

Tabelle 4.6 zeigt die finanziellen Auswirkungen in Folge des Nachfrageeinbruchs zwischen 16.03.2020-28.06.2020 im direkten Vergleich des Vorjahreszeitraums. Zwar konnten die Kosten durch weniger Einsatzstunden und kürzere Laufleistungen um -52,61 % reduziert werden, jedoch reichte diese Reduktion nicht aus, um den Umsatzrückgang von 73,43 % aufzufangen. In Summe ist für den betrachteten Zeitraum ein insgesamt Verlust von -3300,00 € pro Fahrzeug zu verzeichnen. Im Vorjahr betrug der Nettogewinn im Vergleich dazu noch 1442,54 €. Bei einer theoretisch angenommenen Flottengröße von 490 Fahrzeugen entspricht das einem Gesamtverlust von ~1,6 Mio. €.

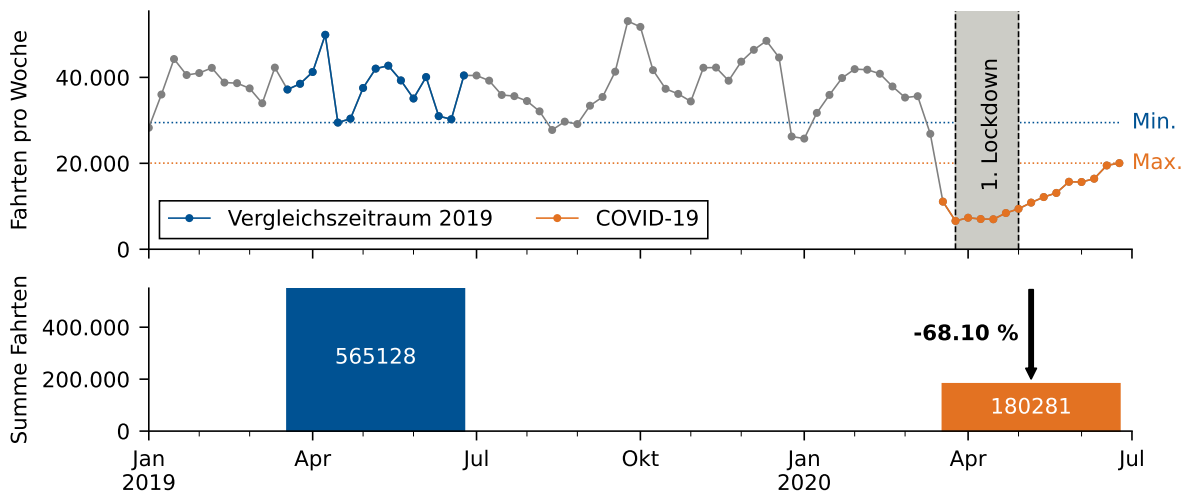


Abbildung 4.15: Kundennachfrage in Folge des 1. Lockdowns im Zeitraum 16.03.2020-28.06.2020 (orange) in Vergleich zu 18.03.2019-30.06.2019 (blau).




Abbildung 4.16: Änderung Nachfrage (links) und Angebot (rechts) in Folge des 1. Lockdowns im Zeitraum 16.03.2020-28.06.2020 (orange) in Vergleich zu 16.03.2020-28.06.2020 (blau). Konfidenzintervall $c = 0,95$

Tabelle 4.6: Gewinn/Verlustrechnung (netto) für den COVID-19 Zeitraum (16.03.2020-28.06.2020) im Vergleich zum Vorjahreszeitraum (16.03.2020-28.06.2020)

	Einheit	Vergleichszeitraum KW 12-26 2019	Zeitraum COVID-19 KW 12-26 2020	
Kosten	€	17 689,48	8382,98	-52,61 %
Fixkosten	€	3570,54	3570,54	-
Betriebsstunden pro Woche	h	57,53	19,16	-66,70 %
Deckungsbeitrag	€/h	4,43	13,31	200,45 %
Variable Streckenkosten	€	3025,87	947,95	-68,67 %
Fahrleistung	km	15 129	4740	-68,67 %
Variable Streckenkosten	€/km	0,20	0,20	-
Variable Lohnkosten	€	10 838,04	3609,46	-66,70 %
Variable Lohnkosten	€/h	12,56	12,56	-
Umsatz	€	19 132,03	5082,98	-73,43 %
Umsatz pro Fahrkilometer	€/km	1,26	1,07	-15,08 %
Gewinn/Verlust	€	1442,54	-3300,00	-328,76 %
Gewinn/Verlust pro Woche	€	103,04	-235,71	-328,76 %
Marge		0,08	-0,65	-912,50 %

4.5 Optimierungspotentiale

In der vorangegangenen Datenanalyse wurden wesentliche Zusammenhänge und Kenngrößen am Beispiel des Münchner Taxibetriebs erläutert. Die Ergebnisse zeigen, dass Optimierungspotentiale in Form von Überkapazitäten vorhanden sind. Gleichzeitig zeigt sich, dass ohne Kostenreduktion ein profitabler Betrieb mittelfristig nur durch steigende Fahrpreise gewährleistet werden kann. Wie in Unterkapitel 2.2 gezeigt, können vier wesentliche Optimierungspfade für den Betrieb von Ridesourcing identifiziert werden: Vermittlungs- und Rebalancingstrategie, Vorhersage der Kundennachfrage und Flottengröße. Im Folgenden werden wirtschaftliche und technische Potentiale für die genannten Optimierungspfade diskutiert.

4.5.1 Wirtschaftliche Potentiale

Optimierung der Flottengröße

Die aufgeführte Kostenrechnung hat gezeigt, dass das größte Potential zur Kostensenkung im Taxigewerbe in der Reduktion der aktiven Fahrzeugflotte liegt. Diese ist für 83,08 % der operativen Kosten verantwortlich. Mit einer mittleren zeitlichen Flottenauslastung von 51,74 % sind gleichzeitig ausreichende Kapazitätsreserven vorhanden, um die Anzahl an aktiven Fahrzeugen zu reduzieren. Eine Reduktion ist jedoch nur dann sinnvoll, wenn sichergestellt ist, dass diese ohne eine Verschlechterung der allgemeinen Servicequalität einhergeht. Wie internationale Studien zeigen, können längere Wartezeiten oder schlechte Verfügbarkeit unmittelbar in Umsatzeinbußen münden, da Kunden zu anderen Mobilitätsanbietern wechseln [30, 187, 197–199].

Servicequalität

Schon jetzt zeigt sich, dass die Wartezeiten in Zeiten hoher Nachfrage um bis zu 47 % ansteigen. Es ist zu erwarten, dass sich dieser Effekt bei einer reduzierten Flottengröße verstärkt. Gerade in diesen Zeiten wird jedoch anteilig der größte Umsatz erzielt. In einem zukünftig stark umkämpften Markt kann die schnelle Verfügbarkeit einen wesentlichen Wettbewerbsunterschied ausmachen und gleichzeitig neue Kunden binden [30, 187, 197, 199, 200]. Um dies zu gewährleisten ist die aktuell praktizierte Vermittlungs- und Rebalancingstrategie zu überprüfen und bei Bedarf zu optimieren.

Fahrpreis

Neben der allgemeinen Servicequalität bildet der Fahrpreis auf Kundenseite ein entscheidendes Auswahlkriterium [187, 197–200]. Konkurrierende Mobilitätsanbieter im Mietwagensektor (FreeNow, Uber) bieten in deutschen Städten schon jetzt Fahrten 20 bis 40 % unter dem aktuellen Taxitarif an, um sich Marktanteile zu sichern [61, 201]. Eine Optimierung der Betriebskosten kann dazu beitragen, das Fahrpreisniveau auf einem konkurrenzfähigen Niveau zu halten.

Erweiterung des Serviceangebots lokaler Vermittlungszentralen

Lokale Vermittlungszentralen stehen in direkter Konkurrenz zu national und global agierenden Fahrdienstvermittlern wie FreeNow, Uber etc. Innovative, auf den lokalen Markt angepasste Dienstleistungen und Angebote können in Zukunft dazu beitragen, sich von der internationalen Konkurrenz abzuheben und generieren einen Mehrwert gleichermaßen für Fahrgäste und Taxiunternehmer. Einen entscheidenden Vorteil können dabei die über einen langen Zeitraum verfügbaren Mobilitätsdaten, sowie die langjährige Vernetzung und Akzeptanz innerhalb der Branche darstellen.

4.5.2 Technische Potentiale

Prädiktion der Kundennachfrage

Die Datenanalyse zeigt, dass die Kundennachfrage einen zyklischen, wiederkehrenden Verlauf aufweist. Zusätzlich wurden zeitliche, räumliche und externe Einflussfaktoren identifiziert. Es kann angenommen werden, dass es, wie in Abschnitt 2.2.2 in ähnlichen Anwendungsfällen gezeigt, möglich ist, das räumlich-zeitliche Nachfrageaufkommen auf Basis des zur Verfügung stehenden Datensatzes vorherzusagen. Hierfür sind im weiteren Verlauf gängige Methoden zur Vorhersage von Zeitreihen auf ihre Eignung zu prüfen. Im praktischen Einsatz kann diese Aufgabe durch die Vermittlungsagentur erfüllt werden. Diese verfügt bereits über die benötigten Daten und kann Vorhersagen als zusätzliche Dienstleistung direkt über ihr Telematiksystem bzw. eine App Taxiunternehmern zur Verfügung stellen. Eine entsprechende Prognose kann beispielsweise dazu genutzt werden, Fahrzeuge im Voraus an Orte hoher Nachfrage umzuverteilen (Rebalancing) oder mittelfristig zur Schicht- und Einsatzplanung verwendet werden.

Optimierte Vermittlungsstrategie

Aktuell verwendet die Vermittlungszentrale der beobachteten Testflotte eine für München individuell entworfene Vermittlungsheuristik. Diese bevorzugt bei der Fahrgastvermittlung Fahrzeuge an einem nahegelegenen Taxistand entsprechend ihrer Wartezeit [202]. Eine ausführliche Erklärung des Vermittlungsablaufs erfolgt in Abschnitt 5.2.1. Für einen Taxifahrer bringt dieses Verfahren Planungssicherheit und wird als fair empfunden. Es ermutigt zudem Taxifahrer, sich an einem Taxistand aufzuhalten, weil Fahrzeuge an einem Taxistand priorisiert vermittelt werden. Für den Kunden bedeutet dies jedoch im schlechtesten Fall, dass ihm anstatt eines Fahrzeuges in unmittelbarer Umgebung, ein weiter entferntes Fahrzeug an einem Taxistand vermittelt wird. Hierdurch erhöhen sich Anfahrtswege und Wartezeiten. Wie in Abschnitt 2.2.1 gezeigt, existieren in der Literatur eine Vielzahl an Ansätzen zur Optimierung des Vermittlungsablaufs. Im weiteren Verlauf der Arbeit ist daher die Leistungsfähigkeit der aktuell praktizierten Heuristik im Vergleich zu alternativen Vermittlungsmethoden zu evaluieren.

Optimierte Rebalancingstrategie

Derzeit gibt es bei der beobachteten Testflotte keine übergeordnete Strategie zur Verteilung von Fahrzeugen im Geschäftsgebiet. Jeder Fahrer entscheidet eigenständig, auf Grund seiner persönlichen Erfahrung und Einschätzung, an welchen Ort er sich nach Abschluss einer Fahrt begibt, um auf den nächsten Auftrag

zu warten. Dies führt nicht selten dazu, dass sich eine große Menge an Fahrzeugen an vermeintlich hoch frequentierten Taxisänden aufhält, während in anderen Teilen des Geschäftsgebiets nur wenige Taxis verfügbar sind. Es wird erwartet, dass sich dieses Ungleichgewicht bei einer Reduktion der Fahrzeuganzahl weiter verstärkt. Wie in Abschnitt 2.2.3 dargestellt, zeigen Studien in ähnlichen Anwendungsfällen [12, 15], dass durch die koordinierte Verteilung von Fahrzeugen Wartezeiten und Anfahrsstrecken reduziert werden können. Im weiteren Verlauf der Arbeit soll deshalb der Mehrwert einer prädiktiven, kostenminimierenden Rebalancingstrategie gegenüber der aktuell praktizierten unkoordinierten Verteilung von Fahrzeugen untersucht werden.

5 Simulationsmodell zur Bewertung prädiktiver Flottenstrategien

5.1 Architektur des Simulationsmodells

Die Bewertung und Analyse der nachgehend beschriebenen Maßnahmen zur Optimierung der Flottenstrategie erfolgt mittels Simulation. Abbildung 5.1 zeigt den Aufbau des hierfür entwickelten Simulationsmodells. Das Modell basiert auf dem open-source Simulationsframework AMoDeus [19]. AMoDeus wurde speziell für die Simulation von MoD-Systemen entwickelt und nutzt im Kern die makroskopische, agentenbasierte Verkehrssimulation MATSim [18] und deren Erweiterung für DVRP [203]. In diesem Ansatz werden sowohl Kunden, als auch Fahrzeuge als individuelle Agenten modelliert. Akteure in der Simulation interagieren dabei miteinander unter der Nutzung geteilter Ressourcen (Straßennetzwerk, Taxisstände etc.). Diese Form der Modellierung erlaubt die größtmögliche Flexibilität, um das Verhalten einzelner Akteure zu bestimmen und Auswirkungen einzelner Verhaltensentscheidungen im globalen Zusammenhang zu bewerten. Für den Zweck dieser Arbeit wurde AMoDeus auf Basis der Version 2.0.0 funktional um die in den folgenden Abschnitten vorgestellten Teilmodelle/-funktionalitäten angepasst und erweitert¹.

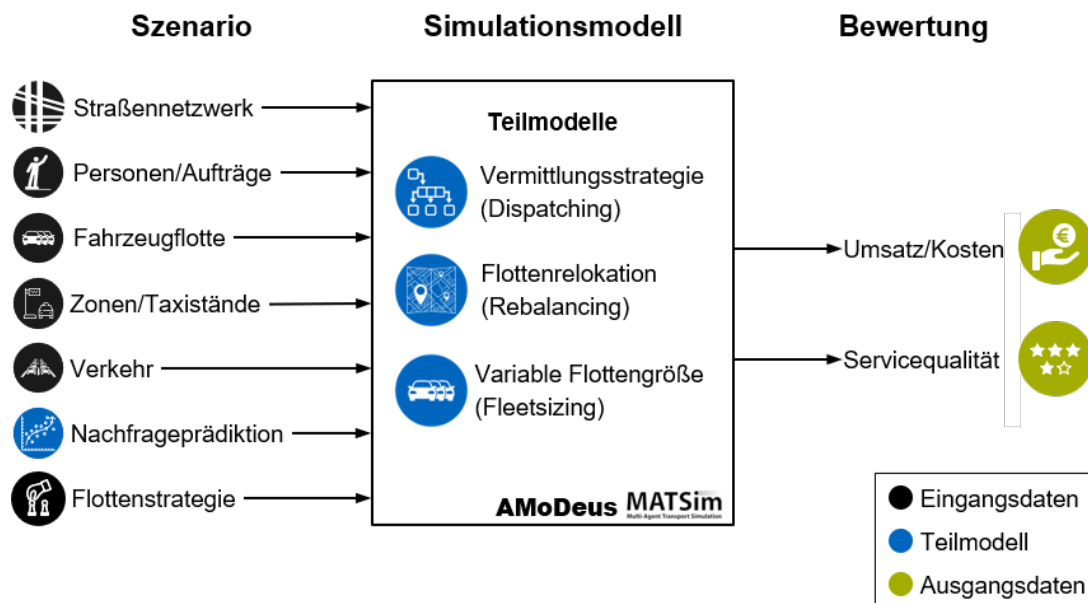


Abbildung 5.1: Architektur des Simulationsmodells zur Bewertung prädiktiver Flottenstrategien für Ridesourcing Dienste

¹Die funktional erweiterte Version von AMoDeus dieser Arbeit wurde unter <https://github.com/TUMFTM/amodeus-munich-taxi> veröffentlicht.

Das Simulationsmodell ist modular aufgebaut und ermöglicht es, durch die Kombination verschiedener Eingangsdaten, individuelle Szenarien zu simulieren. Für die Definition eines Szenarios werden folgende Eingangsdaten verwendet:

- **Straßennetzwerk:** Das Straßennetzwerk definiert die nutzbare Infrastruktur, auf der sich Agenten in der Simulation bewegen können.
- **Personen/Aufträge:** Die Fahrtwünsche der in der Simulation zu bedienenden Kunden werden über den Startzeitpunkt, Abfahrts- und Zielort definiert.
- **Fahrzeugflotte:** Definiert zur Erfüllung der Kundenaufträge zur Verfügung stehende Menge an Fahrzeugen. Die Flottengröße kann dabei statisch oder dynamisch im Zeitverlauf vorgegeben werden.
- **Zonen/Taxistände:** Definieren die für die Vermittlungs- und Rebalancingstrategie zu verwendenden Gebiete und möglichen Haltepunkte der Fahrzeuge.
- **Verkehr:** Um in der Simulation realistische Fahrzeiten zu gewährleisten, können an dieser Stelle zeitlich veränderliche Geschwindigkeitsvorgaben für einzelne Abschnitte des Straßennetzwerks definiert werden.
- **Nachfrageprädiktion:** Räumlich-zeitliche Vorhersage des Nachfrageaufkommens (Unterkapitel 5.4).
- **Flottenstrategie:** Kombination und Parameter der zu wählenden Teilmodelle im Simulationsmodell für Vermittlungs-/Rebalancingstrategie und Flottengröße.

Das Simulationsmodell wird zu Beginn mit den gegebenen Eingangsparametern initialisiert und die in der Flottenstrategie festgelegten Teilmodelle verknüpft und parametrisiert. Im darauf folgenden Simulationsdurchlauf wird das Verhalten der Fahrzeugflotte in Folge der gewählten Flottengröße, Vermittlungs- und Rebalancingstrategie simuliert. Dabei wird versucht, die eingehenden Kundenaufträge gemäß der vorgegebenen Start- und Ziel-Zeitpunkte/Orte zu erfüllen. Jedes Fahrzeug wird in der Simulation als eigener Agent abgebildet. Abbildung 5.2 zeigt das zugrunde liegende Zustandsdiagramm. Fahrzeuge starten im Zustand *Inaktiv*. Entsprechend der in den Eingangsparametern definierten statischen oder zeitlich dynamischen Sollwertvorgaben wechseln Fahrzeuge in den Status *Aktiv*. Aktive Fahrzeuge ohne vorgegebenes Fahrtziel befinden sich im Status *Parken/Warten*. Wurde ein Fahrauftrag durch die Vermittlungsstrategie zugewiesen, begibt es sich in die *Anfahrt zum Kunden*. Dort angekommen wechselt es in den Zustand *Besetzt mit Kunden*. Nach dem Ende einer Kundenfahrt wechselt das Fahrzeug zurück in den Status *Parken/Warten*. Entsprechend der gewählten Rebalancing Strategie verbleibt es entweder am aktuellen Ort oder bekommt eine neue Fahrtzielvorgabe gemäß der Rebalancing Strategie.

Für die anschließende Bewertung der gewählten Flottenstrategie werden folgende Ausgangsdaten durch das Modell erzeugt:

- **Umsatz/Kosten:** Monetärer Wert der Flottenstrategie für den Betreiber einer Fahrzeugflotte. Hierbei werden die fixen und variablen Kosten für den Betrieb der simulierten Fahrzeugflotte mit dem generierten Erlös aus durchgeführten Kundenaufträgen gegenübergestellt. Anhand der monetären Bewertung lassen sich konkrete Einsparpotentiale für einen Flottenbetreiber in Folge der gewählten Strategie ableiten. Diese Werte können einen Flottenbetreiber bei der Preis- und Angebotsgestaltung unterstützen.
- **Servicequalität** Neben der monetären Betrachtung des Flottenbetreibers ist die kundenseitige Betrachtung des Angebots essentiell. Führen Effizienzsteigerungen zu einem schlechteren Kundenerlebnis, hat dies durch evtl. Umsatzeinbußen im Rückschluss negative Folgen auf die monetäre Bewertung. Umgekehrt kann ein verbessertes Angebot dazu führen, dass mehr Kunden die Dienstleistung nutzen und dadurch weitere Erlöse erzielt werden können. Wesentliche Qualitätskriterien wie Vermittlungszeit, Wartezeit, Verfügbarkeit und Reisedauer werden daher als weitere Ausgangsdaten erzeugt.

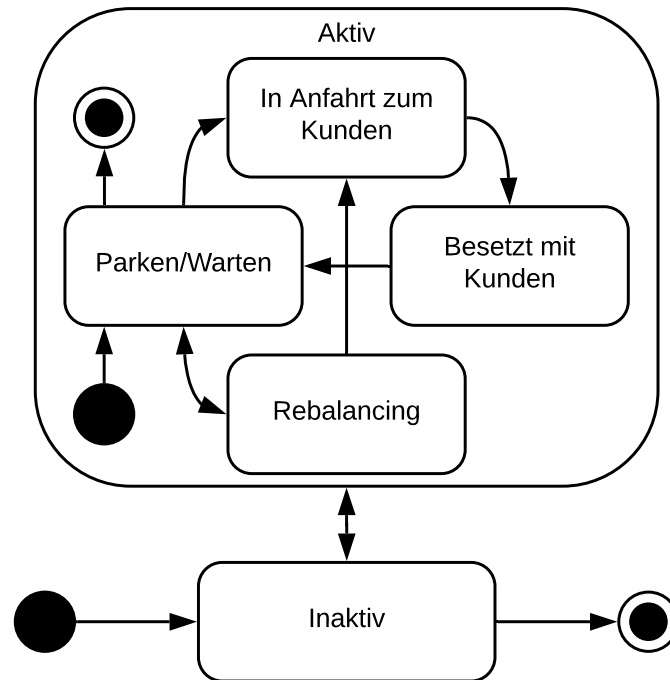


Abbildung 5.2: Zustandsdiagramm eines Taxi-Agenten

5.2 Strategien zur Fahrgastvermittlung

Die Zuordnung eingehender Kundenaufträgen zu verfügbaren Fahrzeugen wird in der Simulation durch die gewählte Vermittlungsstrategie definiert. Insgesamt kommen im Rahmen dieser Arbeit folgende Vermittlungsmethoden (Abschnitt 2.2.1) zum Einsatz, deren Funktionsweise im anschließenden Abschnitt erklärt wird:

- **Sektorvermittlung – Referenzstrategie:** Vermittlungsstrategie der Referenzflotte einer Münchener Vermittlungszentrale [202]
- **Globales Bipartites Matching (GBPM):** Beschreibung und Lösung des Zuordnungsproblems über bipartiten Graphen (Absatz 2.2.1)
- **Nearest Taxi Nearest Request (NTNR):** Optimierte Vermittlungsheuristik für Zeiten hoher Flottenauslastung [75]

Die Fahrgastvermittlung wird innerhalb der Simulation zu diskreten Zeitpunkten ausgeführt. Das hierfür verwendete Intervall kann für jedes Szenario über den Eingangsparameter T_{disp} definiert werden. Als weitere Randbedingungen können Grenzwerte für die Wartezeit, $t_{wait,max}$, und die Vermittlungsdauer, $t_{disp,max}$, definiert werden. Wird einer dieser Grenzwerte überschritten, wird die Fahrt als abgelehnt gekennzeichnet und nicht weiter berücksichtigt. Alle weiteren Fahrten, die im aktuellen Zeitschritt nicht vermittelt werden können, bleiben als offene Aufträge in der Warteschlange und werden im darauf folgenden Zeitschritt erneut berücksichtigt. Für alle vorgestellten Vermittlungsstrategien gilt zudem: Wurde ein Auftrag einmal einem Fahrzeug zugewiesen, bleibt diese Zuordnung bestehen, bis der Auftrag erfüllt oder durch den Kunden storniert wurde. Eine permanente Neuzuweisung von Aufträgen wie in Abschnitt 2.2.1 vorgestellt, ist für den untersuchten Anwendungsfall mit menschlichen Fahrern organisatorisch komplex. Diese Option eignet sich vor allem für autonome Fahrzeugflotten und wird in dieser Arbeit nicht weiter betrachtet.

5.2.1 Sektorvermittlung – Referenzstrategie

Die Bewertung möglicher Vermittlungsstrategien erfolgt in dieser Arbeit im Vergleich zu dem realen Vermittlungsalgorithmus der Referenzflotte. Die Vermittlung erfolgt in diesem Anwendungsbeispiel auf Basis einer räumlichen Unterteilung des Vermittlungsgebietes in Sektoren. Abbildung 5.3 zeigt die Einteilung am Beispiel der Münchner Referenzflotte.

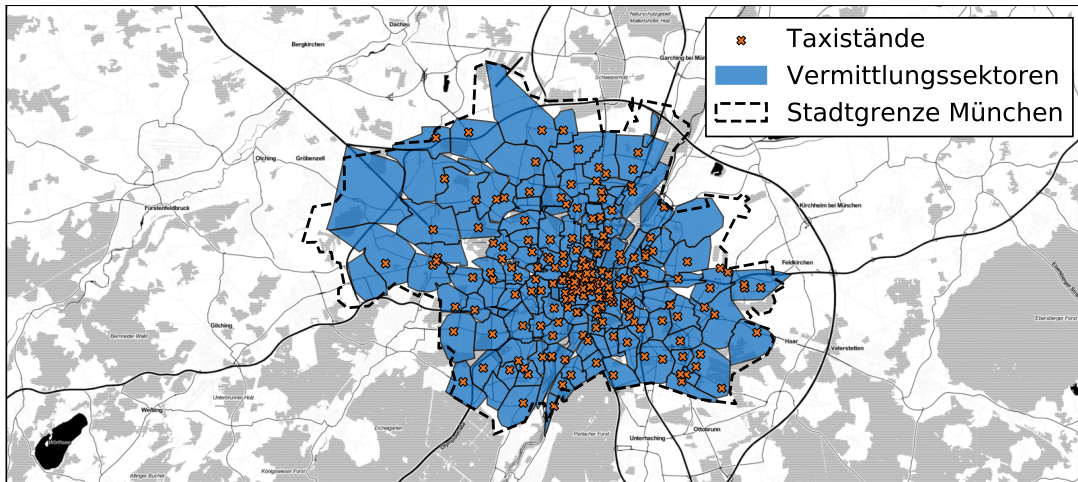


Abbildung 5.3: Vermittlungssektoren und Taxisstände der Münchner Referenzflotte [204]. (Karte: Stamen Design © i. Daten: OpenStreetMap, unter ODbL).

Abbildung 5.4 zeigt den schematischen Ablauf der Vermittlungslogik der Referenzstrategie. Die Vermittlungsheuristik bevorzugt dabei wartende Taxis an Taxisständen ggü. freien Fahrzeugen in der Umgebung mit evtl. kürzeren Anfahrtsweg:

1. Zum Vermittlungszeitpunkt wird geprüft, ob die maximal tolerierte Vermittlungsdauer oder Wartezeit überschritten ist. Falls ja, wird die Fahrt endgültig abgelehnt.
2. Im nächsten Schritt werden die für die Vermittlung priorisierten Sektoren S bestimmt. Zuerst wird dazu der Sektor, in dem die zu vermittelnde Fahrt startet, berücksichtigt. Zusätzlich dazu werden weitere $n - 1$ benachbarte Sektoren berücksichtigt (im Fall der Münchner Referenzflotte gilt i. d. R. $n = 4$).
3. In jedem Sektor werden zuerst Fahrzeuge, die an einem Taxisstand warten, gemäß ihrer Position in der Warteschlange berücksichtigt. Befinden sich in dem entsprechendem Sektor s_i keine Fahrzeuge am Taxisstand, werden als nächstes freie Fahrzeuge innerhalb des Sektors berücksichtigt. Konnte im Sektor s_i kein freies Taxi gefunden werden, werden die verbleibenden Sektoren der Menge S nach dem gleichen Ablauf durchsucht.
4. Konnte auf diesem Weg keine Zuordnung stattfinden, wird die Suche im letzten Schritt auf das gesamte Vermittlungsgebiet ausgeweitet.
5. Konnte ein verfügbares Fahrzeug gefunden werden, das in der Lage ist, den Kundenauftrag innerhalb der maximalen Wartezeit $t_{\text{wait,max}}$ zu bedienen, wird die Fahrt dem Fahrzeug zugewiesen und gilt als vermittelt. Konnte kein verfügbares Fahrzeug ermittelt werden, verbleibt die Anfrage offen und wird zum nächsten Vermittlungszeitpunkt erneut berücksichtigt.

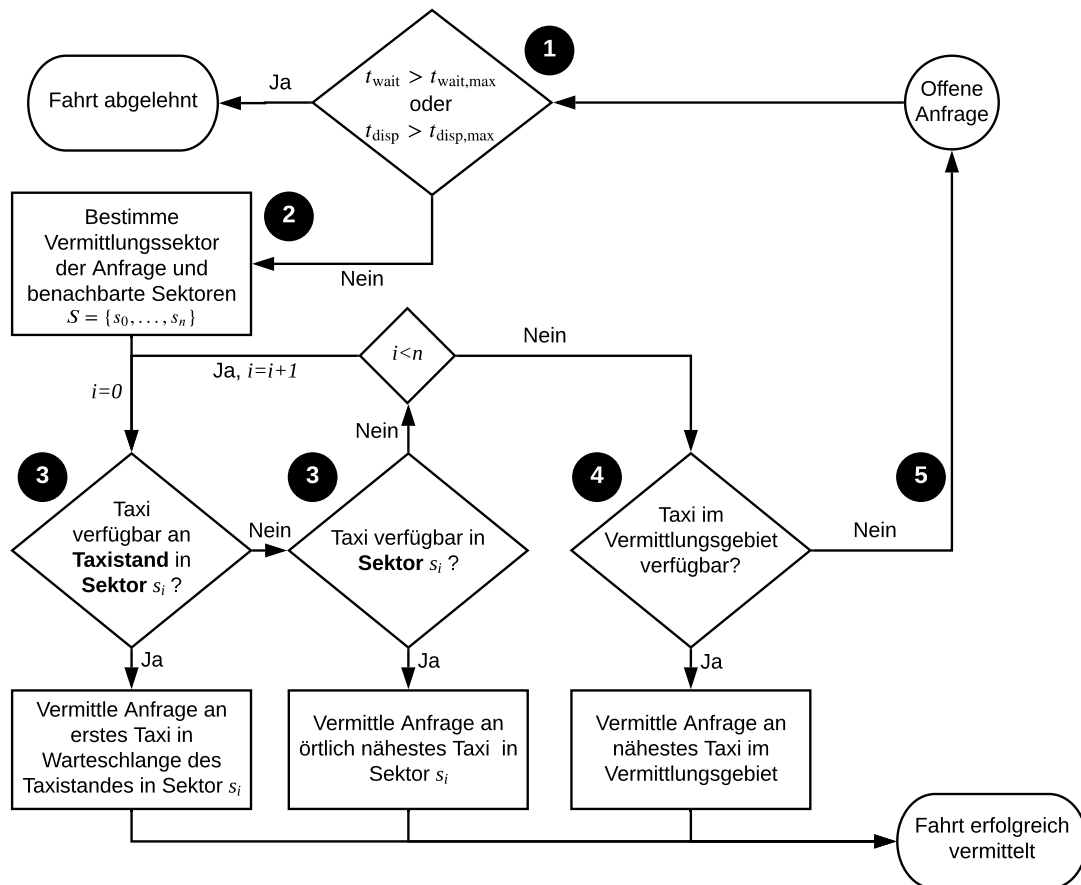


Abbildung 5.4: Schematische Darstellung des Vermittlungsalgorithmus der Münchner Referenzflotte (vgl. [204], [202])

5.2.2 Globales Bipartites Matching (GBPM)

Wie in Unterabschnitt 2.2.1 beschrieben, lässt sich mit der Methode des globalen bipartiten Matchings eine optimale Lösung für das Zuordnungsproblem zwischen verfügbaren Fahrzeugen und offenen Kundenaufträgen finden. Wie in Abbildung 5.5 dargestellt, repräsentieren dabei die Menge an Fahrzeugen, V , und Aufträgen, R , die Knoten eines Graphen. Gewichtete Kanten, w_i , zwischen diesen beiden Mengen beschreiben mögliche Fahrzeug-/Auftrag-Zuordnungen. In dem verwendeten Simulationsframework AMoDeus ist das Verfahren zur Bestimmung des GBPM bereits implementiert [83]. Die Lösung des Optimierungsproblems erfolgt dabei mit der ungarischen Methode nach Kuhn [81]. Als Optimierungsgröße wird an dieser Stelle die minimale Entfernung (Luftlinie) zwischen Fahrzeug und Auftrag verwendet. Eine kritische Größe stellt bei dieser Methode das Vermittlungsintervall T_{disp} dar. Wird dieses zu klein gewählt, kann die Methode aufgrund der geringen Menge an zu vermittelnden Aufträgen kein besseres Ergebnis liefern als die Methode *nearest-taxi*. Wird das Intervall hingegen zu groß gewählt, werden Anfragen, die zu Beginn des Intervalls erfasst werden, stark verzögert vermittelt. In der Folge entsteht eine zusätzliche Wartezeit für den Kunden. Es gilt also, den Parameter T_{disp} in der späteren Simulation so zu wählen, dass eine ausreichende Menge an Anfragen für die Zuordnung zusammengefasst werden, sich aber gleichzeitig die allgemeine Kundenwartezeit nicht erhöht.

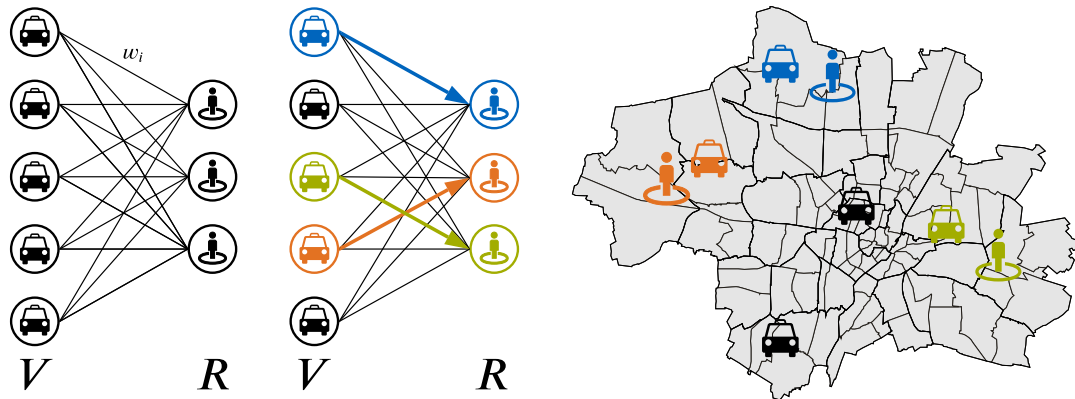


Abbildung 5.5: Schematische Darstellung eines bipartiten Graphen für die Zuordnung von Fahrzeugen zu Kunden.

Der Vermittlungsablauf dieser Strategie ist im Modell wie in Abbildung 5.6 dargestellt implementiert:

1. Zum Vermittlungszeitpunkt wird geprüft, ob die maximal tolerierte Vermittlungsdauer oder Wartezeit überschritten ist. Falls ja, wird die Fahrt endgültig abgelehnt.
2. Für das Zuordnungsproblem der beiden Mengen V und R wird das minimal maximale Matching M bestimmt.
3. Aufträge werden gemäß der Lösung M des Zuordnungsproblems an freie Fahrzeuge zugewiesen.
4. Kann ein Auftrag durch das ihm zugewiesene Fahrzeug innerhalb der maximal tolerierten Wartezeit bedient werden, gilt der Auftrag als erfolgreich vermittelt. Andernfalls verbleibt die Anfrage offen und wird zum nächsten Vermittlungszeitpunkt erneut berücksichtigt.

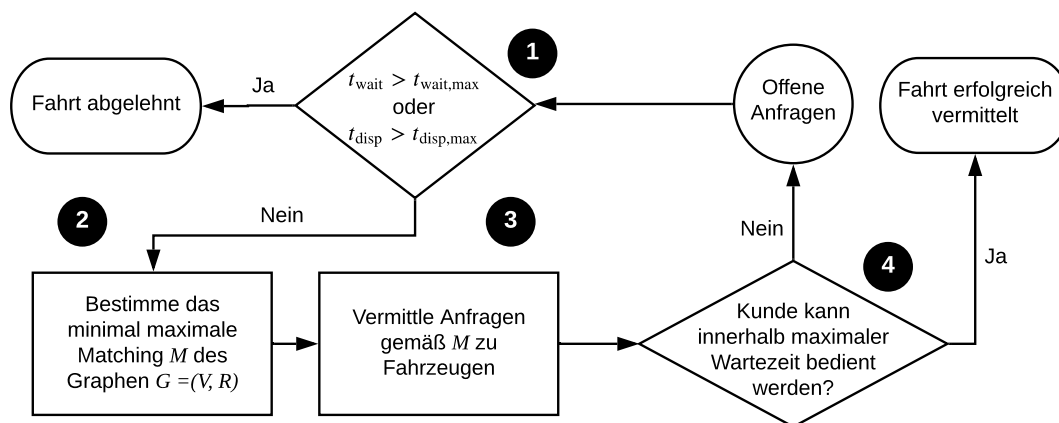


Abbildung 5.6: Schematische Darstellung des Vermittlungsalgorithmus auf GBPM-Basis.

5.2.3 Nearest Taxi Nearest Request (NTNR)

Maciejewski und Bischoff [75] konnten zeigen, dass durch die sequentielle Vermittlungsheuristik NTNR auch in Zeiten hoher Flottenauslastung niedrige Wartezeiten erreichbar bleiben. Stehen zum Vermittlungszeitpunkt mehr Fahrzeuge als Anfragen zur Verfügung, erfolgt die Zuordnung einer Anfrage an das jeweils örtlich nächste Fahrzeug. Im Falle eines Unterangebots (engl. undersupply) an freien Fahrzeugen erfolgt die Zuordnung umgekehrt. Freie Fahrzeuge werden dann dem örtlich nächsten Kunden zugeordnet (Unterabschnitt 2.2.1). Auch das NTNR Verfahren ist bereits in AMoDeus implementiert und wurde für den Zweck dieser Arbeit um die zusätzlichen Randbedingungen der maximalen Vermittlungszeit/Wartezeit erweitert. Der Vermittlungsablauf in der Simulation ergibt sich damit wie folgt (Abbildung 5.7):

1. Zum Vermittlungszeitpunkt wird geprüft, ob die maximal tolerierte Vermittlungsdauer oder Wartezeit überschritten ist. Falls ja wird die Fahrt endgültig abgelehnt.
2. Ist die Anzahl an Fahrzeugen der Menge V größer als die Anzahl der Aufträge der Menge M vermittele jede Anfrage, r_i , an das örtlich nächste Fahrzeug, v_i .
3. Ist die Anzahl an Fahrzeugen der Menge V kleiner als die Anzahl der Aufträge der Menge M wird jedes verfügbare Fahrzeug v_i der örtlich nächsten Anfrage r_i zugeordnet. Alle Anfragen, die in diesem Schritt nicht vermittelt werden können, verbleiben offen und werden im nächsten Vermittlungsschritt erneut berücksichtigt.
4. Kann eine Auftrag durch das ihm zugewiesene Fahrzeug innerhalb der maximal tolerierten Wartezeit bedient werden, gilt der Auftrag als erfolgreich vermittelt. Andernfalls verbleibt die Anfrage offen und wird zum nächsten Vermittlungszeitpunkt erneut berücksichtigt.

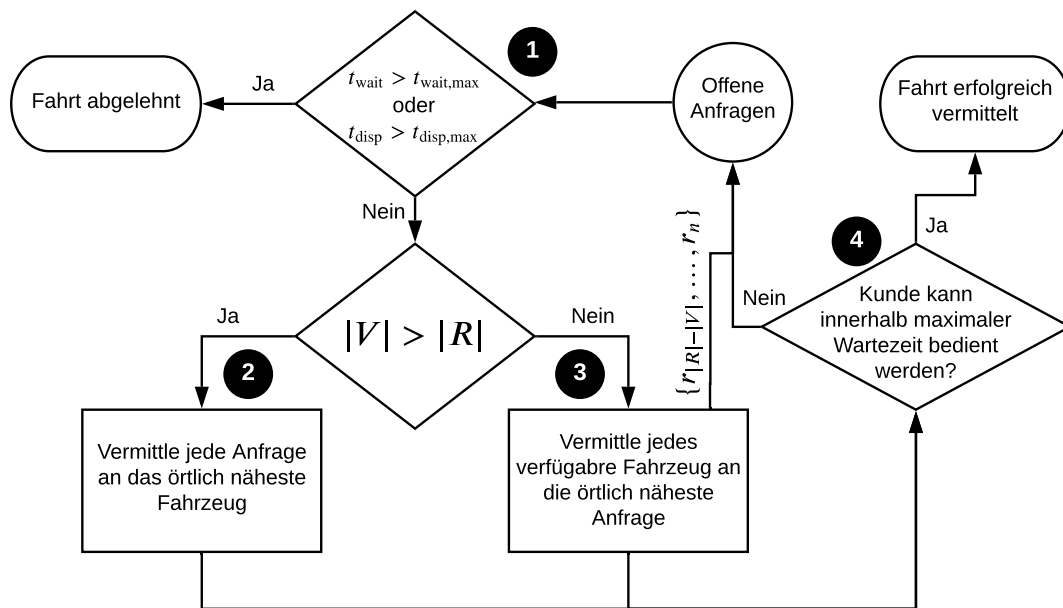


Abbildung 5.7: Schematische Darstellung des Vermittlungsalgorithmus auf GBPM-Basis.

5.3 Rebalancing Strategien

Die gewählte Rebalancingstrategie beeinflusst das Entscheidungsverhalten der Fahrzeuge, wenn sie gerade keinen Kundenauftrag bedienen. Wie in Abschnitt 2.2.3 gezeigt, können hierbei unterschiedliche Ansätze verfolgt werden. Im Rahmen dieser Arbeit wird diesbezüglich das Potential folgender Ansätze weiter untersucht:

- **Dezentrales, individuelles Rebalancing – Referenzstrategie:** Modell der Relokationsstrategie der Münchner Referenzflotte.
- **Prädiktive, gewinnmaximierende Rebalancing Strategie (PRLP):** Lineares Optimierungsproblem zur Bestimmung des kostenoptimalen Rebalancingverhaltens unter Berücksichtigung zukünftig vorhergesagter Kundennachfrage [204].
- **Feedforward fluidic optimal rebalancing policy (FFR):** Flussoptimales Rebalancing Verfahren nach [129].²

²Dieses Verfahren ist in AMoDeus [19] vorimplementiert und wird an dieser Stelle nicht näher beschrieben.

Das Rebalancing Verhalten der Fahrzeugflotte, wird – mit Ausnahme der Referenzstrategie – analog zu dem Vermittlungsvorgang zu diskreten Zeitpunkten ausgeführt. Die Dauer des dazu verwendeten Intervalls kann unabhängig von dem Vermittlungsintervall über den Parameter T_{reb} für jedes Szenario individuell definiert werden. Eine sinnvolle Wahl des Parameters hängt im Wesentlichen von der gewählten Strategie ab. Wird dieser zu klein gewählt, sind unter Umständen noch nicht alle Aktionen des vorherigen Rebalancing Schritts beendet. Wird der Zeitraum zu groß gewählt, verliert die Strategie ihr Optimierungspotential, weil Fahrzeuge zu selten umverteilt werden. Für alle in dieser Arbeit untersuchten Strategien gilt: Fahrzeuge, die sich im Status *Rebalancing* befinden, stehen prinzipiell zur Vermittlung zur Verfügung. Eine laufende Rebalancing Aktion kann abgebrochen werden, wenn währenddessen eine Kundenfahrt vermittelt wurde oder eine aktualisierte Routenvorgabe für das Rebalancing erfolgt.

5.3.1 Dezentrales, individuelles Rebalancing – Referenzstrategie

Für die Bewertung des Potentials einer optimierten Rebalancingstrategie wird – analog zur Vermittlungsstrategie – im Rahmen dieser Arbeit das Referenzverhalten für das Rebalancing Verhalten einer Münchner Testflotte modelliert. Im Gegensatz zur Vermittlungsstrategie existieren hier in Realität keine deterministischen Regeln, die das Verhalten von Taxifahrern beschreiben. Vielmehr handelt es sich in der Realität um individuelle Einzelfallentscheidungen der Taxifahrer, die in der Regel ohne Abstimmung untereinander erfolgen. Das hier vorgestellte, regelbasierte Referenzmodell basiert deshalb auf Beobachtungen und Expertenbefragungen. Wie im weiteren Verlauf der Arbeit gezeigt (Unterkapitel 6.2), ist das Modell dennoch in der Lage, das Verhalten aus globaler Perspektive hinreichend genau abzubilden.

Aus empirisch ermittelten Parametern des Referenzdatensatzes ergeben sich folgende Randbedingungen für das Rebalancingverhalten [205]:

- 50 % der beobachteten Taxis halten sich innerhalb eines Kerngebiets von 3000 m auf (Abbildung 5.8-links).
- Fahrzeuge ohne Auftrag halten sich nach Möglichkeit an einem freien Taxisstand auf.
- Für die Auswahl eines möglichen Taxisstandes wurde die Aufenthaltshäufigkeit für den Referenzzeitraum berechnet (Abbildung 5.8-rechts). Diese Häufigkeitsverteilung dient als Grundlage bei der Auswahl des Rebalancing Ziels einzelner Fahrzeuge.

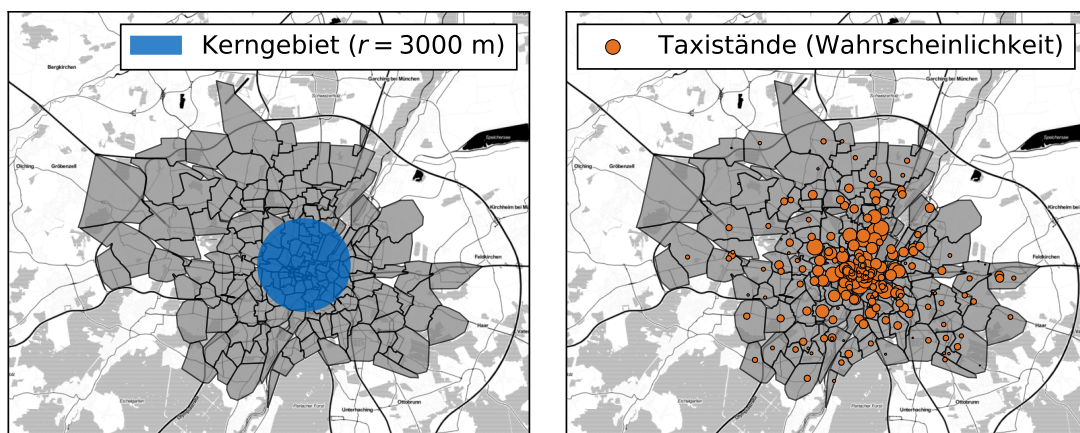


Abbildung 5.8: Links: Kerngebiet der Referenzstrategie. Rechts: Auswahlwahrscheinlichkeit Taxisstände, aufgrund real beobachteter Daten im Referenzzeitraum 2019 (Karte: Stamen Design © ⓘ. Daten: OpenStreet-Map, unter ODbL).

Nach erfolgreichem Abschluss eines Auftrags begibt sich das Fahrzeug umgehend zu einem Taxisstand. Abbildung 5.9 zeigt die dazu verwendete Heuristik: Befindet sich das Fahrzeug nach Ende der Fahrt in

einem Vermittlungssektor, wird dort der örtlich nächste, freie Taxisstand angefahren. Befindet sich das Taxi außerhalb des Vermittlungsgebiets oder gibt es keine freien Taxisstände innerhalb des aktuellen Vermittlungssektors, wird ein zufälliger, freier Taxisstand basierend auf der ermittelten Taxisstandhäufigkeitsverteilung bestimmt und angefahren.

Da es aufgrund der asymmetrischen Start-Ziel-Verteilung der Kundenfahrten im Laufe der Simulation zu einer ungewollten Umverteilung der Fahrzeuge kommt, wird zudem eine zweite Rebalancing Strategie zu diskreten Zeitpunkten T_{reb} für alle *Parkenden/Wartenden* Fahrzeuge vorgegeben. Diese folgt dem in Abbildung 5.10 dargestellten Ablauf:

- Ist das Verhältnis von freien Fahrzeugen innerhalb des Kerngebiets, $\beta_{v,zentrum}$ (5.8), kleiner als der vorgegebene Sollwert, werden Fahrzeuge in Richtung Kerngebiet umverteilt. Dies erfolgt bevorzugt an freie, zufällig ausgewählte Taxisstände. Ist dies nicht möglich, weil alle Taxisstände im Kerngebiet bereits mit der maximalen Anzahl an Fahrzeugen belegt sind, wird ein alternativer, zufälliger Ort innerhalb des Kerngebiets ausgewählt.
- Im Falle eines Überangebots an Fahrzeugen im Kerngebiet ($\beta_{v,zentrum} > \hat{\beta}_{v,zentrum}$) werden Fahrzeuge in der umgekehrten Richtung umverteilt. Die Bestimmung des Zielortes erfolgt analog.
- Ist das Verhältnis freier Fahrzeuge zwischen Zentrum und Umgebung im Gleichgewicht, werden alle Fahrzeuge, die sich aktuell nicht an einem Taxisstand befinden, gemäß der Standard-Heuristik zur Bestimmung des nächsten Taxisstandes behandelt (Abbildung 5.9)




Abbildung 5.9: Standard Rebalancing Verhalten nach Ende einer Kundenfahrt in der Referenzstrategie.

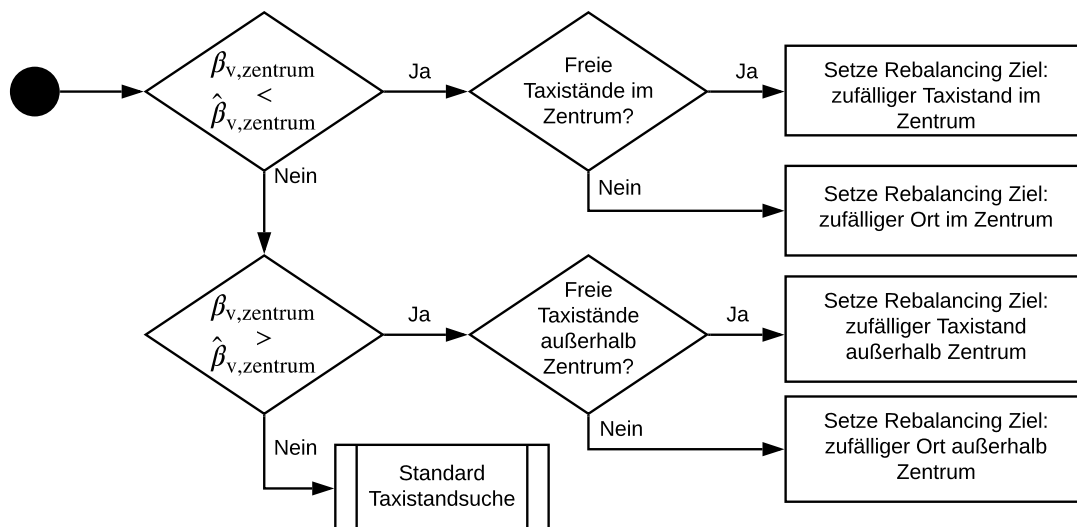


Abbildung 5.10: Ausgleichendes, intervallgesteuertes Rebalancing Verhalten der Referenzstrategie.

le 5.1). Daraus ergibt sich für das Gebiet G eine äußere Abmessung von 8 km x 8 km. Für die Abmessungen der Zellen des Gebiets B wurden die Grenzen bis zu einer maximalen Abdeckung von 99 % der Abfahrtsorte erweitert. Der Parameter für \bar{x}_{border} ergibt sich somit zu 5 km.

Tabelle 5.1: Räumliche Verteilung der Abfahrtsorte [205]

Größe des Gebiets	Anteil der Fahrten
1 km x 1 km	4,4 %
4 km x 4 km	42,8 %
8 km x 8 km	75,1 %
12 km x 12 km	91,2 %
18 km x 18 km	99,0 %
20 km x 20 km	99,6 %

Rebalancing Algorithmus

Die prädiktive, gewinnmaximierende Umverteilung freier Fahrzeuge erfolgt in einem 2-stufigen Verfahren (Abbildung 5.12).

1. Im ersten Schritt werden die Rebalancing Flüsse aller Zellen der Menge G (Gebiet mit hoher regelmäßiger Nachfrage) anhand des nachfolgend beschriebenen Optimierungsverfahren bestimmt.
2. Im zweiten Schritt wird versucht, mit Hilfe der verbleibenden Fahrzeuge ein Angebots-/Nachfrage-Gleichgewicht in den Randgebieten herzustellen. Dazu werden überschüssige Fahrzeuge zwischen Gebieten der Mengen G , B verteilt.

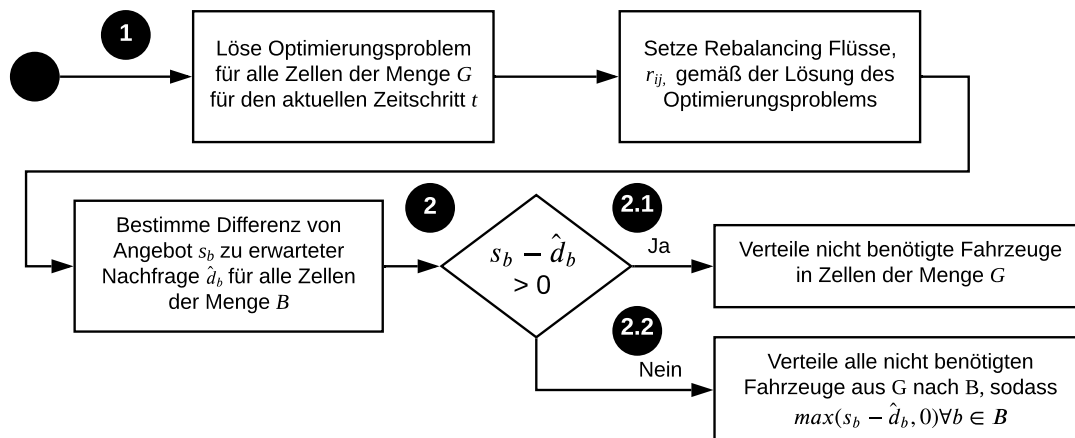


Abbildung 5.12: Vereinfachter Ablauf der prädiktiven, gewinnmaximierenden Rebalancing Strategie

Lineares Optimierungsproblem für Gebiete mit hoher regelmäßiger Nachfrage

Für die Bestimmung einer gewinnmaximierenden Verteilung der Fahrzeugflotte im Kerngebiet lässt sich das Problem in Erweiterung zu [15] als lineares Optimierungsproblem formulieren. Eine erste Beschreibung ist bereits in der eigenen Veröffentlichung [204] erfolgt und ist zum tieferen Verständnis an dieser Stelle nochmal ausführlich dargestellt.

Zielfunktion

Die zu maximierende Zielgröße ist der durch die Fahrzeugflotte generierte Gewinn. Dieser wird maximiert, wenn der durch ein lokales Unterangebot verursachte Erlösausfall, p_{loss} , sowie die durch das Rebalancing

zusätzlich entstehenden Kosten c_{reb} , (Kraftstoff, Fahrzeugabnutzung etc.), minimiert werden. Die Zielfunktion ergibt sich somit zu:

$$\max \sum_{t=t_0}^{t_0+T} \gamma(t) (p_{\text{loss}} - c_{\text{reb}}). \quad (5.1)$$

Über den Gewichtungsparemeter $\gamma(t)$ kann dabei das frühe Erreichen eines Gleichgewichtszustands belohnt werden. Das Optimierungsproblem wird für den Prognosehorizont (Anzahl an Rebalancing Schritten) T gelöst.

Für die weitere Beschreibung des Problems wird das Gebiet in eine Menge uniformer Zellen, G , räumlich diskretisiert. s_i^t sei das Angebot an freien Fahrzeugen einer Zelle g_i zum Zeitpunkt t . Analog dazu sei die Anzahl an offenen Anfragen einer Zelle g_i zwischen Zeitpunkt t und $t + T_{\text{reb}}$, gleich d_t^i . Als Randbedingung für die Zielfunktion gilt: Ein Überangebot an Fahrzeugen in einer Zelle g_i erzeugt keinen zusätzlichen Umsatz³. Im Falle eines Unterangebots an Fahrzeugen ergibt sich somit zum Zeitpunkt t der globale Erlösausfall

$$p_{\text{loss}} = \sum_i \lambda \min(s_i^t - d_t^i, 0). \quad (5.2)$$

Der Parameter λ berücksichtigt dabei den Wert der Zeit (engl. value of time) (VAT) des Kunden. Die durch das Rebalancing hervorgerufenen, zusätzlichen Kosten, ergeben sich aus

$$c_{\text{reb}} = \sum_{i \neq j} c_{ij} r_{ij}^t. \quad (5.3)$$

Dabei sind c_{ij} die variablen Kosten für eine Rebalancing Fahrt von g_i nach g_j und r_{ij}^t die zu bestimmende optimale Anzahl an Rebalancing Fahrten von g_i nach g_j zum Zeitpunkt t .

Nebenbedingungen

Die Lösung des Optimierungsproblems ist an zeitabhängige Nebenbedingungen geknüpft.

NB1: Begrenzung des Angebots an Fahrzeugen

$$s_i^t \geq 0 \quad \text{für } t = t_0, \dots, t_0 + (T - 1), \quad \forall i \in G \quad (5.4)$$

NB2: Beschränkung auf Fahrten, die innerhalb eines Zeitschritts abgeschlossen sind

Alle ermittelten Rebalancing Flüsse müssen innerhalb der Rebalancingperiode T_{reb} abgeschlossen sein, damit diese in den nächsten Optimierungsschritten berücksichtigt werden können:

$$r_{ij}^t = 0 \quad \text{für } \{i, j, t \mid t_{i\bar{j}} \geq T_{\text{reb}}\}. \quad (5.5)$$

Dabei beschreibt $t_{i\bar{j}}$ die benötigte Fahrtzeit zwischen den Zellen g_i und g_j .

³Dieser Zusammenhang kann mit dem aktuellen Datensatz nicht hinreichend bewertet werden. Dieser Parameter kann dennoch eine hohe Relevanz aufweisen, wenn es z. B. darum geht, in einer frühen Marktphase durch ein Überangebot Marktanteile von Mitbewerbern abzurufen

NB3: Angebot an Fahrzeugen

Das Angebot an Fahrzeugen, s_i^t einer Zelle g zum Zeitpunkt t_0 ergibt sich aus der Anzahl an freien Taxis x_i^t abzüglich der ausgehenden Rebalancing Flüsse r_{ij}^t zu

$$s_i^{t_0} = x_i^{t_0} - \sum_{j=1}^{|G|} r_{ij}^{t_0}. \quad (5.6)$$

In den folgenden Zeitschritten wird die Nebenbedingung um die ankommenden und abgehenden Fahrzeuge aus dem vorherigen Zeitschritten ergänzt und ergibt sich zu:

$$\begin{aligned} s_i^t = & \max(s_i^{t-1} - d_i^{t-1}, 0) + x_i^{t-1,t} + \sum_{j=1}^{|G|} (r_{ji}^{t-1} - r_{ij}^t) \\ & + \sum_{\tau=t_0}^{t-1} \sum_{j=1}^{|G|} \mathbb{1} \left(t = \tau + \left\lceil \frac{t_{ij}}{T_{\text{reb}}} \right\rceil \right) \mathbb{P}_\tau(i|j) \min(s_j^\tau, d_j^\tau) \quad \forall t > t_0. \end{aligned} \quad (5.7)$$

Dabei ist:

- $\max(s_i^{t-1} - d_i^{t-1}, 0)$ die Anzahl an verbleibenden, freien Fahrzeugen des vorherigen Zeitschritts,
- $x_i^{t-1,t}$ die Anzahl an Fahrzeugen, die ihre Fahrt bereits vor t_0 begonnen haben und zwischen $t-1$ und t frei werden,
- r_{ji}^{t-1} die Anzahl an ankommenden Rebalancing Flüssen in g_i aus dem vorangegangenen Zeitschritt,
- r_{ij}^t die zu bestimmende Anzahl an abgehenden Rebalancing Flüssen des aktuellen Zeitschritts,
- $\mathbb{P}_\tau(i|j) \min(s_j^\tau, d_j^\tau)$ die zum Zeitpunkt der Lösung unbekannte Anzahl an Fahrzeugen, die im Laufe des Optimierungshorizonts eine Kundenfahrt durchführen und anschließend als freie Fahrzeuge zur Verfügung stehen werden. Diese Anzahl wird mit Hilfe der Wahrscheinlichkeitsfunktion möglicher Start-Ziel-Paare, $\mathbb{P}_\tau(i|j)$, und der zu erwartenden Reisezeit t_{ij} der Fahrten abgeschätzt.

NB4: Kundennachfrage

Die zu erfüllende Kundennachfrage einer Zelle g_i zum Zeitpunkt t ist definiert als

$$d_i^t = \begin{cases} \hat{d}_i^t, & \text{für } t = t_0 \\ \hat{d}_i^t + \max(d_i^{t-1} - s_i^{t-1}, 0), & \forall t \geq t_1 \end{cases}. \quad (5.8)$$

Dabei ist \hat{d}_i^t die Nachfrageprognose (Unterkapitel 5.4) für g_i zum Zeitpunkt t .

Solver

Das beschriebene Optimierungsproblem muss zur Laufzeit der Simulation kontinuierlich gelöst und das Ergebnis als Sollvorgabe an die Simulation zurückgegeben werden. Um die Rechenzeit während der Simulation zu reduzieren, gehen folgende statische Parameter als Eingangsdaten in die Simulation ein:

- Die Wahrscheinlichkeitsverteilung der Funktion $\mathbb{P}_t(i|j)$ wird auf Basis der beobachteten Fahrten der letzten zwei Monate für jede Start-Ziel-Paarung (g_i, g_j) bestimmt.

- Die Fahrzeit zwischen den Zellen (g_i, g_j) wird auf Basis des hinterlegten Straßennetzes zwischen den Zellmittelpunkten einmalig für alle Zellpaarungen bestimmt.
- Die prädizierte Kundennachfrage wird auf Basis der beobachteten Daten für den Simulationszeitraum vorberechnet (Unterkapitel 5.4) und steht als Lookup-Table während der Simulation zur Verfügung.

Das Optimierungsproblem wird im Verlauf der Simulation zu diskreten Zeitpunkten t_{reb} gelöst. Dazu werden die Nebenbedingungen des Optimierungsproblems mit den benötigten Werten aus der Simulation aktualisiert.

Für die Lösung des Problems wird der kommerzielle Solver Gurobi [209] verwendet. Durch entsprechende JAVA-bindings kann das Modell direkt in das Simulationsmodell integriert werden.

Verfahren für den Ausgleich zwischen Zentrum und Randbereichen

Wie im vorherigen Abschnitt beschrieben, ist die Lösung des prädiktiven, gewinnmaximierenden Optimierungsproblems auf Gebiete der Menge G beschränkt. Vorstudien [205, 207] haben gezeigt, dass auch niedrig frequentierte Gebiete außerhalb des Zentrums einen entscheidenden Einfluss auf die Qualitätsmetriken zur Bewertung der Servicequalität haben. Gerade diese Gebiete profitieren aufgrund der längeren Anfahrtswege aus dem Zentrum von einem ausgeglichenen Verhältnis von Angebot und Nachfrage.

Dazu wird im ersten Schritt die verbleibende Menge, V_{idle} , an Fahrzeugen bestimmt, die für den Ausgleich zwischen Zentrum und Randgebiet herangezogen werden kann. Dabei werden nur Fahrzeuge berücksichtigt, die zum Zeitpunkt t keine Aktion ausführen.

$$V_{\text{idle}} = V_{\text{idle}}^B \cap V_{\text{idle}}^G. \quad (5.9)$$

Die lokale Differenz von Angebot und prädizierter Nachfrage für alle Gebiete der Menge B , δ_b^{SD} ergibt sich aus allen freien Fahrzeugen, x_b^t , des Gebiets b zum Zeitpunkt t ; allen innerhalb des Rebalancingintervalls T_{reb} frei werdenden Fahrzeugen, $x_b^{t, t+T_{\text{reb}}}$; abzüglich der prädizierten Nachfrage \hat{d}_b :

$$\delta_b^{\text{SD}} = x_b^t + x_b^{t, t+T_{\text{reb}}} - \hat{d}_b \quad \forall b \in B. \quad (5.10)$$

Im Falle eines Unterangebots ($\delta_b^{\text{SD}} < 0$) an Fahrzeugen werden im nächsten Schritt eine Menge an Zielorten, R , bestimmt. Dazu wird eine Anzahl von $\text{sign}(\delta_b^{\text{SD}})$ Orten der Menge R hinzugefügt. I. d. R. handelt es sich dabei um Taxisstände. Anschließend wird für die beiden Mengen (V_{idle}, R) mittels bipartiten Matchings (Abschnitt 5.2.2, Unterabschnitt 2.2.1) eine fahrstreckenoptimale Zuordnung bestimmt.

Abschließend werden alle überschüssigen Fahrzeuge aus den Gebieten der Menge B in Richtung G verteilt. Ziel ist dabei immer das Gebiet g_i mit dem niedrigsten Verhältnis von Angebot und Nachfrage.

5.4 Modell zur räumlich-zeitlichen Prädiktion der Kundennachfrage

Die in Abschnitt 5.3.2 vorgestellte Rebalancing Strategie setzt eine Prädiktion der räumlich-zeitlichen Kundennachfrage voraus. Dieser Unterabschnitt beschreibt das Vorgehen zur Entwicklung eines dazu geeigneten Prädiktionsmodells. Dabei werden zuerst die allgemeinen Anforderungen und der Aufbau des Modells beschrieben. Im weiteren Verlauf wird auf dieser Grundlage ein Vorhersagemodell für das Anwendungsbei-

spiel (Taxiverkehr München) abgeleitet. Dazu werden verschiedene Vorhersagemethoden aus dem Stand der Technik (Abschnitt 2.2.2) anhand des zur Verfügung stehenden Datensatzes bewertet.

5.4.1 Allgemeine Anforderungen an das Prädiktionsmodell

Aus der beschriebenen Rebalancing Strategie und den zur Verfügung stehenden Daten ergeben sich für das Modell folgende Anforderungen:

Ziel des Prädiktionsmodells

Ziel des Modells ist es, Volumen und Ort von zukünftigen Kundenaufträgen bestmöglich vorherzusagen. Dabei soll eine größtmögliche räumliche und zeitliche Auflösung erreicht werden.

Räumliche Auflösung

Die räumliche Diskretisierung ergibt sich aus der in Abbildung 5.11 vorgestellten Einteilung des Rebalancing Gebiets. Die Anzahl und Größe der Zellen des Gebietes G sind so zu bestimmen, dass eine ausreichende Vorhersagegenauigkeit bei gleichzeitig hoher räumlicher Auflösung gewährleistet ist.

Zeitliche Auflösung

Die zeitliche Auflösung der Vorhersage ist ko-abhängig von der Zeitkonstante des Rebalancing Problems, T_{reb} . Der Prognosehorizont ist ebenfalls durch die Anzahl an zu berücksichtigenden Zeitschritten, T , aus der Rebalancing Strategie vorgegeben. Für das Anwendungsbeispiel des Münchner Taxiverkehrs wurden im Rahmen einer Voranalyse [205, S. 23–25] $T_{\text{reb}} = 20$ min und $T = 2$ ermittelt.

Eingangsdaten

Die Vorhersage soll auf Basis historischer Auftragsdaten (Abfahrtsort, Abfahrtszeit) erfolgen. Zusätzlich stehen weitere sekundäre Datensätze (Kapitel 3) zur Verfügung.

5.4.2 Architektur Prädiktionsframework

Wie in Abschnitt 2.2.2 gezeigt, kommen in der Literatur unterschiedliche Methoden für die Vorhersage des Fahrgastaufkommens zum Einsatz. Da die Bewertung dieser Methoden in der Literatur oft nur für den dort dargestellten Anwendungsfall gültig ist, lässt sich daraus lediglich eine Vorauswahl geeigneter Methoden ableiten. Die finale Auswahl und Parametrierung des Modells muss jedoch anhand des tatsächlichen Anwendungsfalles erfolgen [210, S. 145]. Im Rahmen dieser Arbeit wurde daher für den Vergleich unterschiedlicher Modelle ein modulares Prädiktionsframework entwickelt⁴. Abbildung 5.13 zeigt die Architektur des Frameworks. Das Basismodell gibt dabei eine generalisierte Struktur für die Implementierung einzelner Teilmodelle vor. Je nach Methode und Parametrierung des gewählten Modells ergeben sich unterschiedliche Anforderungen an die Struktur und Art der Eingangsdaten. Für den Trainingsprozess müssen daher für jedes Modell individuelle Eingangsdaten generiert werden. In diesem Schritt erfolgt auch die räumlich-zeitliche Diskretisierung. Dazu werden die beschreibenden Variablen x und die Zielgrößen y für jedes Vorhersagegebiet in Zeitreihen $x_g(t)$, $y_g(t)$ überführt. Durch eine Entkopplung der Eingangsdatengenerierung und dem Modell selbst ist sichergestellt, dass die Teilmodelle auch für weitere Anwendungsbeispiele in der Zukunft verwendet werden können.

5.4.3 Modellierung von Zeitreihen als Supervised Learning Problem

Bei der Vorhersage zukünftiger Werte einer Zeitreihe mithilfe vergangener Beobachtungen handelt es sich um ein Supervised Learning (engl. überwachtetes Lernen) Problem. Ziel ist es dabei, eine Funktion f zu

⁴Der Quellcode des Prädiktionsframeworks und seiner Teilmodelle ist auf GitHub unter folgender URL veröffentlicht: <https://github.com/TUMFTM/mod-prediction-framework>

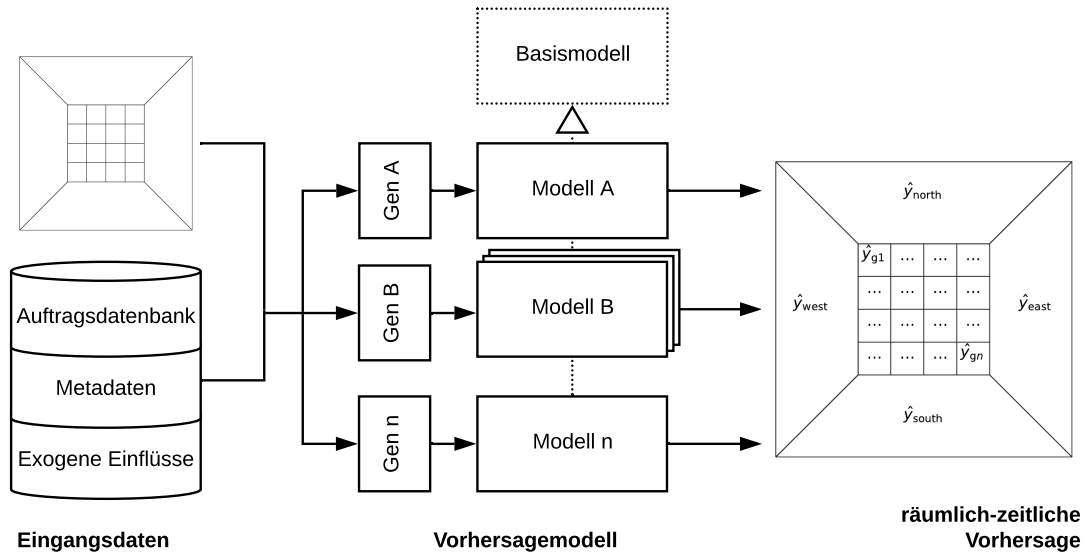


Abbildung 5.13: Modulare Architektur des Prädiktionsframeworks

bestimmen, die eine möglichst genaue Abbildung $Y = f(X)$ der Eingangswert(e) (X) auf die Zielwert(e) (Y) liefert [97, S. 24]. Dabei soll diese Abbildung auch für unbekannte Eingangswerte gelten.

Diskretisierung

Im Fall des Anwendungsbeispiels des Münchner Taxiverkehrs bestehen die Beobachtungen aus einzelnen, unabhängigen Ereignissen (Startzeit, Startort). Diese müssen in einem ersten Schritt in eine raum-/zeitdiskrete Zeitreihe überführt werden. Dazu werden alle Ereignisse pro Gebiet innerhalb eines Zeitintervalls aufsummiert (Tabelle 5.2). $y_g(t)$ beschreibt also die Summe aller Fahrten innerhalb des Gebiets g für das Intervall $[t, t + \Delta t[$

Tabelle 5.2: Beispiel für die Umwandlung der Rohdaten in eine raum-/zeitdiskrete Zeitreihe

(a) Rohdaten				(b) Raum-/zeitdiskrete Zeitreihe				
#	Startort	Startzeit	...	t	y_0	y_1	y_2	y_3
1	(48.13878, 11.57013)	2019-04-08 00:00:03	...	2019-04-08 00:00:00	8	5	15	8
2	(48.13953, 11.55649)	2019-04-08 00:01:12	...	2019-04-08 00:20:00	20	2	12	7
3	(48.26463, 11.66870)	2019-04-08 00:05:25	...	2019-04-08 00:40:00	16	3	16	10
...	2019-04-08 01:00:00	15	7	18	6
n	(48.14857, 11.56867)	2019-04-08 01:00:05	...	2019-04-08 01:20:00	6	8	20	7

Lags

In der Regel werden mehrere vergangene Zeitschritte (Bsp. $y(t), y(t-1), y(t-2)$) für die Bestimmung der Funktion f benötigt. In der englischsprachigen Literatur spricht man dabei von "Lags". $t-1$ entspricht "Lag 1", $t-2$ "Lag 2", etc. [211]. Durch Verschieben der Zielwerte $y(t)$ um $t-i$ lässt sich ein Eingangsvektor, x_i (Lag i) erzeugen. Analog kann vorgegangen werden, wenn mehrere zukünftige Zeitschritte vorhergesagt werden sollen. Tabelle 5.3 zeigt dies am Beispiel der Zeitreihe y_0 für $i \in \{1, 2\}$

Tabelle 5.3: Lagged Supervised Learning Problem

(a) Einschrittprognose			(b) Mehrschrittprognose			
x_{t-2}	x_{t-1}	y_t	x_{t-2}	x_{t-1}	y_t	y_{t+1}
–	–	8	–	–	8	20
–	–	20	–	–	20	16
8	20	16	8	20	16	15
20	16	15	20	16	15	6
16	15	6	16	15	6	–
...

5.4.4 Vorgehen zur Modellauswahl

Zur Auswahl eines geeigneten Modells für die räumlich-zeitliche Vorhersage der Kundennachfrage wurden, basierend auf bewährten Methoden des Stands der Technik (Abschnitt 2.2.2), unterschiedliche Ansätze und Eingangs- und Hyperparameterkombinationen in Konzeptstudien [205, 206, 208, 212–214] untersucht. Gemäß der Empfehlung von Brownlee [210, S. 158] erfolgt die Bewertung einzelner Methoden iterativ immer im Vergleich zum besten bisher existierenden Modell. Die Güte einzelner Modelle wird dabei anhand der Fehlermetriken engl. root mean square error (RMSE), engl. mean absolute error (MAE) und R^2 bewertet.

Für die Auswahl eines geeigneten Prädiktionsansatzes wurden folgende Methoden als Modell innerhalb des Frameworks implementiert und anhand des Referenzdatensatzes bewertet:

- **Einfache Modelle:** persistente Vorhersage, gleitender Mittelwert
- **Autoregressive Modelle:** ARIMA, SARIMA
- **Rekurrente neuronale Netze:** LSTM, ConvLSTM

5.4.5 Teilmodelle

Der folgende Abschnitt beschreibt die zur finalen Bewertung herangezogenen Teilmodelle. Mit Ausnahme der Methode ConvLSTM gilt: Für jedes Vorhersagegebiet $g \in G$ muss ein eigenes Modell für die Vorhersage trainiert werden. Beispiel: Für die Vorhersage eines Gebiets mit 8×8 Zellen und vier Randgebieten mit der Methode ARIMA müssen 68 einzelne Modelle des Typs ARIMA trainiert werden.

Einfache Modelle

Als Minimalreferenz werden für den weiteren Vergleich die Naive Vorhersage und die Methode des gleitenden Mittelwerts herangezogen (Absatz 2.2.2).

Autoregressive Modelle

Für die Vorhersage (saisonaler) Zeitreihen eignen sich nach [99] autoregressive Modelle der (S)ARIMA Klasse⁵. Die Beschreibung eines ARIMA Prozesses erfolgt anhand der Parameter (p, d, q) . Dabei definiert p und q die Ordnung (Anzahl der zu berücksichtigenden Zeitschritte) der Autoregression bzw. des gleitenden Mittelwerts. Der Parameter d gibt an, wie oft die Zeitreihe differenziert werden muss, um diese in einen stationären Prozess zu überführen. Weist eine Zeitreihe zusätzlich eine saisonale Komponente auf – wie im Referenzbeispiel anhand des zyklischen Tages- und Wochenverlaufs zu erkennen – kann dies durch einen SARIMA Prozess mithilfe der Parameterkombination $(p, d, q)(P, D, Q)m$ beschrieben werden. Die Kombination (P, D, Q) beschreibt dabei analog zu dem gerade beschriebenen Parameter (p, d, q) die Ordnungen

⁵Aus Gründen des Umfangs wird an dieser Stelle auf eine ausführliche Beschreibung der statistischen Grundlagen verzichtet. Es sei hierfür auf die Grundlagenliteratur z. B. [99] verwiesen.

der saisonalen Komponente. Über den Parameter m wird die Periodendauer der saisonalen Komponente beschrieben. Beispiel: Für eine täglich wiederkehrende Periode in einer stündlich diskretisierten Zeitreihe ist $m = 24$ zu wählen. Die Bestimmung der bestmöglichen Parameterkombination im Falle des Referenzbeispiels erfolgt iterativ mittels Permutation (Grid-Search Algorithmus) (vgl. [208]). Die Implementierung erfolgt mithilfe des Python Moduls *StatsModels* [215].

Rekurrente neuronale Netze

Im Vergleich zu klassischen, statistischen Verfahren bieten neuronale Netze im Allgemeinen mehr Freiheiten bei der Modellierung zusätzlicher beschreibender Variablen [97, S. 3]. Wie im Stand der Technik gezeigt, eignen sich auf Grund ihres rekurrenten Aufbaus dabei besonders LSTM-Netze zur Vorhersage von Zeitreihen. Für die Implementierung wird das Machinelearning Framework *Keras* [216] auf Basis von *TensorFlow* [217] verwendet. Im Folgenden werden zwei Varianten eines LSTM-Netzwerks vorgestellt. Der Aufbau der neuronalen Netze orientiert sich dabei an den Empfehlungen in [97, 210, 218].

Eingangsvektor Lags

Für den Trainingsprozess werden die räumlich diskreten Zeitreihen wie in Unterabschnitt 5.4.3 beschrieben in einen Eingangsvektor überführt, der die Beobachtungen der letzten n Zeitschritte umfasst (Beispiel Tabelle 5.4).

Tabelle 5.4: Beispiel für den Eingangsvektor der Lag Variablen für $n = 36$

t	x_{t-36}	...	x_{t-11}	x_{t-10}	x_{t-9}	x_{t-8}	x_{t-7}	x_{t-6}	x_{t-5}	x_{t-4}	x_{t-3}	x_{t-2}	x_{t-1}
25.05.2015 00:00:00	25	...	23	15	13	10	15	20	19	12	13	11	10
25.05.2015 00:20:00	29	...	15	13	10	15	20	19	12	13	11	10	8
25.05.2015 00:40:00	35	...	13	10	15	20	19	12	13	11	10	8	10

Eingangsvektor Metadaten

Für die in dieser Arbeit untersuchten neuronalen Netze wurde der Einfluss folgender kategorischer Metadaten auf die Prognosequalität in Vorstudien [157, 158, 206, 208] untersucht:

- Stunde des Tages (x_{h0}, \dots, x_{h23})
- Wochentag (x_{d0}, \dots, x_{d6})
- Schulferien ($x_{FA}, x_{OS}, x_{PF}, x_{SO}, x_{HE}, x_{WI}$)
- Öffentlicher Feiertag (x_{PH})
- Oktoberfest ($x_{oktFest}$)
- Wetter ($x_{temp}, x_{percep}, x_{hum}$)
- Öffentliche Veranstaltungen ($x_{g,event}$)
- Verpätungen im ÖPNV ($x_{g,OEPNV}$)

Dabei wurde gezeigt, dass durch das Hinzufügen von Wetter, Veranstaltungsdaten und Verspätungen im ÖPNV keine weitere Verbesserung der Vorhersage erreicht werden kann. Mögliche Hypothesen, die eine weitergehende Analyse benötigen, sind:

- **H1:** Informationen bezüglich Veranstaltungen sind bereits implizit im räumlich-zeitlichen Verlauf der Kundennachfrage enthalten. Eine zusätzliche Modellierung als Eingangsvariable bringt deshalb keinen Vorteil.
- **H2:** Die Datenqualität des Veranstaltungsdatensatzes ist ungenügend. Dieser enthält nur den Beginn, aber nicht das Ende einer Veranstaltung. Zudem ist unbekannt, wie viele Personen an einer Veranstaltung teilnehmen.

- **H3:** Unterschiedliche Arten von Veranstaltung üben einen unterschiedlichen Einfluss auf das Nachfrageverhalten aus. Hierzu wäre eine gezielte Einflussanalyse von Veranstaltungsart und -Ort nötig, um entsprechende Eingangsvariablen zu erzeugen.
- **H4:** Das Wetter hat im Allgemeine keinen Einfluss auf die kurzfristige Dynamik der Kundennachfrage. Die lokalen Effekte im Bezug auf das untersuchte Gebiet sind zu vernachlässigen.
- **H5:** Wie in [157] gezeigt, kann nur bei sehr großen Verspätungen im ÖPNV ein Effekt auf die Fahrgastnachfrage nachgewiesen werden. Ereignisse dieser Art treten aber zu selten auf, um die Prognosequalität nachhaltig positiv zu beeinflussen.

Für die folgenden Modelle ergibt sich somit, neben dem zeitlichen Verlauf der Nachfrage, ein zusätzlicher Eingangsvektor mit 39 Einträgen. Die kategorischen Variablen werden als binäre Werte kodiert (engl. one-hot encoding) [219]. Tabelle 5.5 zeigt beispielhaft den resultierenden Eingangsvektor:

Tabelle 5.5: Beispiel für den Eingangsvektor der Metadaten

t	x_{h0}	...	x_{h23}	x_{d0}	...	x_{d6}	x_{FA}	x_{OS}	x_{PF}	x_{SO}	x_{HE}	x_{WI}	$x_{oktFest}$	x_{PH}
25.05.2015 00:00:00	1	...	0	1	...	0	0	0	1	0	0	0	0	1
25.05.2015 00:20:00	1	...	0	1	...	0	0	0	1	0	0	0	0	1
25.05.2015 00:40:00	1	...	0	1	...	0	0	0	1	0	0	0	0	1

LSTM Modell mit Metadaten

Das erzeugte neuronale Netze besteht aus zwei parallelen Eingangssträngen (Abbildung 5.14)⁶. Die letzten n Beobachtungen (Eingangsvektor Lags) werden dabei, wie von Brownlee [97, S. 128] empfohlen, in einem LSTM Strang verarbeitet. Im Falle des Eingangsvektors Metadaten handelt es sich um kategorische Variablen. Diese werden in einem separaten MLP Strang verarbeitet. Beide Stränge werden anschließend verkettet. Zum Schutz vor einer Überanpassung des Netzwerkes (Overfitting) wird eine zusätzliche Dropout Schicht eingebracht [220]. Ausgang des Netzwerkes bilden die nächsten T vorherzusagenden Werte der Zeitreihe. Da dieses Netz nicht in der Lage ist, räumliche Zusammenhänge abzubilden, wird für jedes Vorhersagegebiet ein eigenes Netz trainiert und anschließend zur Vorhersage genutzt. Diese Architektur bietet jedoch den Vorteil, dass sie unmittelbar auch für eine globale Vorhersage der Gesamtnachfrage bzw. des Fahrzeugangebots verwendet werden kann.

ConvLSTM Modell mit Metadaten

Im Gegensatz zu herkömmlichen LSTM Netzen sind ConvLSTM Netze, mittels Faltung benachbarter Matrixeinträge in der Lage, auch räumliche Zusammenhänge abzubilden [112]. Die Kernelgröße definiert dabei die Anzahl an Zellen der Faltung. Wie auch im vorherigen Fall werden die Eingangsdaten in zwei Strängen von dem neuronalen Netz gelernt. Der Eingangsvektor mit den vergangenen Werten der Zeitreihe wird als dreidimensionaler Tensor übergeben. Dabei geben n die Anzahl an Lags und i, j die Anzahl an Zeilen und Spalten des räumlichen Rasters an. Zwei aufeinander folgende ConvLSTM Schichten bilden den räumlich-zeitlichen Verlauf der Eingangsgröße ab. Im Unterschied zum vorherigen Modell werden hier die parallelen Stränge am Ende durch ein Hadarmad Produkt fusioniert und an die Ausgangsschicht übergeben (Abbildung 5.15).

Diese Netz-Architektur bringt den Vorteil mit sich, dass anstatt $i \cdot j$ einzelner Modelle lediglich ein Modell für das ganze Vorhersagegebiet trainiert werden muss.

⁶Aus Gründen des Umfangs wird an dieser Stelle auf eine ausführliche Beschreibung verzichtet und auf die entsprechende Grundlagenliteratur [97, 210, 218] verwiesen.

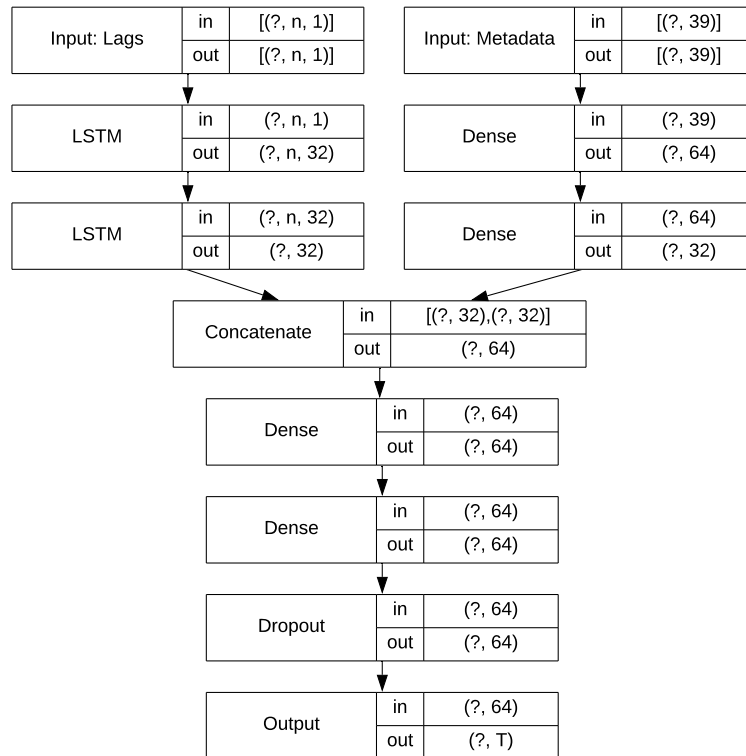


Abbildung 5.14: Architektur hybrides LSTM mit Metadaten. (n , Anzahl der Lags, T Vorhersagehorizont)

Trainings-/Validierungsprozess, Hyperparameter

Für beide LSTM-Modelle gelten die gleichen Trainingsbedingungen. Der zu trainierende Datensatz wird dazu in Trainings-, Validierungs- und Testdatensatz aufgeteilt [221]. Dabei werden 67 % der nicht zum Testen verwendeten Daten direkt für das Training des Modells und 33 % für die Validierung des Trainingsprozesses verwendet. Das Training wird maximal für 100 Epochen durchgeführt und frühzeitig abgebrochen, falls über zehn Epochen die Vorhersage der Validierungsdaten nicht verbessert wurde (engl. early stopping) [222]. Als Gütemaß für den Trainingsprozess wird die mittlere quadratische Abweichung engl. mean square error (MSE) verwendet. Die Optimierung erfolgt mit der Methode *Adam* [223], mit den in Keras [216] hinterlegten Standardparametern. Die Optimierung der Hyperparameter erfolgt mit der Rastermethode (engl. grid search).

Modellbewertung und -Auswahl

Zur Auswahl eines geeigneten Vorhersagemodells werden die im letzten Abschnitt beschriebenen Modelle mit historischen Daten aus dem Zeitraum 09.03.2015–31.12.2018 trainiert, und deren Prognosegüte für den Zeitraum 01.01.2019–31.12.2019 bestimmt. Dieser ist identisch mit dem späteren Simulationszeitraum. Für die Modellbewertung werden im ersten Schritt ausschließlich Einschrittprognosen herangezogen und das beste Modell anschließend zu einer Zweischrittvorhersage erweitert. In Bezug auf die räumliche Diskretisierung wurden zwei Varianten für die Einteilung des inneren Gebietes G untersucht. Dies wurde dazu in 4x4 und 8x8 Zellen unterteilt.

Die Güte einzelner Modelle wird dabei anhand der Fehlermetriken RMSE und MAE und R^2 bewertet. Um die Aussagekraft der Fehlermaße zu erhöhen, wurden dazu nur Gebiete berücksichtigt, welche während des Trainingszeitraums durchschnittlich mindestens eine Fahrt pro Zeitschritt aufweisen. Wie in Abschnitt 2.3.1 bereits angemerkt, besteht ansonsten die Gefahr, die Vorhersagegüte des Modells zu überschätzen.

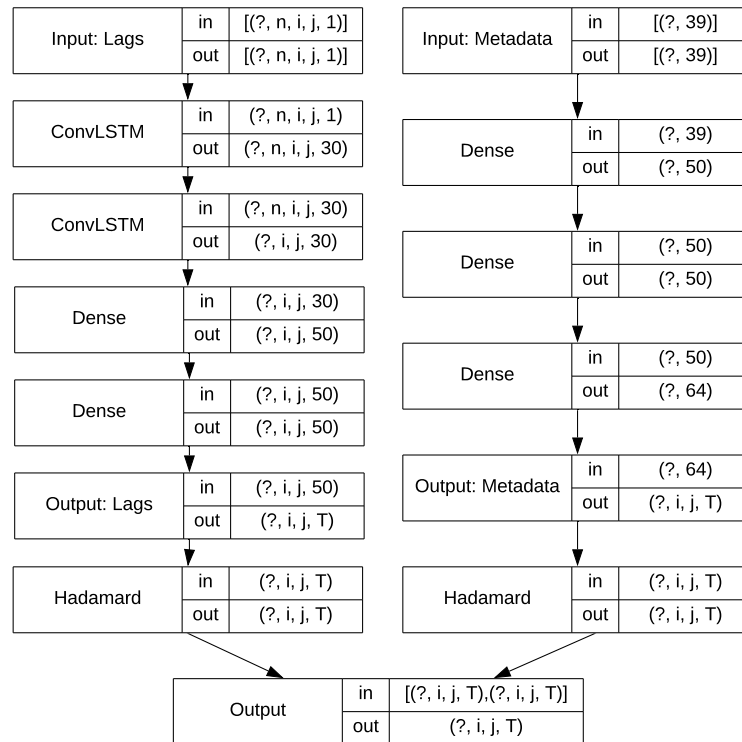


Abbildung 5.15: Architektur hybrides ConvLSTM mit Metadaten. (i, j , Anzahl der Reihen, Spalten des uniformen Rasters, n , Anzahl der Lags, T Vorhersagehorizont)

Einschrittprognose

Tabelle 5.6 fasst die Fehlermetriken einzelner Modelle für die Einschrittprognose zusammen. Zur weiteren Differenzierung werden die Fehlerwerte gemittelt für die Gebiete g_i und die Randbereiche b_i separat aufgeführt. Zusätzlich dazu gibt X_{sum} das jeweilige Maß für den globalen Fehler aus der Summer aller Einzelvorhersagen an. Die Ergebnisse zeigen, dass die Modellvariante LSTM mit Metadaten die niedrigsten Fehler in der Vorhersage ermöglicht. Für einzelne Zellen innerhalb des Gebiets G beträgt die gemittelte quadratische Abweichung (RMSE) 1,938 Fahrten. Bezogen auf die absolute Anzahl an Anfragen in der Stadt beträgt die durchschnittliche mittlere quadratische Abweichung 9,20 Fahrten. Während die Fehlerwerte RMSE und MAE einen Eindruck über die Größenordnung des Fehlers vermitteln, lässt sich die Güte der Vorhersage mit Hilfe des Regressionskoeffizienten, R^2 , bestimmen. Dieser beträgt für das LSTM Modell mit Metadaten gemittelt über alle Gebiete 0,426 und für die globale Vorhersage 0,886. Auffallend ist an dieser Stelle die schwache Prognosequalität der Modellvariante ConvLSTM, welche knapp über der Minimalreferenz des Persistenzmodells liegt. Es ist wahrscheinlich, dass die Vorhersagequalität in diesem Anwendungsbeispiel negativ von Zellen mit wenigen, zufälligen Beobachtungen beeinflusst wird (Abbildung 5.16).

Vergleicht man die Ergebnisse der beiden räumlichen Diskretisierungen, bleiben die beschriebenen Unterschiede zwischen den Modellen weiterhin gültig, wenn auch die Prognosequalität insgesamt sinkt. Zwar weisen die Modelle niedrigere Fehlerwerte auf, hierbei muss aber berücksichtigt werden, dass pro Zelle nur noch ein Viertel des Gebiets abgedeckt wird und dementsprechend auch weniger Fahrten pro Zelle stattfinden. Dies wird deutlich, wenn man den R^2 -Wert für beide Varianten vergleicht. Dieser verschlechtert sich innerhalb der Gebiete von 0,426 auf 0,353 durch eine feinere Gebietseinteilung. Gleichzeitig wird jedoch in der aufsummierten Betrachtung aller Gebiete auf globaler Ebene eine bessere Vorhersage erzielt. Auf Basis der gezeigten Metriken wird für den weiteren Verlauf dieser Arbeit das Modell LSTM mit Metadaten für die Vorhersage der Kundennachfrage verwendet.

Tabelle 5.6: Prognosegüte der Einschnittprognose einzelner Vorhersagemethoden im Zeitraum 01.01.2019-31.12.2019.

Modell/Fehlermetrik	RMSE _G	MAE _G	R _G ²	RMSE _B	MAE _B	R _B ²	RMSE _{sum}	MAE _{sum}	R _{sum} ²
<i>G</i> (8x8 km, <i>n</i> = 16), <i>g_i</i> (2x2 km), <i>B</i> (5 km), Δ <i>t</i> = 20 min									
Persistenzmodell	2.552	1.905	-0.021	2.969	2.267	0.088	10.212	7.867	0.859
Gleitender Mittelwert (<i>w</i> =3)	2.178	1.648	0.277	2.532	1.939	0.344	10.775	8.169	0.843
ARIMA(2, 0, 1)	2.104	1.591	0.341	2.455	1.871	0.386	11.479	8.700	0.822
SARIMA(2, 0, 1)(2, 0, 2, 3)	2.096	1.588	0.344	2.450	1.871	0.388	11.225	8.486	0.830
ConvLSTM	2.525	1.805	0.170	2.275	1.750	0.470	15.964	10.494	0.656
LSTM	1.938	1.487	0.426	2.272	1.748	0.471	9.200	7.044	0.886
<i>G</i> (8x8 km, <i>n</i> = 64), <i>g_i</i> (1x1 km), <i>B</i> (5 km), Δ <i>t</i> = 20 min									
Persistenzmodell	1.857	1.330	-0.162	2.969	2.267	0.088	8.481	6.488	0.831
Gleitender Mittelwert (<i>w</i> =3)	1.560	1.159	0.189	2.532	1.939	0.344	8.605	6.485	0.820
ARIMA(2, 0, 1)	1.494	1.112	0.266	2.455	1.871	0.386	9.754	7.349	0.776
SARIMA(2, 0, 1)(2, 0, 2, 3)	1.487	1.109	0.271	2.450	1.871	0.388	9.305	7.025	0.796
ConvLSTM	1.672	1.282	0.154	2.273	1.749	0.470	12.065	10.113	0.658
LSTM	1.392	1.061	0.353	2.271	1.748	0.472	7.915	6.078	0.853

Abbildung 5.16 zeigt zur weiteren Einordnung der lokalen Unterschiede in der Prognosequalität einen Ausschnitt der Vorhersage des Modells LSTM mit Metadaten für den Zeitraum während des Oktoberfests 2019. Besonders deutlich wird hierbei die lokal stark unterschiedliche Qualität der Vorhersage. In manchen Gebieten ist das Nachfrageaufkommen so gering und von zufälligen Ausschlägen geprägt, dass lediglich ein mittlerer Nachfrageverlauf angenähert werden kann (wie im Beispiel gezeigt für die Zelle (0, 0)). Zwar beträgt der mittlere absolute Fehler im gezeigten Zeitraum hierbei mit 1,1 knapp mehr als eine Fahrt, ein Wert von $R^2 = 0,0243$ zeigt jedoch die schlechte Approximation des Verlaufs der tatsächlichen Zeitreihe. Deutlich bessere Vorhersagen können in Gebieten mit ausreichender Nachfrage erzielt werden. Wie hier für die Gebiete (2, 0) und (1, 0) gezeigt, lässt sich die Dynamik des Verlaufs mit einem R^2 -Wert von 0,793 bzw. 0,887 sehr gut abbilden.

Mehrschrittprognose

Wie in Abschnitt 5.4.1, erfordert das Optimierungsproblem der prädiktiven Rebalancingstrategie einen Prognosehorizont von 2x20 min. Hierzu wird das zuvor ausgewählte Modell um einen weiteren Prognoseschritt erweitert. Tabelle 5.7 zeigt für beide räumlichen Diskretisierungsstufen, die Fehlerwerte für die Vorhersageschritte $t = 0$ und $t = 1$. Die Ergebnisse zeigen, dass in beiden Fällen die Prognosegüte im zweiten Zeitschritt leicht abfällt, jedoch immer noch auf einem vergleichbaren Niveau der Einschnittprognose liegt.

Tabelle 5.7: Prognosegüte des Modells LSTM mit Metadaten für die Vorhersage von 2 Zeitschritten im Zeitraum 01.01.2019-31.12.2019.

Modell/Fehlermetrik	RMSE _g	MAE _g	R _g ²	RMSE _b	MAE _b	R _b ²	RMSE _{sum}	MAE _{sum}	R _{sum} ²
<i>G</i> (8x8 km, <i>n</i> = 16), <i>g_i</i> (2x2 km), <i>B</i> (5 km), Δ <i>t</i> = 20 min									
LSTM $t = 0$	1.938	1.487	0.426	2.272	1.748	0.471	9.200	7.044	0.886
LSTM $t = 1$	1.958	1.499	0.416	2.323	1.776	0.450	9.635	7.335	0.875
<i>G</i> (8x8 km, <i>n</i> = 64), <i>g_i</i> (1x1 km), <i>B</i> (5 km), Δ <i>t</i> = 20 min									
LSTM $t = 0$	1.392	1.061	0.353	2.271	1.748	0.472	7.915	6.078	0.853
LSTM $t = 1$	1.401	1.066	0.345	2.320	1.777	0.452	8.207	6.274	0.842

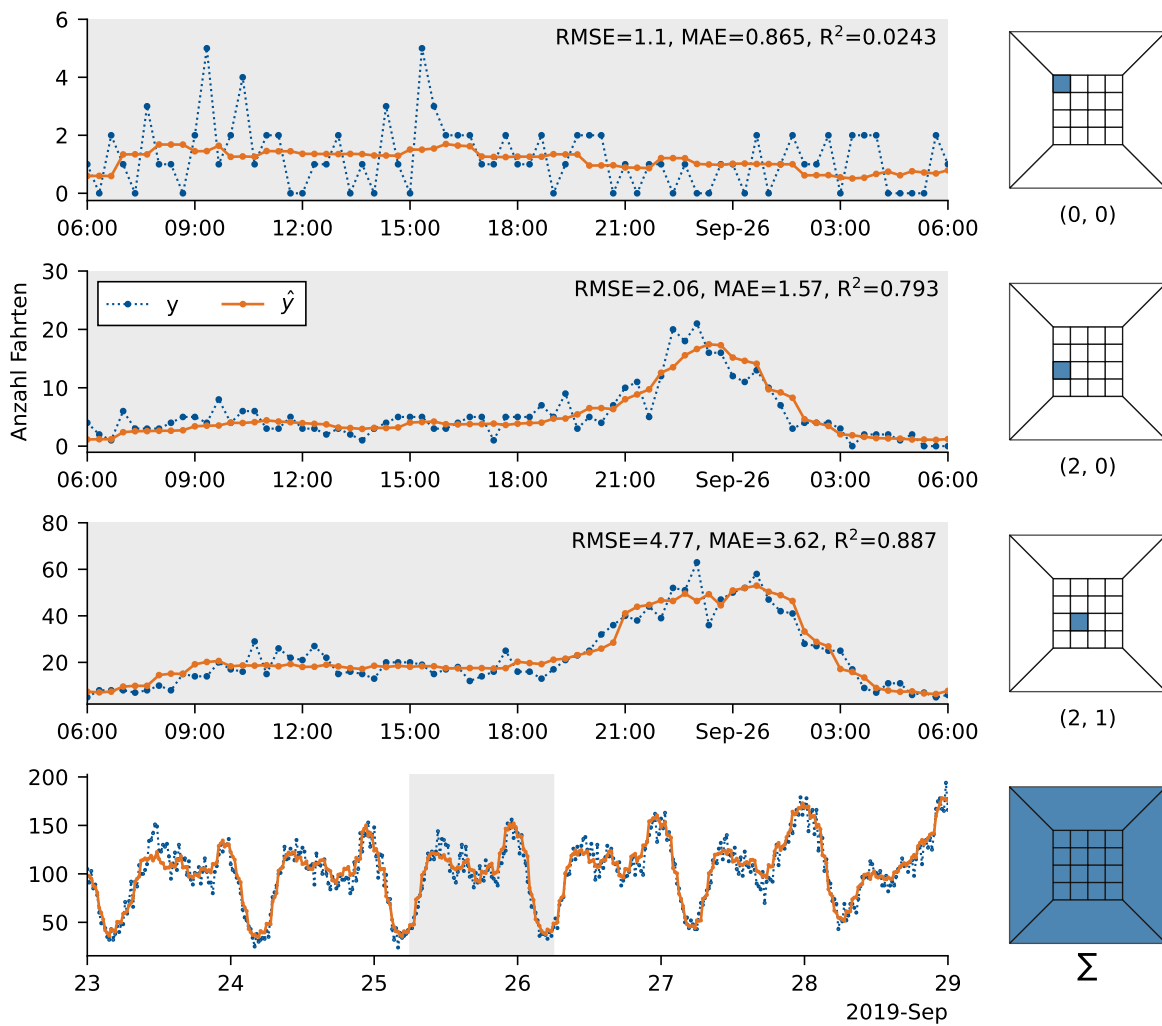


Abbildung 5.16: Einschrittprognose des Modells LSTM mit Metadaten im Zeitraum 23.09.2019–29.09.2019. Vorhersageintervall $\Delta t = 20$ min

5.4.6 Zusammenfassung

In diesem Abschnitt wurde die Entwicklung, Auswahl und Bewertung eines Modells zur räumlich-zeitlichen Vorhersage der Kundennachfrage vorgestellt. Dabei wurden mehrere Methoden zur Vorhersage von Zeitreihen miteinander verglichen und ein geeignetes Modell für den weiteren Verlauf der Arbeit identifiziert. Es wurde festgestellt, dass sich die Qualität der Vorhersage örtlich stark unterscheidet und deswegen eine differenzierte Bewertung des Prognosemodells erforderlich ist. Die Ergebnisse zeigen, dass die gesetzten Anforderungen der Rebalancingstrategie mit dem Prognosemodell erreicht werden können.

5.5 Anpassung der Flottengröße

Wie in Abschnitt 4.1.1 gezeigt, variiert das Angebot an Fahrzeugen in realen Anwendungsfällen zeitabhängig. Die Anzahl an verfügbaren Fahrzeugen hat einen erheblichen Einfluss auf die zu untersuchende Flottenstrategie. Um in der Simulation eine realitätsgetreue Abbildung darzustellen, wird das Simulationsframework AMoDeus um eine weitere Teilfunktion erweitert. Abbildung 5.17 zeigt schematisch den dazu implementierten Algorithmus zur dynamischen Anpassung der Flottengröße. In der Simulation wird zu dis-

kreten Zeitpunkten (T_{fs}) geprüft, ob die Anzahl an aktiven Fahrzeugen, $x_{\text{active}}(t)$, dem vorgegebenen Sollwert, $\hat{x}_{\text{active}}(t)$, entspricht. Der Sollwertverlauf wird dabei zu Beginn der Simulation über die Eingangsdaten vorgegeben (Abbildung 5.1). Sind zum Zeitpunkt der Überprüfung mehr Fahrzeuge aktiv als der Sollwert, wird versucht, diese Differenz durch Abmelden aktiver Fahrzeuge auszugleichen (Abbildung 5.2). Es werden dabei nur Fahrzeuge, die aktuell keinen Kundenauftrag zugewiesen bekommen haben, abgemeldet. Befindet sich ein Fahrzeug im Status Rebalancing, beendet es die Aktion am aktuellen Ort und wechselt in den Status Parken/Warten, bevor es abgemeldet wird. Abgemeldete Fahrzeuge verbleiben an dem letzten bekannten Ort bis zu ihrer Wiederanmeldung. Die Auswahl der Fahrzeuge erfolgt aufgrund der Dauer, die ein Fahrzeug in der Simulation aktiv war. Sind zum Zeitpunkt der Überprüfung zu wenig Fahrzeuge aktiv, werden entsprechend des Sollwerts inaktive Fahrzeuge reaktiviert. Diese starten ihre Aktion an dem letzten bekannten Aufenthaltsort.

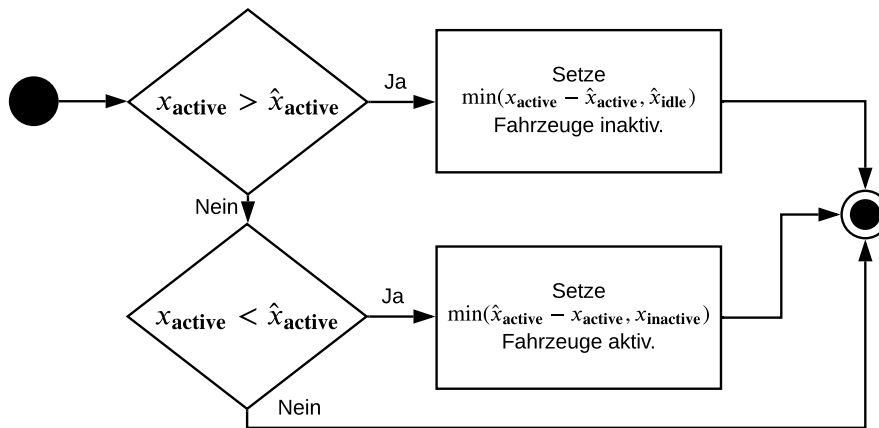


Abbildung 5.17: Algorithmus zur dynamischen Anpassung der Flottengröße (Angebot an Fahrzeugen)

6 Simulationsszenarien und Ergebnisse

In diesem Kapitel werden die Ergebnisse der Simulationsstudie vorgestellt. Am Anwendungsbeispiel des Münchner Taxiverkehrs werden dabei die Potentiale einer optimierten Flottenstrategie bewertet. Zu Beginn des Kapitels werden allgemeingültige Eingangsgrößen für die weiteren Simulationen definiert. Anschließend wird der Einfluss von Vermittlungsstrategie, Rebalancingstrategie und Flottengröße auf die Bewertungskriterien Umsatz/Kosten und Servicequalität bewertet.

Vergleichsgrundlage für die Bewertung sind dabei die Ergebnisse der simulierten Referenzstrategie. Diese wird in Unterkapitel 6.2 auf Basis des Beobachtungsdatensatzes validiert. Es ist somit sichergestellt, dass evtl. Modellungenauigkeiten in Bezug auf die Abbildung der Realität keinen Einfluss auf die Bewertung der untersuchten Flottenstrategien haben.

6.1 Allgemeine Randbedingungen

Dieser Abschnitt fasst alle allgemeingültigen Randbedingungen und Eingangsparameter der nachfolgenden Simulationsszenarien zusammen. Die Beschreibung szenariospezifischer Parameter erfolgt im jeweiligen erklärenden Abschnitt.

Simulationszeitraum

Der Untersuchungszeitraum der Simulationsstudie umfasst das Jahr 2019. Die Simulation erfolgt auf Wochenbasis. Jede Einzelsimulation startet am Montag einer Woche um 00:00 Uhr und endet am darauffolgenden Montag um 06:00 Uhr. Die ersten sechs Stunden dienen dabei als Einschwingphase und bleiben im Verlauf der weiteren Auswertung unberücksichtigt. Der Zeitraum wurde zudem so gewählt, dass dieser mit dem Schichtwechsel (06:00 Uhr) der Referenzflotte übereinstimmt. Es ergeben sich somit für jedes Szenario 52 Einzelsimulationen.

Fahrzeugflotte

Die Anzahl verfügbarer Fahrzeuge wird während der Simulation dynamisch an eine Sollwertvorgabe angepasst (Unterkapitel 5.5). Die dazu benötigten Eingangsdaten werden vor Beginn der Simulation aus dem Referenzdatensatz für den jeweiligen Simulationszeitraum ermittelt.

Straßennetzwerk

Das Simulationsgebiet umfasst den Großraum München. Das in Abbildung 6.1 abgebildete Gebiet, bestehend aus dem Stadtzentrum München und den umliegenden Gemeinden, deckt 99,31 % der Fahrten des Referenzdatensatzes ab. Das zu Grunde liegende Straßennetz wurde dazu aus OpenStreetMap [161] extrahiert und für die Simulation aufbereitet. Da die Simulationsdauer auf Grund der Vielzahl an Routenberechnungen unter anderem wesentlich von der Größe des verwendeten Straßennetzwerks abhängt, werden außerhalb des Stadtgebiets lediglich Hauptstraßen und Nebenstraßen (OSM-Tag: *motorway*, *trunk*, *primary*, *secondary*, *tertiary*, *unclassified*, *motorway_link*, *trunk_link*, *primary_link*, *secondary_link*, *tertiary_link*) modelliert. Im Stadtzentrum werden alle für den Typ Auto freigegebenen Wege abgebildet. Durch dieses Vorgehen kann die Anzahl an Wegen um 95 % reduziert werden [224], bei gleichzeitiger hoher räumlicher Abdeckung in der Simulation.

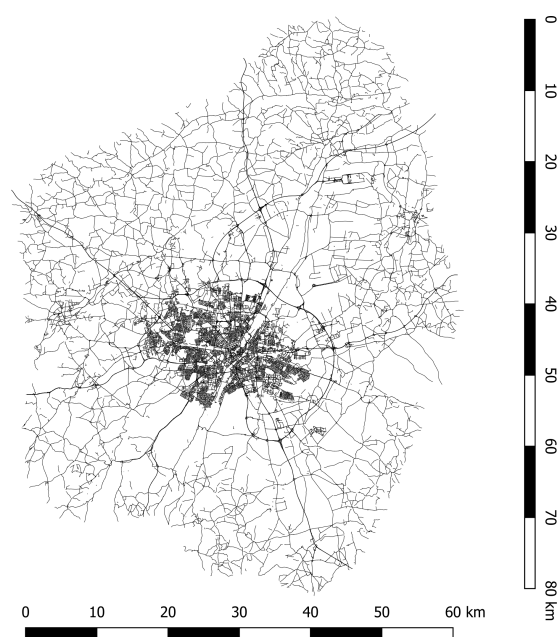


Abbildung 6.1: Verwendetes hybrides Straßennetzwerk der Simulation (Daten: OpenStreetMap, unter ODbL)

Verkehr

Das verwendete Simulationsframework, MATSim, wurde ursprünglich entwickelt, um ausgehend von Aktivitäten einzelner Personen auf das Verkehrsgeschehen zu schließen [18, S. 3–4]. Normalerweise ergibt sich also als Ergebnis einer MATSim-Simulation die zeitlich variable Auslastung des Straßennetzwerkes beziehungsweise die Reisezeit für jeden Straßenabschnitt. Im Rahmen dieser Simulationsstudie werden jedoch nur Fahrzeuge der Testflotte simuliert. Ohne weitere Anpassung würde dies zu niedrigen Reisezeiten in der Simulation führen, weil die Auswirkungen des restlichen Verkehrs unberücksichtigt blieben. Ruch et al. [12] schlagen aus diesem Grund ein Vorgehen zur iterativen Bestimmung der Straßenabschnittsgeschwindigkeit vor. Ausgehend von real beobachteten Fahrdauern der Testflotte werden die zeitlich variablen Geschwindigkeitsvorgaben für alle möglichen Straßenabschnitte einer Route so lange iterativ angepasst, bis die Reisezeiten denen der realen Fahrzeugflotte entsprechen. Die zeitliche Auflösung beträgt für diesen Anwendungsfall 7,5 min. Da der Simulationszeitraum im Vergleich zu [12] erheblich größer ist, wurde für die Anwendung in dieser Arbeit der Algorithmus optimiert, um die benötigte Anzahl an Iterationen zu verringern:

- Die Lernrate e , wird anstatt eines konstanten durch einen linearen Verlauf vorgegeben. Der Algorithmus konvergiert so zu Beginn schneller in Richtung der Lösung.
- Anstatt einer Initialisierung mit der maximal zulässigen Straßenabschnittsgeschwindigkeit, werden die für eine repräsentative Woche vorberechneten Abschnittsgeschwindigkeiten als Initialwert verwendet.

Für das gewählte Szenario sind 280 000 Iterationen pro Simulationswoche notwendig, um realistische Fahrtzeiten in der Simulation zu erreichen.

Abbildung 6.2 zeigt das Ergebnis der Anpassung beispielhaft für eine ausgewählte Simulationswoche. Es ist deutlich zu erkennen, dass Fahrtzeiten in der Simulation ohne weitere Anpassung zu kurz angenommen würden. Durch die iterative, zeitlich-dynamische Anpassung der Abschnittsgeschwindigkeiten können realistische Reisezeiten erreicht werden, ohne den Umverkehr mitsimulieren zu müssen. Abbildung 6.2 zeigt

außerdem, dass die Anpassung der Abschnittsgeschwindigkeiten keinen wesentlichen Einfluss auf die generelle Routenwahl (Fahrstrecke) hat.




Abbildung 6.2: Anpassung der Straßenabschnittsgeschwindigkeit am Beispiel der Simulationswoche 04.11.2019–11.11.2019 nach 280 000 Iterationen. Links: Fahrtzeiten vor und nach Anpassung im Vergleich zur Referenz. Rechts: Fahrtstrecken vor und nach Anpassung im Vergleich zur Referenz

Die angepassten, zeitlich veränderlichen Straßenabschnittsgeschwindigkeiten werden für jede zu simulierende Woche des Untersuchungszeitraums einmalig vorberechnet und als Eingangsdaten der Simulation übergeben.

Aufträge

Die Abbildung der Kundennachfrage erfolgt gemäß des in Absatz 3.1 beschriebenen Datensatzes durch die Parameter Start-/Zielort und Abfahrtszeit. Zusätzlich zu der im Rahmen der Datenaufbereitung erfolgten Datenfilterung werden alle Fahrten mit dem Startort Flughafen ausgeschlossen (1,78 %) (Abschnitt 4.1.2). Abbildung 6.3 zeigt das simulierte Auftragsvolumen für jede Woche des Simulationszeitraums




Abbildung 6.3: Übersicht Anzahl Kundenaufträge im Simulationsszenario

Weitere allgemeingültige Parameter

Alle nachfolgend beschriebenen Szenarien verwenden einheitlich die in Tabelle 6.1 dargestellten Parameter. Alle Fahrten, die eine maximale Wartezeit von 30 min bzw. eine maximale Vermittlungszeit von 3 min

überschreiten, werden als abgelehnt deklariert. Die angenommenen Werte basieren auf Expertenaussagen [175] und sind nicht durch Kundenumfragen validiert. Da diese Werte jedoch konstant für alle Szenarien angenommen werden, ist eine Vergleichbarkeit zwischen den Szenarien gewährleistet.

Für Lohn- und variable Streckenkosten werden die in Unterkapitel 4.3 hergeleiteten Werte verwendet. Die Fahrpreiserlöse berechnen sich gemäß der aktuell gültigen Taxitarifordnung der Landeshauptstadt München [156].

Für die Ein- und Ausstiegsdauer werden 162 s angenommen. Dieser Wert wurde auf Basis des zur Verfügung stehenden Referenzdatensatzes empirisch ermittelt.

Tabelle 6.1: Allgemeingültig übergreifende Simulationsparameter für alle simulierten Strategien

Parameter	Wert
Flottengröße Basiswert	490 Fzg.
Simulationszeitraum Gesamt	31.12.2018 00:00–30.12.2019 06:00
Simulationszeitraum Einzelsimulation	1 Woche (Mo 00:00 Uhr–Mo 06:00 Uhr)
Einschwingphase	6 h
Maximale Vermittlungsdauer, $t_{\text{disp,max}}$	3 min
Maximale Kundenwartezeit, $t_{\text{wait,max}}$	30 min
Fixkosten pro Fzg., c_{fix}	255,04 €/Woche
Variable Lohnkosten, c_{lohn}	12,56 €/h
Variable Streckenkosten, c_{km}	0,200 €/km
Basisfahrtpreis, e_{basis}	3,7 €/km [156]
Variabler Fahrtpreis e_{var}	1,7 –2 €/km [156]
Einstiegsdauer pro Kunde, t_{pickup}	162 s
Ausstiegsdauer pro Kunde, t_{dropoff}	162 s
Intervall Anpassung Flottengröße, T_{fs}	60 s

Orchestrierung und Parallelisierung der Simulation

Die durchschnittliche Simulationsdauer für eine Woche beträgt, anhängig von der Komplexität der gewählten Strategie, zwischen einer und sechs Stunden (Referenz: CPU: Intel Xeon@2.4 GHz, RAM: 25 GB). Da die einzelnen Parameter-Kombinationen voneinander unabhängig sind, kann die insgesamt benötigte Simulationsdauer durch Parallelisierung verkürzt werden. Dazu werden die Simulationen, wie in [225] beschrieben, mit Hilfe von Docker parallelisiert. Die Simulationsdauer skaliert somit direkt mit der Anzahl an verfügbaren CPU. Für diese Arbeit wurde eine virtuelle Maschine des Leibniz-Rechenzentrums (20 CPU Intel Xeon@2.4 GHz, 632 GB RAM) verwendet.

Notation

Für die weitere Beschreibung der Szenarien wird folgende Notation verwendet:

Rebalancingstrategie-Vermittlungsstrategie-Flottengröße

Die Abkürzung REF-GBPM-90 beschreibt also das Simulations-Szenario Rebalancing gemäß Referenzstrategie und die Vermittlung gemäß Bipartiten Matching mit einer auf 90 % skalierten Fahrzeugflotte. Dabei wird sowohl der zeitliche Verlauf des Fahrzeugangebots, als auch die absolute Flottengröße auf den angegebenen Wert skaliert. Tabelle 6.2 fasst weitere verwendete Abkürzungen zusammen:

Tabelle 6.2: Verwendete Notation zur Beschreibung der Simulationsszenarien

Abkürzungen	Beschreibung
Rebalancingstrategien	
REF	Referenzstrategie
FFR	engl. feedforward fluidic optimal rebalancing policy (FFR)
PRLP4x4	Prädiktive, gewinnmaximierende Rebalancing Strategie mit 4x4 Vorhersagezellen
PRLP8x8	Prädiktive, gewinnmaximierende Rebalancing Strategie mit 8x8 Vorhersagezellen
Vermittlungsstrategien	
REF	Referenzstrategie
GBPM	engl. global bipartite matching (GBPM)
NTNR	engl. nearest taxi nearest request (NTNR)
Flottengröße	
90	90 % des zeitlich variablen Angebots an Fahrzeugen

6.2 Referenzszenario/Validierung

Als Vergleichsgrundlage für alle nachfolgend dargestellten Ergebnisse dient die Simulation eines Referenzszenarios. Dieses bildet die aktuell von der Referenzflotte praktizierte Vermittlungs- und Rebalancing Strategie ab und wird anhand des vorliegenden Referenzdatensatzes validiert. Die Validierung erfolgt anhand von flotten-, fahrt- und kundenbezogenen Kennwerten für jede der 52 simulierten Wochen des Referenzszenarios.

6.2.1 Parameter

Neben den in Unterabschnitt 6.1 beschriebenen, allgemeinen Parametern, gelten für das Referenzszenario folgende, in Tabelle 6.3 dargestellte, Parameter. Die Vermittlung folgt der in Abschnitt 5.2.1 beschriebenen Sektorvermittlung. Für das Vermittlungsintervall T_{disp} werden in der Simulation zur Reduzierung der Rechenzeit 10 s angenommen. Die Zuweisung der Aufträge erfolgt nichtsdestotrotz sequenziell nach Auftragsingang. Die Rebalancing Strategie folgt analog zur Vermittlung dem in Abschnitt 5.3.1 beschriebenen Ablauf. Dabei wählen Fahrzeuge nach Abschluss eines Auftrags unmittelbar ihren nächsten Zielort ($T_{reb} = 1$ s). Zusätzlich wird im Intervall $T_{reb} = 1200$ s geprüft, ob genügend Fahrzeuge im Zentrum vorhanden sind und diese bei Bedarf umverteilt. Der zeitliche Verlauf der Flottengröße wird zu 100 % aus dem Referenzdatensatz übernommen.

Tabelle 6.3: Simulationsparameter Referenzstrategie

Parameter	REF-REF-100
Vermittlungsstrategie	Referenzstrategie (REF)
Vermittlungsintervall, T_{disp}	10 s
Rebalancingstrategie	Referenzstrategie (REF)
Rebalancing Intervall, T_{reb}	1 s 1200 s
Flottengröße	100 % (490 Fzg.)

6.2.2 Flottenbezogene Kennwerte

Zur Bewertung des Flottenverhaltens werden die in Abbildung 6.4 und der zugehörigen Tabelle 6.4 dargestellten Kennwerte herangezogen.

- **Summe Arbeitsstunden:** Aufsummierte Arbeitszeit aller aktiven Fahrzeuge pro Woche

- **Mittlere Flottenauslastung:** Mittelwert der wöchentlichen Auslastungsrate der Fahrzeugflotte
- **Summe Fahrleistung:** Gesamt gefahrene Kilometer der Fahrzeugflotte pro Woche
- **Summe Kosten:** Summe der lohn- und streckenbezogenen Kosten pro Woche
- **Summe Umsatz:** Summe aller Fahrerlöse pro Woche

Die dargestellten Abweichungen in Prozent berechnen sich aus der Differenz von Simulation zu Referenzdaten, bezogen auf den Referenzdatensatz für jede Woche des Simulationszeitraums.

Tabelle 6.4: Aggregierte prozentuale Abweichung Simulation/Referenzdaten für 52 Wochen in 2019

	Arbeitsstunden	Flottenauslastung	Fahrleistung	Kosten	Umsatz
Unterer Whisker	-0,32 %	0,58 %	-4,05 %	-0,84 %	0,34 %
Q ₂₅	-0,22 %	5,05 %	-1,12 %	-0,38 %	1,19 %
Median	-0,18 %	6,88 %	-0,44 %	-0,19 %	1,67 %
Mittelwert	-0,16 %	6,97 %	0,15 %	-0,09 %	1,73 %
Q ₇₅	-0,11 %	9,02 %	1,32 %	0,13 %	2,28 %
Oberer Whisker	0,02 %	12,04 %	4,37 %	0,82 %	3,50 %




Abbildung 6.4: Aggregierte Abweichung Simulation/Referenzdaten für 52 Wochen in 2019

Flottengröße, Fahrzeugangebot

Der zeitliche Verlauf des Angebots an Fahrzeugen bestimmt maßgeblich die Auftragskapazität und Kosten der Fahrzeugflotte. Abbildung 6.5 zeigt stellvertretend den Vergleich von Simulation zu Referenzdaten für die Simulationswoche KW 45 2019. Es ist zu erkennen, dass der zeitliche Verlauf der Sollwertvorgabe folgt.




Abbildung 6.5: Verlauf der Flottengröße für das Referenzszenario (Samplingfrequenz 5 min), Arbeitsstunden am Beispiel der KW 45 2019

Betrachtet man die daraus resultierende Summe an Arbeitsstunden (Abbildung 6.4, Tabelle 6.4) ist zu erkennen, dass die Angebotskurve dem vorgegebenen Sollwert mit einer geringen Abweichung von $-0,16\%$ folgt und somit den realen Verlauf abbildet. Kleinere, in ihrer Auswirkung zu vernachlässigende, Schwankungen können in folgenden Situationen entstehen:

- Die Anpassung an die Sollwertvorgabe erfolgt im Intervall T_{fs} alle 60 s. Freie fahrende Fahrzeuge werden erst abgemeldet, wenn sie den nächsten Straßenabschnitt erreichen. Im ungünstigen Fall fährt das Fahrzeug also noch einige Sekunden weiter, bis die Sollwertvorgabe greift.
- Nur freie Fahrzeuge können abgemeldet werden. Existieren im Moment der Sollwertvorgabe keine oder zu wenige freie Fahrzeuge, werden diese erst im nächsten Anpassungsschritt abgemeldet.
- Durch diesen Effekt kann es im nachfolgenden Schritt auch dazu kommen, dass zu wenige neue Fahrzeuge angemeldet werden.

Flottenauslastung

Die Flottenauslastung ist ein maßgebliches Kriterium für die Bewertung der Effizienz und Elastizität der Fahrzeugflotte. Abbildung 6.6 zeigt beispielhaft den zeitlichen Verlauf der simulierten Auslastung für die Simulationswoche KW 45 im Vergleich zu dem Validierungsdatensatz. Es ist zu erkennen, dass die Simulation den real beobachteten Verlauf in Umfang und Dynamik mit einem mittleren Fehler von $6,97\%$ im Validierungszeitraum abbilden kann. Die mittlere Flottenauslastung ist in allen 52 Wochen höher als in Realität beobachtet. Diese Abweichung resultiert im Wesentlichen aus dem Umstand, dass in der Simulation im Gegensatz zum Validierungsdatensatz keine Direkteinstiege möglich sind. Durch die im Vergleich höhere Anzahl an Anfahrten steigt die Flottenauslastung im Vergleich zum Validierungsdatensatz. Hinzu kommt, dass Ein- und Ausstiegszeiten im Validierungsdatensatz unberücksichtigt sind. Auch diese erhöhen die Flottenauslastung in der Simulation im Vergleich zu den Validierungsdaten.




Abbildung 6.6: Vergleich Flottenauslastung Simulation/Referenzszenario am Beispiel der KW 45 2019

Fahrleistung

Die Flottenfahrleistung hat, neben den Arbeitsstunden, einen direkten Einfluss auf die Betriebskosten der Fahrzeugflotte. Der mittlere Fehler über alle Wochen des Validierungsszenarios beträgt $0,15\%$ und weist eine geringe Streuung auf. Es kann somit festgestellt werden, dass die Gesamtfahrleistung durch das Simulationsmodell korrekt abgebildet wird.

Kosten/Umsatz

In der direkten Folge aus der korrekten Abbildung der Arbeitsstunden und Flottenfahrleistung kann bestätigt werden, dass auch die Kostenberechnung in der Simulation vergleichbare Werte in Bezug auf den Validierungsdatensatz liefert. Die mittlere Abweichung beträgt an dieser Stelle $-0,09\%$.

Bezogen auf den Umsatz beträgt der mittlere Validierungsfehler $1,73\%$. Dieser resultiert aus den geringfügig höheren Fahrtstrecken bei Besetztfahrten im Vergleich zu dem Validierungsdatensatz (Abschnitt 6.2.3)

6.2.3 Fahrtbezogene Kennwerte

Die Bewertung des individuellen Fahrzeugverhaltens erfolgt auf Basis einzelfahrtbezogener Kennwerte. Abbildung 6.7 zeigt den Vergleich der benötigten Distanzen und Fahrzeiten pro Fahrt und Fahrtzweck am Beispiel der KW 45–2019. Es ist zu erkennen, dass in der Simulation sowohl Strecke, als auch Dauer für Fahrten der Kategorien *Anfahrt* und *Besetzt* korrekt abgebildet werden. Wie im vorherigen Abschnitt beschrieben finden jedoch mehr Anfahrten als in Realität statt. Dies hat zur Folge, dass die insgesamt zurückgelegte Anfahrstrecke im Vergleich zum Referenzdatensatz über das Jahresmittel um 150% zu hoch angenommen wird (Abbildung 6.8).

Es ist zudem zu erkennen, dass die Fahrten des Typs Rebalancing im Vergleich zu den beobachteten Werten in Strecke und Dauer als zu gering angenommen werden. Die Simulation ist an dieser Stelle durch die hinterlegte Entscheidungsheuristik reglementiert. Das individuelle Verhalten einzelner Taxifahrer kann nicht aus den Realdaten extrahiert werden. Die Kalibrierung der Referenz-Rebalancingstrategie erfolgte anhand der räumlichen Fahrzeugverteilung, um eine möglichst akkurate Wartezeit abbilden zu können. Auf die Gesamtfahrleistung bezogen gleichen sich die Effekte der längeren Anfahrstrecke und der geringeren Rebalancing Strecke aus und haben somit keinen nachteiligen Einfluss auf die Bewertung der Strategie.

Abbildung 6.7 bestätigt außerdem, dass die dynamische Anpassung der Straßenabschnittsgeschwindigkeiten korrekt funktioniert.

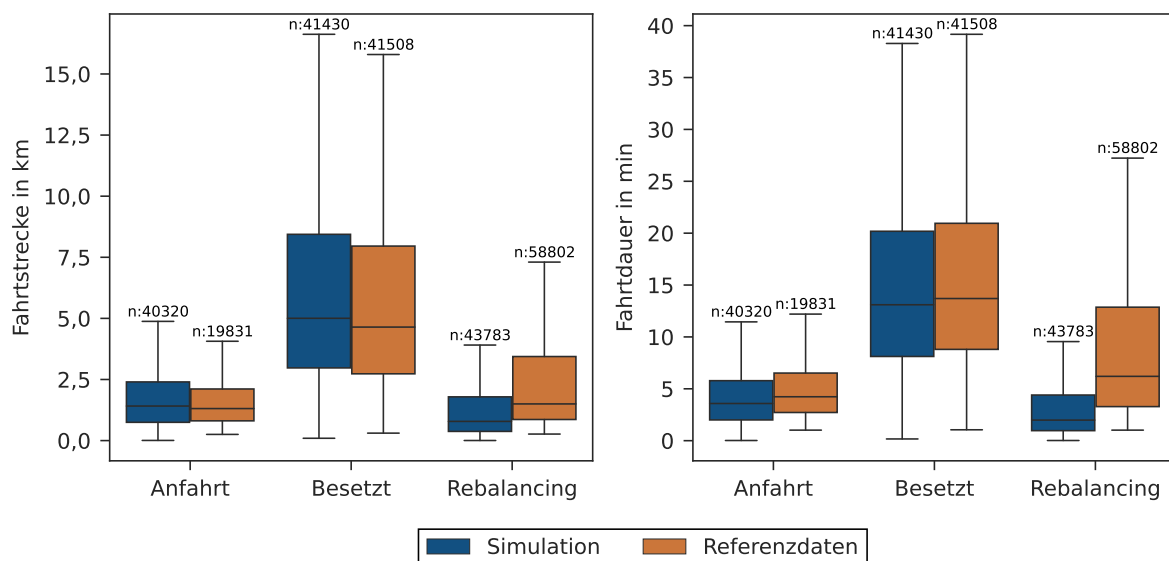


Abbildung 6.7: Vergleich Fahrtstrecke und -dauer Simulation/Referenzszenario am Beispiel der KW 45–2019




Abbildung 6.8: Wöchentliche prozentuale Abweichung der kumulierten Distanz nach Fahrzeugstatus

6.2.4 Kundenbezogene Kennwerte

Neben den flotten- und fahrtbezogenen Kennwerten bestimmen kundenbezogene Kennwerte (Wartezeit, Auftragserfüllungsquote) die Service-Qualität des Gesamtsystems und stellen ein zentrales Bewertungskriterium dar.

Wartezeit

Als Kundenwartezeit t_{wait} wird die Zeitspanne zwischen Auftragseingang und Eintreffen des Fahrzeugs am Abholort definiert. Abbildung 6.9 zeigt beispielhaft die Häufigkeitsverteilung der simulierten und beobachteten Wartezeiten in KW 45–2019. Es ist zu erkennen, dass die Art und Varianz der Verteilung korrekt abgebildet wird.




Abbildung 6.9: Vergleich Kundenwartezeit Simulation/Referenzdatensatz am Beispiel der KW 45 2019. Links: Histogramm der Wartezeiten (Bingröße 1 min) Rechts: Kumulative Häufigkeitsverteilung (CDF) der Wartezeiten

Dies gilt, wie Abbildung 6.10 zeigt, auch für die Betrachtung des gesamten Simulationszeitraums. Der mittlere Fehler beträgt im Vergleich zu dem Referenzdatensatz 0,73 % (Q_{25} : -5,84 %, Q_{75} : 5,07 %).

Auftragserfüllungsquote

Der Kennwert Auftragserfüllungsquote gibt an, welcher Prozentsatz an eingehenden Kundenanfragen tatsächlich bedient wird. Übersteigt die maximal tolerierte Vermittlungs- bzw. Wartezeit den definierten Grenzwert, wird die Fahrt als nicht durchführbar gewertet. Im Falle des Referenzszenarios sollten möglichst alle




Abbildung 6.10: Vergleich Kundenwartezeit Simulation/Referenzdatensatz für alle simulierte Wochen in 2019. Links: Mittlere Wartezeit pro Simulationswoche (X), Q_{25} - Q_{75} (I). Rechts: Wöchentliche prozentuale Abweichung der mittleren Wartezeit

beobachteten Fahrten auch in der Simulation als durchführbar gewertete werden. Abbildung 6.11 zeigt die bedienten Kundenanfragen im Vergleich von Simulation zu Referenzdatensatz. Es ist zu erkennen, dass die Grenzwerte nur in sehr geringem Umfang (Mittelwert 0,84 %) überschritten werden. Dies betrifft bei genauerer Analyse vor allem Kundenanfragen an den Rändern des Simulationsgebietes.




Abbildung 6.11: Vergleich Auftragserfüllungsquote Simulation/Referenz. Links: Summe bedienter Kunden pro Woche, Rechts: Verteilung der Ablehnungsquote pro Simulationswoche in Prozent

6.2.5 Fazit

Der Vergleich von simulierter Referenzstrategie und dem real beobachteten Referenzdatensatz hat gezeigt, dass das Simulationsmodell in der Lage ist, den aktuellen Ist-Zustand korrekt und mit ausreichender Genauigkeit abzubilden. Im folgenden Verlauf der Arbeit wird nun die simulierte Referenzstrategie (REF) als Vergleichsgrundlage für alle weiteren Ergebnisse verwendet. Durch dieses Vorgehen ist sichergestellt, dass durch das Modell induzierte Fehler im Vergleich unterschiedlicher Strategien für jede Strategie im gleichen Umfang gelten. Eine Übertragbarkeit der Ergebnisse auf die Realität ist unter Berücksichtigung der Validierungsfehler dennoch gegeben, weil Fehler im Vergleich zwischen Szenarien gering sind [226].

6.3 Änderung der Vermittlungsstrategie

Die Vermittlungsstrategie hat einen wesentlichen Einfluss auf die Servicequalität. Durch die Art der Zuweisung von Aufträgen zu Fahrzeugen bestimmt sie im Wesentlichen die Anfahrtswege und die daraus resultierenden Wartezeiten der Kunden. Als erstes Optimierungspotential wird in diesem Abschnitt der Einfluss verschiedener Vermittlungsstrategien in Bezug auf die Servicequalität und das Flottenverhalten untersucht.

6.3.1 Szenarien

Auf Basis der Analyse des Stands der Technik werden die Vermittlungsmethoden GBPM und NTNR ausgewählt und deren Wirksamkeit in Bezug auf das validierte Referenzszenario für München bewertet. Tabelle 6.5 zeigt die dazu verwendeten Simulationsparameter. Um die Leistungsfähigkeit der Vermittlungsansätze unter erhöhter Auslastung zu untersuchen, wird zudem die dynamische Flottengröße von 100 bis 60 % variiert.

Tabelle 6.5: Parameter Simulationsszenarien bei Änderung der Vermittlungsstrategie

Parameter	REF-REF	REF-GBPM	REF-NTNR
Vermittlungsstrategie	Referenzstrategie (REF)	Globales Bipartites Matching (GBPM)	Nearest taxi nearest request (NTNR)
Vermittlungsintervall, T_{disp}	10 s	30 s	10 s
Rebalancingstrategie	Referenzstrategie (REF)	Referenzstrategie (REF)	Referenzstrategie (REF)
Rebalancing Intervall, T_{reb}	1 s 1200 s	1 s 1200 s	1 s 1200 s
Flottengröße	100 bis 60 %	100 bis 60 %	100 bis 60 %

6.3.2 Ergebnisse

Servicequalität

Die Bewertung des Einflusses alternativer Vermittlungsstrategien in Bezug auf die Servicequalität erfolgt anhand der Kennwerte mittlere Wartezeit, mittlere Vermittlungsdauer und der Quote abgelehnter Fahrten. Abbildung 6.12 zeigt die Werte der Parameter auf Wochenbasis in Bezug auf die dynamische Flottengröße und Vermittlungsstrategie. Bei Betrachtung der mittleren wöchentlichen Wartezeit ist zu erkennen, dass sowohl GBPM als auch NTNR eine Reduzierung der Wartezeit bewirken. Dieser Effekt verstärkt sich zugunsten der beiden alternativen Vermittlungsstrategien bei reduzierter Flottengröße. Keine der Strategien kann einen Anstieg der Wartezeit verhindern, jedoch mildern beide den Anstieg im Vergleich zu REF deutlich ab.

Bezüglich der Vermittlungsdauer bewegen sich alle dargestellten Strategien für 100 % Flottengröße im Bereich ihres Erwartungswertes. Während die Vermittlungsdauer bei REF deutlich mit abnehmender Flottengröße ansteigt, können GBPM und NTNR diese auf einem niedrigen Niveau halten. Relativ gesehen ist die Verschlechterung der mittleren Vermittlungsdauer bei GBPM am geringsten. Absolut gesehen erreicht NTNR bis zu einer reduzierten Flottengröße von 70 % geringere Vermittlungszeiten.

Die bisherigen Ergebnisse lassen sich auch auf die letzte Kenngröße, die wöchentliche Ablehnungsquote, übertragen. Während diese bei REF mit erhöhter Flottenauslastung schnell ansteigt, können GBPM und NTNR die Ablehnungsquote bei 90 % Flottengröße noch auf dem gleichen Niveau wie REF halten. Auch hier müssen jedoch ab 80 % Flottengröße Einbußen in Kauf genommen werden. Diese werden jedoch durch GBPM und NTNR reduziert.




Abbildung 6.12: Einfluss der Vermittlungsstrategie auf die mittlere wöchentliche Wartezeit (Links), die mittlere wöchentliche Vermittlungsdauer (Mitte) und die wöchentliche Ablehnungsquote (Rechts)

Flottenverhalten

Die Ursache der im vorangegangenen Abschnitt beschriebenen Effekte wird bei der Betrachtung des Flottenverhaltens deutlich. Abbildung 6.13 zeigt den Einfluss der Vermittlungsstrategie auf die Anfahrtstrecke pro Simulationswoche. Sowohl wöchentlicher Mittelwert, als auch Median zeigen, dass die Anfahrtstrecke durch GBPM und NTNR reduziert wird, was in Konsequenz in einer niedrigeren Wartezeit resultiert. Mit Reduktion der Flottengröße steigt die Anfahrtstrecke an. Dies zeigt sich auch in der absoluten Änderung der Gesamtanfahrtsstrecke im Vergleich zu REF-REF-100. Hervorzuheben ist an dieser Stelle, dass die Gesamtanfahrtsstrecke trotz höherer Bedienrate bei GBPM und NTNR kleiner ist als bei REF. Deutlich wird an dieser Stelle, dass der global optimierende Ansatz GBPM auch lokal eine bessere Lösung des Vermittlungsproblems erreicht als der lokal optimierende Ansatz NTNR

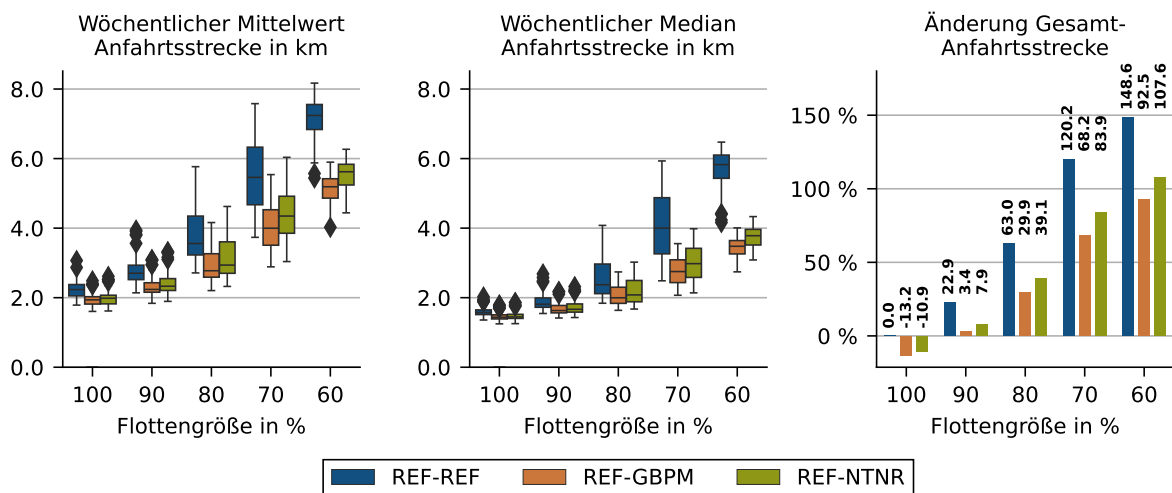


Abbildung 6.13: Einfluss der Vermittlungsstrategie auf die Anfahrtstrecke: Wöchentlicher Mittelwert in km (Links), wöchentlicher Median (Mitte), wöchentliche Gesamtstrecke im Vergleich zu REF-REF-100 (Rechts)

Die Änderung der Anfahrtstrecke hat einen unmittelbaren Einfluss auf die Flottenauslastung. Diese ist im Wesentlichen über die drei Faktoren Anzahl aktiver Fahrzeuge, Anfahrtsdauer und Dauer Kundenfahrt beeinflusst. Es wird angenommen, dass die Dauer einer Kundenfahrt selbst nicht beeinflusst werden kann. Die

beiden anderen Parameter sind in ihrer Wirkung gegensätzlich. Während eine Reduktion der Anzahl aktiver Fahrzeuge die Auslastung der Fahrzeugflotte steigert, sind in Folge reduzierter Anfahrtswege Fahrzeuge zeitlich in geringerem Umfang gebunden, was die Flottenauslastung senkt. Bei gleichbleibender Kundennachfrage kann also die Reduktion der Anfahrtswege dazu beitragen, zusätzliche Potentiale für die Reduktion der Fahrzeugflotte zu schaffen.

Abbildung 6.14 zeigt den Einfluss von Vermittlungsstrategie und reduzierter Flottengröße auf die flottenbezogenen Kennwerte, mittlere Flottenauslastung, Kosten und Umsatz. Beide alternativen Strategien schaffen es nur in geringem Maße, die Flottenauslastung im Vergleich zu REF zu senken, wohl gleich GBPM dies bei abnehmender Flottengröße am stärksten vermag. In Bezug auf die Kosten ist zu erkennen, dass die Reduktion der Flottengröße einen weitaus größeren Hebel darstellt als die Verkürzung der Anfahrtswege in Folge einer geänderten Vermittlungsstrategie. Hierbei muss die höhere Erfüllungsquote gedanklich mitberücksichtigt werden. Bezogen auf die Anfahrt sinken die Kosten. Insgesamt steigen diese jedoch, weil mehr Aufträge erfüllt werden können und somit mehr Kilometer zurückgelegt werden. Betrachtet man den generierten Umsatz wird, wie bereits im vorherigen Abschnitt gezeigt, deutlich, dass Kostenvorteile bei gleichbleibendem Umsatz nur durch alternative Vermittlungsstrategien zu erreichen sind.




Abbildung 6.14: Einfluss der Vermittlungsstrategie auf die Kennwerte: Mittlere Flottenauslastung, Kosten 2019 (Differenz zu REF-REF-100 in %) und Umsatz 2019 (Differenz zu REF-REF-100 in %)

6.3.3 Fazit

Die Analyse alternativer Vermittlungsstrategien hat gezeigt, dass sowohl durch den Einsatz von GBPM, als auch von NTNR, die Servicequalität im Vergleich zur aktuell praktizierten Strategie gesteigert werden kann. Beide untersuchten Strategien vermögen dies in einer vergleichbaren Größenordnung. Dabei zeigt im direkten Vergleich die global optimierende Methode GBPM geringe Vorteile gegenüber NTNR, welche aber erst bei höheren Auslastungen in Folge einer reduzierten Flottengröße zum Tragen kommen. In Bezug auf die Betriebskosten der Fahrzeugflotte lassen sich durch die Änderung der Vermittlungsstrategie selbst keine relevanten Einsparungen erzielen. Jedoch wird deutlich, dass ohne eine Anpassung der Vermittlungsstrategie Kosteneinsparungen auf Betreiberseite nicht ohne eine Verschlechterung der Servicequalität zu erreichen sind. Eine optimierte Vermittlungsstrategie ermöglicht also weiteres Einsparpotential.

Es bleibt zu untersuchen, inwiefern eine Optimierung des Vermittlungsintervalls T_{disp} dieses Potential erhöht. Weiteres Optimierungspotential besteht in der kontinuierlichen Neuzuweisung von Kunden und Fahrzeugen (engl. Reassignment bzw. Redispatching) [70, 85]. Die Akzeptanz in einem Szenario mit menschl-

chen Fahrern ist jedoch fraglich (Absatz 2.2.1) und wurde deshalb an dieser Stelle nicht näher untersucht. Wie vergleichbare Studien [68, 85, 86] zeigen, ist in Szenarien mit autonomen Fahrzeugen mit einer weiteren Reduzierung der Wartezeit zu rechnen.

6.4 Änderung der Rebalancingstrategie

Die räumliche Verteilung der Fahrzeugflotte hat neben der im vorigen Abschnitt untersuchten Vermittlungsstrategie ebenfalls einen direkten Einfluss auf die Servicequalität. Durch eine günstige Positionierung der Fahrzeuge lassen sich Anfahrtswege und in der Folge Wartezeiten verkürzen. Der folgende Abschnitt beschreibt den Einfluss der Rebalancingstrategie auf kunden- und betreiberrelevante Kenngrößen.

6.4.1 Szenarien

Für die folgende Untersuchung werden die beiden alternativen Strategien FFR [129] und PRLP [204] im Vergleich zur Referenzstrategie der Münchner Testflotte untersucht. Die Fahrgastvermittlung erfolgt in allen Szenarien mit der Strategie GBPM. Tabelle 6.6 gibt eine Übersicht der in diesem Abschnitt untersuchten Strategien und deren Parametern. Für die Strategie FFR werden die in [19] definierten Standardeinstellungen verwendet ($T_{\text{reb}} = 30$ s, $k = 12$). Die in Abschnitt 5.3.2 vorgestellte, prädiktive, gewinnmaximierende Rebalancingstrategie PRLP wird in zwei Varianten untersucht, um den Einfluss der räumlichen Diskretisierung darzustellen. Dazu wird das Vorhersagegebiet einmal in 16 Zellen der Größe 2x2 km (PRLP4x4) und einmal in 64 Zellen der Größe 1x1 km (PRLP8x8) unterteilt. In beiden Fällen wird $T_{\text{reb}} = 20$ min gewählt. Dementsprechend ist auch der Prognosehorizont des Vorhersagemodells mit 2x20 min zu wählen. Als weitere Parameter des linearen Optimierungsproblems werden für die streckenbezogenen Kosten $\alpha = 0,1855$ €/km und für den Umsatzverlust einer nicht durchgeführten Fahrt innerhalb des Rebalancingintervalls $\lambda = 12,26$ €/Fahrt angenommen. Dieser Wert wurde auf Basis des Realdatensatzes ermittelt und entspricht dem durchschnittlich generierten Umsatz einer Kundenfahrt im Zeitraum von 20 min. Alle untersuchten Strategien werden in Bezug auf das validierte Referenzszenario REF-REF-100 bewertet.

Tabelle 6.6: Parameter Simulationsszenarien bei Änderung der Rebalancingstrategie

Parameter	REF-GBPM	FFR-GBPM	PRLP4x4-GBPM	PRLP8x8-GBPM
Vermittlungsstrategie	GBPM	GBPM		GBPM
Vermittlungsintervall, T_{disp}	10 s	30 s		30 s
Rebalancingstrategie	REF	FFR		PRLP
Räumliche Diskretisierung	Taxistände/Kerngebiet	K-Means ($k = 12$)	4x4 Zellen (2x2 km)	8x8 Zellen (1x1 km)
Prognosemodell	-	-		LSTM
Prognosehorizont	-	-		2x20 min
Optimierungsparameter	-	-	$\lambda = 12,26$ €/Fahrt, $\alpha = 0,1855$ €/km	
Rebalancingintervall, T_{reb}	1 s 20 min	30 s		1 s 20 min
Flottengröße	100 bis 60 %	100 bis 60 %		100 bis 60 %

6.4.2 Ergebnisse

Servicequalität

Abbildung 6.15 zeigt den Einfluss alternativer Rebalancing Strategien in Bezug auf die mittlere wöchentliche Wartezeit und die Quote an abgelehnten Fahrten. Es ist zu erkennen, dass durch die Strategie PRLP eine weitere Reduzierung der mittleren Wartezeit zu erreichen ist. Dies gelingt jedoch nur bei moderaten Anpassungen der Flottengröße (100 bis 90 %).

Die Rebalancingstrategie FFR weißt durchgehend höhere Wartezeiten als die Vergleichsstrategien auf. Auch in Bezug auf die Ablehnungsquote werden konstant höhere Werte erreicht.

Im direkten Vergleich der räumlichen Diskretisierung zeigt sich, dass sich eine zunehmend feinere Unterteilung des Vorhersage-/Rebalancinggebiets nachteilig auf die Wartezeit auswirkt. In Bezug auf die Ablehnungsquote ist keine relevante Verbesserung in Folge der Rebalancingstrategie PRLP zu erkennen.

Abbildung 6.16 zeigt im direkten Vergleich der Simulationswochen die relative Änderung der Wartezeit (Q_{25} , Median, Mittelwert, Q_{75}) im Vergleich zu REF-REF-100. Anfragen mit kurzen Wartezeiten (Q_{25} , Q_{50}) profitieren am stärksten von den Änderungen der Rebalancing Strategie. In diesem Bereich liegt die zusätzliche Verbesserung in der Größenordnung von 10 %. Auch bei einer reduzierten Flottengröße (Abbildung 6.15-Rechts) kann noch eine Verbesserung erreicht werden, der Effekt fällt jedoch kleiner aus.

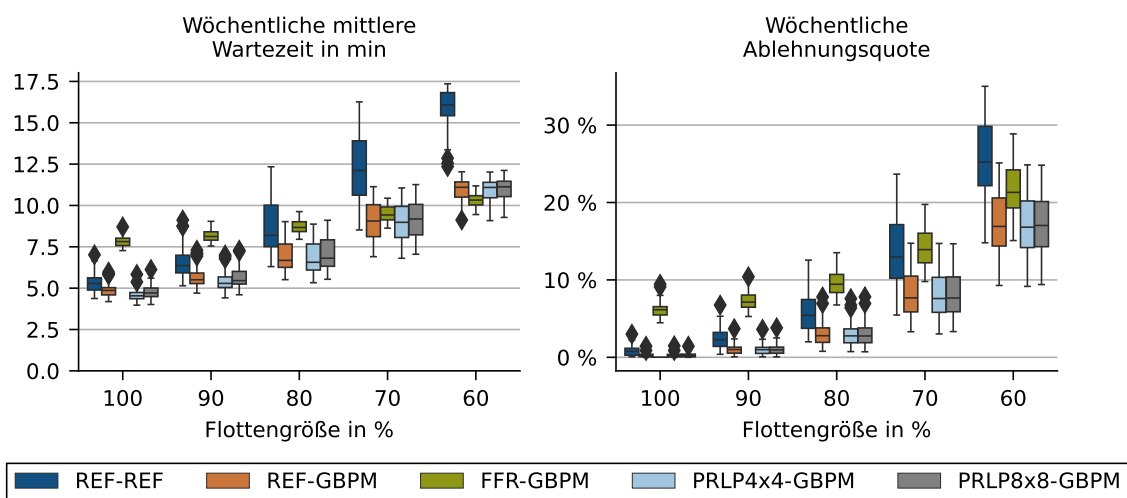


Abbildung 6.15: Einfluss der Rebalancingstrategie auf die mittlere wöchentliche Wartezeit (Links), die mittlere und die wöchentliche Ablehnungsquote (Rechts)

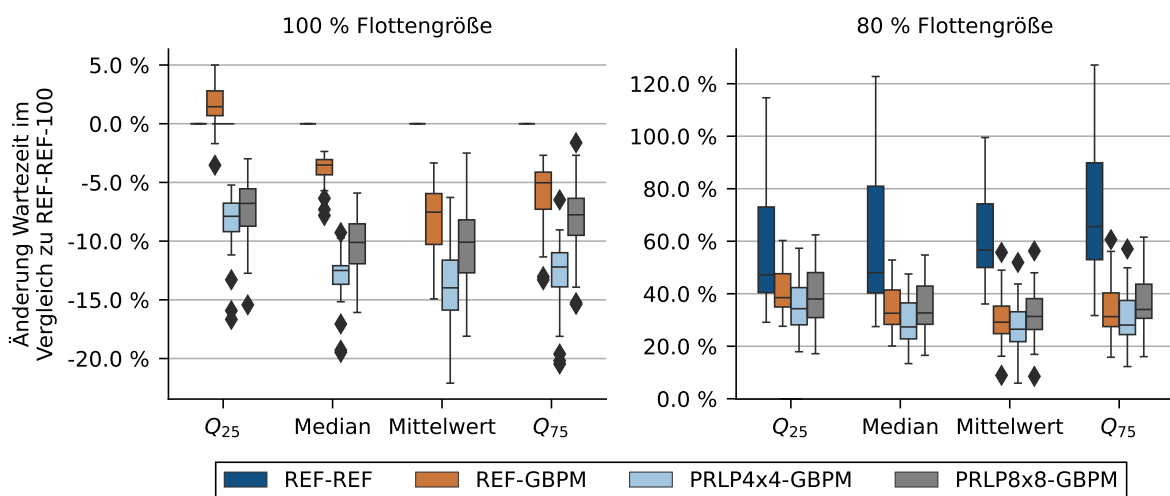


Abbildung 6.16: Änderung der Kundenwartezeit durch prädictives Rebalancing für 100 % (Links) und 80 % Flottengröße.

Flottenverhalten

Auch an dieser Stelle lassen sich die Ursachen der Beobachtungen des vorherigen Abschnitts auf das generelle Flottenverhalten zurückführen. Abbildung 6.18 stellt die wöchentlichen mittleren Anfahrts- bzw. Rebalancingstrecken dar. Es ist zu erkennen, dass FFR insgesamt eine viel geringere Umverteilung der Fahrzeuge anstößt als die weiteren Vergleichsstrategien. In Folge resultiert daraus eine längere Anfahrtsstrecke und damit längere Wartezeiten. Im Gegensatz dazu kann durch ein vorausschauendes, zielgerichtetes Rebalancing der Fahrzeuge die Anfahrtsstrecke durch PRLP um 4,5 % im Vergleich zu REF-GBPM-100 reduziert werden. Abbildung 6.18 verdeutlicht zudem, dass bei reduzierter Flottengröße Fahrzeuge immer weitere Strecken für die Anfahrt zurücklegen müssen und gleichzeitig auf Grund der erhöhten Flottenauslastung zu wenige Fahrzeuge zur Verfügung stehen, welche umverteilt werden könnten. Eine deutliche Reduzierung der für das Rebalancing aufgewendeten Strecke ist die direkte Folge. Im direkten Vergleich der beiden räumlichen Diskretisierungen PRLP4x4 und PRLP8x8 zeigt sich, dass bei einer feineren lokalen Auflösung der Vorhersage, Fahrzeuge kürzere Rebalancingfahrten durchführen, in Summe aber eine höhere Rebalancingdistanz zurücklegen. Diese trägt aber nicht dazu bei, die mittlere Anfahrtsstrecke zu reduzieren.

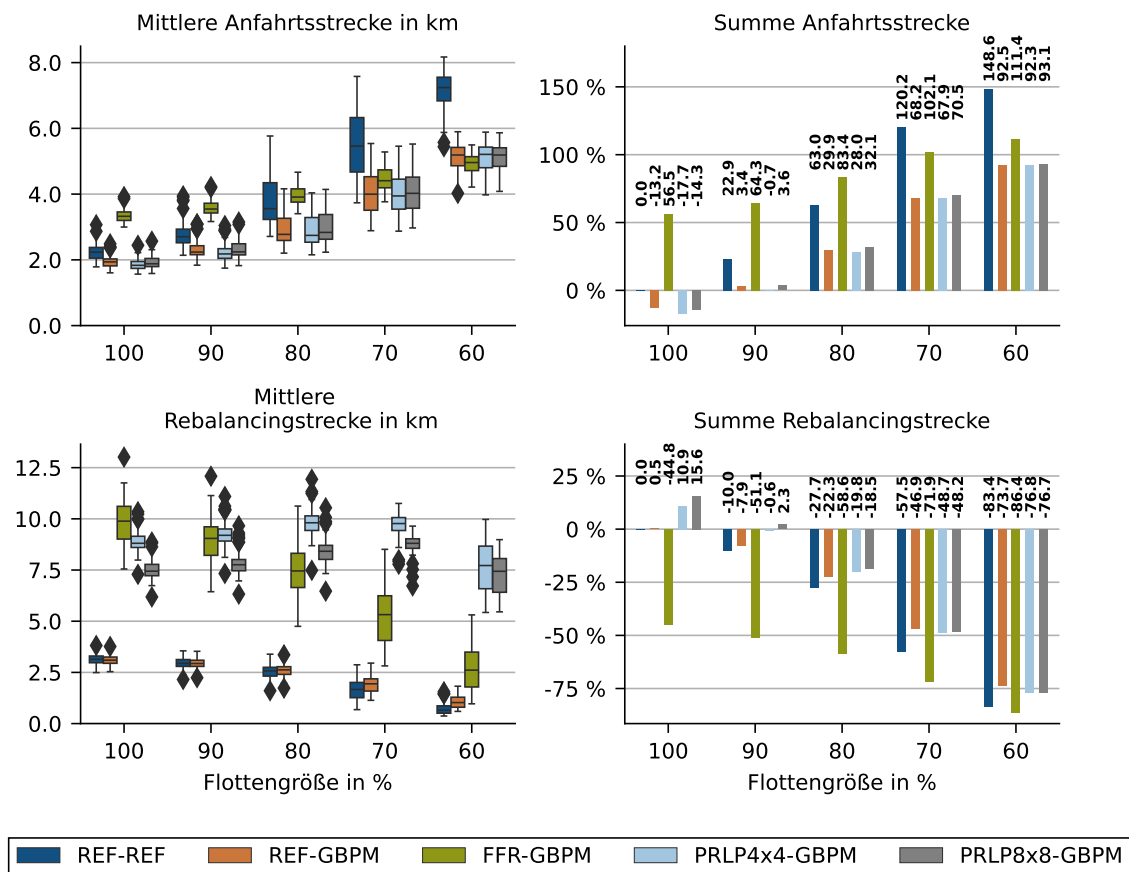


Abbildung 6.17: Einfluss der Rebalancingstrategie auf Anfahrts- (oben) und Rebalancingdistanzen (unten)

Weiterhin bleibt die Reduktion der Fahrzeuganzahl in Bezug auf die mittlere Flottenauslastung der bestimmende Faktor (Abbildung 6.18). Durch die Reduktion/Vergrößerung (PRLP/FFR) der Anfahrtsstrecken ist lediglich eine geringe Änderung der Flottenauslastung erkennbar. Der Einfluss der Rebalancing Strategie auf die Betriebskosten der Fahrzeugflotte ist analog zur Änderung der Vermittlungsstrategie irrelevant. Auch in Bezug auf den erzielten Umsatz kann keine Verbesserung ggü. REF-GBPM erreicht werden.




Abbildung 6.18: Einfluss der Rebalancingstrategie auf die Kennwerte: Mittlere Flottenauslastung, Kosten 2019 (Differenz zu REF-REF-100 in %) und Umsatz 2019 (Differenz zu REF-REF-100 in %)

6.4.3 Fazit

Die Analyse alternativer Rebalancingstrategien hat gezeigt, dass durch den zusätzlichen Einsatz prädiktiver Umverteilung von Fahrzeugen in Bezug auf kundenrelevante Werte deutliche Verbesserungen erzielt werden können. Wartezeiten können hier zusätzlich in der Größenordnung von 10 % im Vergleich zu REF-GBPM reduziert werden. Die Ergebnisse zeigen, dass die Vorteile einer prädiktiven Rebalancingstrategie vor allem dann zum Tragen kommen, wenn die Flotte genügend Kapazität an freien Fahrzeugen für das Rebalancing hat. Außerdem wurde gezeigt, dass durch den Einsatz des vorgeschlagenen Verfahrens PRLP keine zusätzlichen Kosten durch das Rebalancing für den Flottenbetreiber entstehen. Diese werden durch die im gleichen Umfang reduzierten Anfahrtswege ausgeglichen. Gleichzeitig können durch alternative Rebalancingstrategien keine direkten Kosten eingespart werden. Wohlgleich trägt ein optimiertes Rebalancing dazu bei, dass Verschlechterungen in der Servicequalität in Folge einer reduzierten Flottengröße abgemildert werden. Die Anpassung der Rebalancingstrategie macht dementsprechend, analog zu einer optimierten Vermittlungsstrategie, Kosteneinsparungen aufgrund einer verkleinerten Fahrzeugflotte möglich.

Kritisch sind an dieser Stelle die Ergebnisse der Rebalancingstrategie FFR zu bewerten. Es kann angenommen werden, dass diese durch eine Optimierung der Standardparameter auf den spezifischen Anwendungsfall noch verbessert werden können. Das Ergebnis zeigt jedoch deutlich die Schwächen eines generalisierten Vorgehens im Vergleich zu einem auf die Rahmenbedingungen optimierten Strategie.

Bisher vernachlässigt bleibt auch, dass durch eine verbesserte Servicequalität womöglich eine weitere Umsatzsteigerung auf dem Markt zu erzielen ist und somit weitere Zugewinne bei Umsatz und Gewinn des Flottenbetreibers zu erwarten sind.

6.5 Optimierte Flottengröße

In den letzten beiden Abschnitten wurde gezeigt, dass durch eine Reduktion der Flottengröße bei gleichzeitiger Einführung optimierter Vermittlungs- und Rebalancingstrategien Kostenersparnisse unter Beibehaltung/Verbesserung der aktuellen Servicequalität erreicht werden können. Es wurde außerdem gezeigt, dass der Wartezeitvorteil des prädiktiven Rebalancing nur bei einer ausreichenden Rebalancingkapazität der Fahrzeugflotte zu erreichen ist. Bisher wurde dabei der zeitliche Verlauf der Flottengröße konstant zwischen 60 bis 100 % skaliert. Abbildung 6.19 zeigt den zeitlichen Verlauf der Fahrzeugzustände während der Simulationswoche KW 45 für das Szenario PRLP4x4-GBPM-80. Es ist zu erkennen, dass eine pauschale Reduktion um 20 % zum einen weitere Reduktionspotentiale (*) offen lässt und zum anderen in Zeiten hoher Nachfrage das Gesamtsystem überlastet (!). Angelehnt an die üblichen Schichtwechselzeiten soll deshalb in einem weiteren Szenario untersucht werden, welche zusätzlichen Potentiale in Bezug auf Servicequalität und Betriebskosten durch eine Reduktion der Fahrzeuganzahl pro Schicht zu erreichen ist. Als erste Potentialabschätzung und Grundlage zukünftiger Analysen wird die Anzahl aktiver Fahrzeuge jeweils separat für Tag- und Nachtschicht angepasst und die Flottenskalierungen 70|100, 80|100 und 80|110 für die Strategie PRLP4x4-GBPM untersucht. Die übrigen Parameter aus Tabelle 6.6 bleiben unverändert.




Abbildung 6.19: Beispiel zeitlicher Verlauf des Flottenstatus für PRLP4x4-GBPM-80 für die Simulationswoche KW 45–2019

6.5.1 Ergebnisse

Servicequalität

Abbildung 6.20 zeigt den Einfluss der optimierten Flottengrößenanpassung auf die mittlere wöchentliche Wartezeit und die wöchentliche Ablehnungsquote für die Vermittlungs-/Rebalancingstrategie PRLP4x4-GBPM. Die Ergebnisse lassen sich in drei Gruppen zusammenfassen:

- A:** Anpassungen, die in Kombination mit einer prädiktiven Rebalancing Strategie eine Steigerung der Servicequalität zur Folge haben,
- B:** Anpassungen, die eine Beibehaltung des Status Quo sichern und
- C:** Anpassungen, die in einer moderaten Verschlechterung der Servicequalität resultieren.

Vergleicht man die Ergebnisse für die Flottengrößen 80, 80|100 und 80|110 wird deutlich, dass die zusätzliche Rebalancingkapazität während der Nachtschicht zusätzliche Potentiale freisetzt. Im Szenario 80|100 kann die Wartezeit und Ablehnungsquote auf dem Niveau des Referenzszenarios gehalten werden. Erhöht man die Anzahl der Fahrzeuge in der Nachtschicht zusätzlich um (80|110), kann die mittlere wöchentliche Wartezeit weiter gesenkt werden, erreicht jedoch nicht das Niveau der 100 %-Flotte.

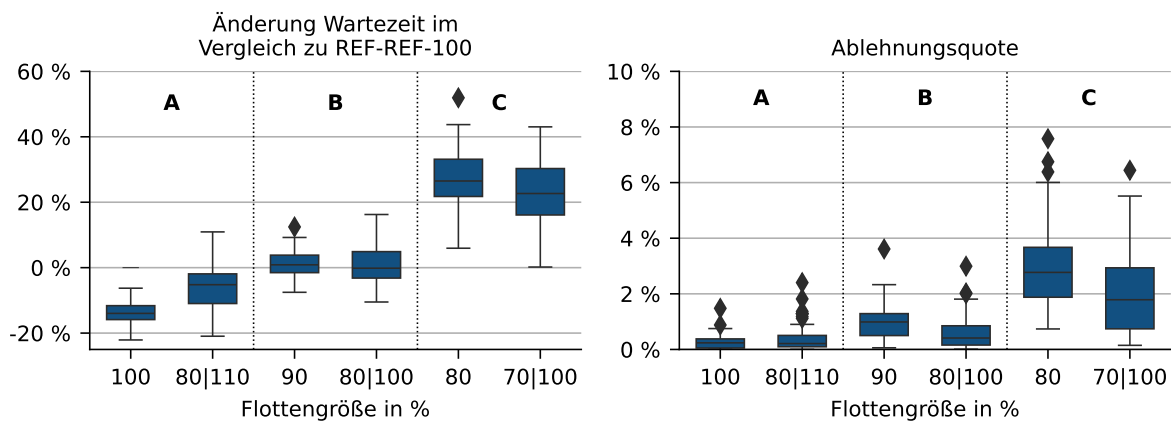


Abbildung 6.20: Einfluss der Flottenanpassung auf die mittlere wöchentliche Wartezeit (Links) und die wöchentliche Ablehnungsquote (Rechts)

Kostensparnisse und Gewinnpotentiale

Auf Betreiberseite ergeben sich für die simulierten Szenarien folgende, in Abbildung 6.21 dargestellte, Kostensparnis- und Gewinnpotentiale.

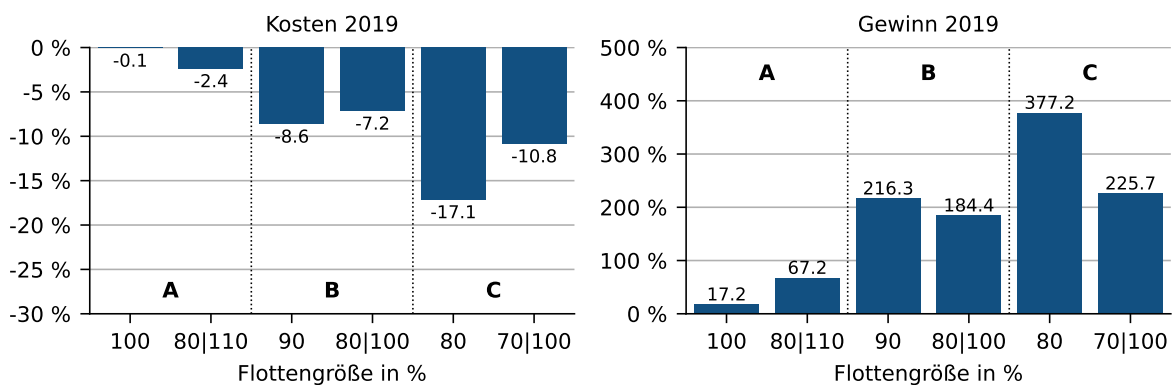


Abbildung 6.21: Einfluss der Flottenanpassung auf die Kennwerte: Kosten 2019 (Differenz zu REF-REF-100 in %) und Umsatz 2019 (Differenz zu REF-REF-100 in %)

Da weiterhin der Lohn sowie die absolute Anzahl an Fahrzeugen die bestimmenden Faktoren für die Kostenänderung darstellen, skalieren Kosten und Gewinn für alle Szenarien entsprechend der Flottengröße. Betrachtet man die Kostensparnis in Zusammenhang mit der Auswirkung auf die Servicequalität (A-C) wird deutlich, dass:

- A:** Durch eine optimierte Anpassung der Flottengröße (80|110) sowohl die Servicequalität gesteigert, als auch Kosten gespart werden können (-2,4 %). Dies resultiert in einer möglichen Gewinnsteigerung von 67,2 %.
- B:** Bei gleichbleibender Servicequalität die operativen Kosten um bis zu -8,6 % (PRLP4x4-GBPM-90) reduziert werden können. Dies resultiert in einer möglichen Gewinnsteigerung von 216,3 %. Auf Grund der höheren Fixkosten für den Betrieb einer 100 % Flotte wird im Szenario PRLP4x4-GBPM-80|100 eine um 1,4 % geringere Kosteneinsparung erreicht.
- C:** Bei einer weiteren Reduktion der Tagschicht auf 70 % (PRLP-GBPM-70|100) keine weiteren Vorteile gegenüber PRLP-GBPM-80 erzielt werden können. Mit der Bereitschaft, eine moderate Verschlechterung der Servicequalität in Kauf zu nehmen, ist eine Kostenreduktion um 17,1 %, gepaart mit einer Gewinnsteigerung um 377,2 %, möglich.

6.5.2 Fazit

Die Reduktion der Flottengröße stellt auf Betreiberseite den wesentlichen Hebel zur Senkung der Betriebskosten dar. Sowohl Fixkosten für die Bereitstellung des Fahrzeuges, als auch Lohnkosten sind die wesentlichen Kostentreiber. Durch eine optimierte Einsatzplanung in Kombination mit einer prädiktiven, global optimierenden Vermittlungs-/Rebalancingstrategie ist es möglich, Betriebskosten zu senken und gleichzeitig die Servicequalität zu steigern. Nichtsdestotrotz kann auch eine pauschale Anpassung der Flottengröße auf Schichtbasis nicht das gesamte, in Abbildung 6.19 dargestellte, Optimierungspotential ausschöpfen. An dieser Stelle sind weitere Optimierungspfade zu untersuchen. Denkbar wäre hier beispielsweise der Einsatz einer prädiktiven Schichtplanung. Dazu könnte eine mittelfristige Vorhersage der Kundennachfrage verwendet werden, um die optimale Anzahl an Fahrzeugen für eine individuelle Schicht zu bestimmen. Für die weitere Optimierung ist außerdem zu bestimmen, welcher Anteil an Fahrzeugen als Rebalancingreserve vorgehalten werden muss. An dieser Stelle liefern die gezeigten Ergebnisse zwar Hinweise, eine konkrete Aussage kann auf Grund der vielfältigen Wechselwirkungen jedoch nur anhand einer tiefergehenden Analyse erreicht werden. Es ist außerdem zu überprüfen, durch welche operativen Maßnahmen die Anzahl aktiver Fahrzeuge im Realbetrieb gesteuert werden kann, und inwiefern hier neue Anreizstrukturen für Fahrer- und Flottenbetreiber entwickelt werden müssen.

7 Diskussion

In diesem Kapitel werden die Beiträge dieser Arbeit diskutiert. Die Diskussion ist inhaltlich in eine allgemeine Bewertung des Vorgehens, die Beantwortung der in Abschnitt 2.3.2 aufgestellten Forschungsfragen und die Ableitung von Handlungsempfehlungen und Möglichkeiten zur technischen Umsetzung unterteilt. Abschließend wird die Relevanz der erzielten Ergebnisse unter wissenschaftlicher, gesellschaftlicher und gewerblicher Perspektive herausgestellt.

7.1 Allgemeine Bewertung

Ziel dieser Arbeit ist es, Optimierungspotentiale für den Betrieb von Ridesourcing-Diensten, am Beispiel des Münchner Taxiverkehrs, zu identifizieren, Lösungsansätze aufzuzeigen und diese zu bewerten. Dazu wurden aufbauend auf einer vorangestellten Potentialanalyse Teilmodelle für Vermittlungs- und Rebalancingstrategie, Nachfrageprädiktion und Flottengrößenanpassung entwickelt und in das Simulationsframework AMoDeus [19] integriert. Die Einflüsse einzelner Optimierungspfade wurden im Rahmen einer Simulationsstudie für das Jahr 2019 am Beispiel einer Münchner Taxiflotte untersucht und deren Wechselwirkungen dargestellt.

Das generelle Vorgehen, der modulare Aufbau der Teilmodelle und deren Integration in das Simulationsframework ist insgesamt als positiv zu bewerten. Dadurch konnten im Rahmen der Simulationsstudie mit geringem Aufwand eine Vielzahl an Szenariopermutationen untersucht und bewertet werden. Die klare Trennung von Eingangsdaten und Modellen ermöglicht es, diese mit geringem Aufwand zukünftig auf weitere Anwendungsbeispiele in anderen Städten und Flottenzusammensetzungen zu übertragen.

Der Umfang der Simulationsstudie bekräftigt die Aussagekraft der Ergebnisse. Die Ergebnisse fußen auf 1716 Einzelsimulationen. Durch die Simulation eines ganzen Jahres kann der Einfluss saisonaler Effekte ausgeschlossen und der Einfluss der Optimierungsmaßnahmen sowohl in nachfrageschwachen, als auch -starken Wochen gezeigt und bewertet werden.

7.1.1 Datengrundlage

Die Ergebnisse dieser Arbeit wurden auf Basis eines Realdatensatzes einer Münchner Taxiflotte erstellt. Der Datensatz repräsentiert circa 14,7 % der in München zugelassenen Taxen. Die Interpretation der Ergebnisse ist daher immer bezogen auf das Anwendungsbeispiel einzuordnen und nicht ohne weiteres direkt auf die Gesamtflotte oder andere Städte übertragbar. Es kann davon ausgegangen werden, dass generelle Effekte der gezeigten Optimierungspfade auch auf andere Szenarien und Flotten übertragen werden können deren Umfang ist jedoch im Einzelfall gesondert zu prüfen.

Trotz sorgfältiger Prüfung und Datenfilterung können Datenlücken, die aus dem Erhebungsprozess (z. B. Taxifahrer schaltet Telematik-Einheit aus) resultieren, nicht vollumfänglich ausgeschlossen werden. Da aus Datenschutzgründen keine zusammenhängenden Fahrtketten übertragen werden, kann eine Plausibilisierung nur auf Einzelfahrtbasis erfolgen.

Eine weitere Einschränkung des Datensatzes ist, dass dieser nicht in allen Fällen Informationen bezüglich der Anfahrtswege liefert. Diese werden durch das Telematiksystem nur als solche erfasst, wenn eine Fahrt über die angeschlossene Taxizentrale vermittelt wurde. Wurde der Auftrag über einen anderen Anbieter vermittelt, wird die Fahrt im Datensatz unter dem Status Frei aufgeführt.

7.1.2 Nachfrageprädiktion

Für die Vorhersage der Kundennachfrage wurde ein modulares Prädiktionsframework erarbeitet. Durch die generische Modellstruktur können verschiedene Methoden zur Vorhersage getestet und bewertet werden. Es wurde gezeigt, dass die hohen Anforderungen bezüglich örtlicher und zeitlicher Auflösung der Vorhersage mit hinreichender Prognosequalität erreicht werden können. Die Qualität der Vorhersage variiert dabei lokal stark. Der zeitlich dynamische Nachfrageverlauf kann nur in Gebieten mit ausreichender Datenqualität sinnvoll abgebildet werden. Vor diesem Hintergrund ist kritisch zu hinterfragen, ob in Gebieten mit niedrigem Nachfrageaufkommen nicht auch einfachere Modelle ausreichen und somit Rechenzeit und Ressourcen gespart werden können. Zu Beginn der Arbeit wurde vermutet, dass durch die Hinzunahme zusätzlicher Einflussfaktoren, welche im Rahmen der Potentialanalyse untersucht wurden, die Prognosequalität gesteigert werden kann. Eine Verbesserung der Prognosequalität mit Hilfe der zusätzlich erhobenen Datensätze bzgl. Veranstaltungen, Verspätungen im ÖPNV und Wetter konnte nicht gezeigt werden.

7.1.3 Simulationsmodell

Die korrekte Funktion des Simulationsmodells, sowie die Einhaltung der vorgegebenen Abfolge von Fahrzeugzuständen wurde durch Testroutinen und kontinuierliche Integration [227] des Quellcodes abgesichert. Die Ergebnisse wurden während der Entwicklung zudem ständig anhand einer ausgewählten Testwoche plausibilisiert und stichprobenartig in der von AMoDeus bereitgestellten grafischen Oberfläche überprüft.

Für eine realitätsgetreue Abbildung der Fahrtzeiten wurden die Straßengeschwindigkeiten wie in Unterabschnitt 6.1 beschrieben mit Hilfe eines iterativen Verfahrens auf Basis realer Beobachtungen angepasst. Wie gezeigt, konnten damit realistische Fahrtauern erzielt werden. Es kann jedoch nicht vollumfänglich dafür garantiert werden, dass die Fahrtzeiten in Zeiträumen oder Gebieten ohne Beobachtungsdaten den realen Reisezeiten entsprechen.

Für die Kalibrierung der Referenzstrategie wurde versucht, das individuelle Fahrerverhalten durch eine Entscheidungslogik abzubilden. Diese wurde derart kalibriert, dass wesentliche Kenngrößen zwischen Simulation und Validierungsdatensatz übereinstimmen. Die Entscheidungslogik versucht somit in erster Linie, das Gesamtverhalten der Fahrzeugflotte korrekt abzubilden. Sie ist nicht geeignet, um auf individueller Ebene Fahrer und deren Entscheidungsprozess zu bewerten.

Innerhalb der Simulation wird angenommen, dass Fahrzeuge jederzeit unbegrenzt und überall auf dem Straßennetzwerk parken können. Zwar sehen die Rebalancingstrategien REF und PRLP vor, dass Fahrzeuge bevorzugt an Taxiständen parken, ist jedoch kein Taxistand in der Nähe, parken Fahrzeuge auch in diesen Fällen willkürlich auf dem Straßennetzwerk. In Realität wäre ein derartiges Verhalten nicht umsetzbar. Eine Modellierung realer Parkmöglichkeiten ist jedoch nicht ohne weiteres möglich. Die hierfür benötigten Daten bzgl. Parkmöglichkeiten und Parkplatzbelegung liegen nicht vor.

Für die Ein- und Ausstiegszeiten wurde der empirisch ermittelte Mittelwert von 162 s angenommen. Gerade in Zeiten hoher Flottenauslastung hat dieser Parameter einen hohen Einfluss auf die Elastizität der Fahrzeugflotte. Es wurde im Rahmen dieser Arbeit nicht weiter untersucht, ob dieser Wert abhängig von Tageszeit und Fahrtzweck ist. Es ist anzunehmen, dass ein Geschäftsreisender mit Gepäck längere Zeit für

den Ein- und Ausstieg benötigt als jemand, der sich von einem abendlichen Restaurant-/Clubbesuch nach Hause fahren lässt.

7.1.4 Kostenmodell/Erlösmodell

Das für die monetäre Bewertung verwendete Kostenmodell berücksichtigt Fixkosten für Anschaffung und Betrieb der Fahrzeugflotte, variable, streckenbezogene Kosten sowie Lohnkosten. Die hierfür ermittelten Werte basieren auf Branchenreferenzwerten und wurden durch Branchenexperten plausibilisiert. In dieser Arbeit wurde vereinfacht angenommen, dass die gesamte Fahrzeugflotte mit 490 Fahrzeugen von einem einzelnen Flottenbetreiber betrieben wird, und alle Fahrzeuge mit angestellten Fahrern betrieben werden. Die Lohnkosten wurden vereinfacht mit einem pauschalen mittleren Stundenlohn bestimmt. Für eine zukünftige Betrachtung einer optimierten Einsatzplanung wird empfohlen, die Berechnung der Lohnkosten variabel handzuhaben.

Die ermittelten Gewinne/Umsätze pro Fahrzeug sind daher als Durchschnittswerte zu interpretieren und können nicht unmittelbar für selbständige Einmannbetriebe übernommen werden. Die Berechnung des Fahrpreises richtet sich nach dem Preismodell der Münchner Taxi Tarif Ordnung [156] und erfolgt ausschließlich auf Basis des Grundfahrpreises und der streckenabhängigen Kosten. Weitere Erlöse durch Wartezeiten, Zuschläge für Gepäck etc. sowie Pauschalpreise (Fahrt Messe/Flughafen) bleiben unberücksichtigt.

7.2 Forschungsfragen

Die zentrale Forschungsfrage dieser Arbeit war die Suche nach geeigneten Maßnahmen, welche die Effizienz im Taxigewerbe bei gleichzeitiger Einhaltung/Verbesserung der Servicequalität zu steigern vermögen. Im folgenden Abschnitt werden die dazu formulierten Teilfragestellungen aufgegriffen und auf Basis der in dieser Arbeit dargestellten Ergebnisse beantwortet.

Welchen Einfluss haben Vermittlungsstrategie, Rebalancingstrategie und Flottengröße auf Servicequalität und Betriebskosten der Fahrzeugflotte?

In Kapitel 6 wurden Vermittlungs- und Rebalancingstrategie sowie die Flottengröße bezüglich ihres Einflusses auf kunden- und betreiberrelevante Kenngrößen untersucht. Am Beispiel einer Münchner Testflotte wurden dabei drei Vermittlungsalgorithmen, drei Rebalancingalgorithmen und acht verschiedene Flottenskalierungen untersucht. Die Ergebnisse stellen klar: Die Wahl der Vermittlungs- und Rebalancingstrategie beeinflusst im Wesentlichen kundenrelevante Kennwerte (Wartezeit, Erfüllbarkeit). In keinem der untersuchten Szenarien konnte auf Grund einer geänderten Vermittlungs-/Rebalancingstrategie als direkte Konsequenz eine nennenswerte Kosteneinsparung erzielt werden. Hauptkostentreiber im Fall einer konventionellen Taxiflotte ist der Lohn des Fahrers, sowie die Fixkosten für den Betrieb der Fahrzeugflotte. Deshalb zeigt auch die Reduktion der Flottengröße an dieser Stelle das größte Potential in Bezug auf eine mögliche Kosten- und Gewinnoptimierung.

Fahrgastvermittlung: Wie leistungsfähig sind aktuell in der Praxis eingesetzte Vermittlungsalgorithmen und welche Optimierungsmöglichkeiten gibt es?

In Unterkapitel 6.3 wurde die aktuell praktizierte Vermittlungsstrategie der Münchner Testflotte in verschiedenen Flottenskalierungen untersucht. Diese wurde dabei mit zwei weiteren Strategien (GBPM, NTNR) aus dem Stand der Technik verglichen. Es konnte gezeigt werden, dass die aktuell praktizierte Vermittlungs-

strategie in Zeiten hoher Auslastung am Rande ihrer Leistungsfähigkeit steht. Erhöht sich die Auslastung durch mehr Kundenanfragen oder eine reduzierte Fahrzeugflotte, müssen unmittelbar Abstriche in der Servicequalität in Kauf genommen werden. Die im weiteren Verlauf untersuchte Vermittlungsmethode GBPM profitiert gegenüber der Referenzstrategie von folgenden Vorteilen: Durch die Aufhebung der Warteschlangenpriorisierung am Taxistand wartender Fahrzeuge werden Anfahrtswege reduziert, weil nun örtlich nahe Fahrzeuge gegenüber lange wartenden Fahrzeugen bevorzugt werden. Durch die Zusammenfassung von Aufträgen innerhalb des Vermittlungsintervalls T_{disp} werden Anfahrtswege nicht mehr nur für eine 1:1 Zuordnung optimiert, sondern für alle in diesem Zeitraum erfassten Fahrten. Dadurch kann die Wartezeit ohne weitere Anpassung von Flottengröße und Rebalancingverhalten im Mittel zwischen 3,7 bis 15 % reduziert werden. Weiteres Optimierungspotential an dieser Stelle besteht in der Wahl des Parameters T_{disp} . Dieser wurde für die durchgeführten Studien auf den Wert 30 s begrenzt. Es ist weiter zu untersuchen, welchen Effekt hier eine Vergrößerung bzw. eine der Flottenauslastung entsprechende, dynamische Anpassung des Intervalls hat. Weitere, im Rahmen dieser Arbeit nicht untersuchte, Optimierungsmöglichkeiten sind die kontinuierliche Neuzuweisung von Aufträgen und eine vorausschauende Vermittlungsstrategie. Erstere ist für konventionelle Fahrzeugflotten ungeeignet, weil Fahrer hier laufend auf geänderte Routenanweisungen reagieren müssten. Von einer vorausschauenden Vermittlungsstrategie können Anfragen in Gebieten profitieren, in denen zum Vermittlungszeitpunkt zu wenig Fahrzeuge vorhanden sind. Ist bekannt, dass ein Fahrzeug dort in Kürze eine andere Fahrt beenden wird, kann dieses Fahrzeug bereits für die ausstehende Anfrage reserviert werden und ist womöglich schneller vor Ort als ein Fahrzeug, das einen längeren Anfahrtsweg in Kauf nehmen muss. Es ist an dieser Stelle weiter zu prüfen, welche zusätzlichen Wartezeitvorteile dadurch erreicht werden können.

Rebalancing: Können Fahrzeuge durch Vorhersage der Kundennachfrage derart umverteilt werden, dass Anfahrtswege und -Zeiten reduziert werden können?

Zur Beantwortung dieser Frage wurde in Abschnitt 5.3.2 basierend auf [15, 204] eine prädiktive, gewinnmaximierende Rebalancingstrategie entwickelt. Diese nutzt das in Unterkapitel 5.4 vorgestellte Modell zur Vorhersage der räumlich-zeitlichen Kundennachfrage, um Fahrzeuge innerhalb des Geschäftsgebietes vorausschauend zu verteilen. Die Ergebnisse der Simulationsstudie bestätigen, dass dadurch eine weitere Verkürzung von Anfahrtswegen- und Zeiten möglich ist. In Kombination mit einer optimierten Vermittlungsstrategie sind dadurch, unter Beibehaltung der aktuellen Flottengröße, Verkürzungen der mittleren wöchentlichen Wartezeit zwischen 6 bis 22 % möglich. Es konnte auch gezeigt werden, dass für die untersuchte Testflotte keine zusätzlichen Kosten entstehen. Die Leistungsfähigkeit der Rebalancingstrategie hängt wesentlich von der allgemeinen Flottenauslastung ab. In Zeiten hoher Auslastung kann das Rebalancing keinen Beitrag zur Entlastung liefern, weil schlichtweg zu wenig Fahrzeuge für das Rebalancing zu Verfügung stehen. Ein vorausschauendes Rebalancing ist also hauptsächlich in Zeiten moderater Auslastung und direkt vor Zeiten hoher Auslastung geeignet, die allgemeine Wartezeit zu verkürzen. Die Entwicklung und Parametrierung des Algorithmus sowie der räumlichen Diskretisierung erfolgte in engem Abgleich mit den örtlichen Besonderheiten des Anwendungsbeispiels. Für die Anwendung in anderen Städten und Regionen muss die Parametrierung überprüft und ggf. angepasst werden. Vor allem in Regionen mit großer räumlicher Ausdehnung ist eine sinnvolle räumliche Diskretisierung zu wählen, weil die Komplexität des Optimierungsproblems $\mathcal{O}(n-1)^2$ mit der Anzahl an Zellen skaliert. In Szenarien mit hoher räumlicher Ausdehnung ist daher ein mehrstufiges Rebalancingverfahren zu untersuchen. Eine wirksame Umsetzung im Realbetrieb hängt wesentlich von der Bereitschaft der teilnehmenden Taxifahrer und Unternehmen ab. Da im Gegensatz zu einem fest vermittelten Kundenauftrag eine Rebalancingfahrt vor allem im Vertrauen auf einen zukünftigen Auftrag stattfindet, muss an dieser Stelle die Akzeptanz von Taxifahrern für ein derartiges System weiter untersucht werden.

Nachfrageprädiktion: Kann durch die Fusion mehrerer Datenquellen eine hohe räumliche und zeitliche Auflösung in der Vorhersage der Kundennachfrage erreicht werden?

Im Rahmen der Entwicklung des Vorhersagemodells (Unterkapitel 5.4) wurden, neben dem historischen Verlauf der Kundennachfrage, mehrere zusätzliche Eingangsdaten untersucht (Absatz 5.4.5). Dabei konnten vor allem solche zusätzliche Informationen die Prognose verbessern, die den jeweiligen Vorhersagezeitpunkt in einen zeitlichen Kontext setzen (Stunde des Tages, Wochentag, öffentlicher Feiertag, Schulferien). Es konnten zwar Anomalien im Nachfrageverhalten auf öffentliche Veranstaltungen [158] und Verspätungen im ÖPNV [157] zurückgeführt werden, diese Informationen konnten jedoch nicht dazu beitragen, das Prädiktionsmodell merkbar zu verbessern. Sowohl die räumliche, als auch die zeitliche Auflösung der Vorhersage ist wesentlich von dem verfügbaren Nachfragedatensatz abhängig. Für das Anwendungsbeispiel in München konnte eine maximale, sinnvolle Auflösung von 2×20 min bei einer Zellgröße von $1 \text{ km} \times 1 \text{ km}$ bzw. $2 \text{ km} \times 2 \text{ km}$ bei einer Gesamtabdeckung eines Gebietes von $8 \text{ km} \times 8 \text{ km}$ erreicht werden.

Flottengröße: Entspricht die Anzahl an derzeit in der Praxis eingesetzten Fahrzeugen der Anzahl an tatsächlich benötigten Fahrzeugen? Wenn nein, welche Optimierungspotentiale gibt es dabei?

Die Ergebnisse der Simulationsstudie (Kapitel 6) bestätigen die bereits in der Potentialanalyse (Kapitel 4) aufgestellte Vermutung, dass die aktuelle Anzahl an Fahrzeugen die Anzahl an tatsächlich benötigten Fahrzeugen übersteigt. Dies gilt vor allem für Zeiten moderater Nachfrage (Tagschicht werktags). In Zeiten hoher Nachfrage (z. B. Nachtschicht Fr./Sa., Sa./So.) werden jedoch alle aktuell verwendeten Fahrzeuge benötigt. Eine Reduktion der Anzahl an eingesetzten Fahrzeugen stellt auf Grund des hohen Lohnkostenanteils den größten Hebel bei den Betriebskosten zur Kosteneinsparung und Gewinnmaximierung dar. In der Simulationsstudie wurde diesbezüglich die Fahrzeugflotte schrittweise von 100 bis 60 % skaliert. In einem zweiten Schritt wurde zudem untersucht, welchen Effekt eine separate Skalierung von Tag- und Nachtschicht zur Folge hat. Die Ergebnisse zeigen deutlich, dass eine Reduktion der Flottengröße bei Beibehaltung der aktuellen Vermittlungs- und Rebalancingstrategie unmittelbar zu einer Verschlechterung der Servicequalität führt. Weitere Optimierungspotentiale könnte eine mittelfristige Vorhersage der Anzahl an benötigten Fahrzeugen liefern. Auf Basis dieser könnte das Angebot an Fahrzeugen gezielt der zu erwartenden Nachfrage angepasst werden. In weiterführenden Arbeiten kann hierfür auf das entwickelte Prädiktionsframework zurückgegriffen werden.

Welche Maßnahmen sind geeignet, um die Effizienz im Taxigewerbe bei gleichzeitiger Einhaltung/Verbesserung der Servicequalität zu steigern?

Einen maßgeblichen Stellhebel zur Steigerung der Profitabilität im Taxigewerbe stellt die Reduktion der Anzahl an aktiven Fahrzeugen dar. Wie gezeigt muss mindestens eine weitere Maßnahme – Vermittlungs- oder Rebalancingstrategie – umgesetzt werden, wenn die Servicequalität auf dem aktuellen Niveau gehalten werden soll. Eine Verbesserung der Servicequalität bei gleichzeitiger Reduzierung der Flottengröße ist nur durch die Anpassung beider Strategien möglich. Dabei hängt die Auswahl der Maßnahmen wesentlich von dem primären Optimierungsziel ab. Sollen primär Wartezeiten reduziert werden, kann dies durch die Optimierung der Rebalancing- und Vermittlungsstrategie kostenneutral erreicht werden. Durch eine Reduktion der Fahrzeugflotte um 10 % bei gleichzeitiger Einführung von GBPM und PRLP, konnte gezeigt werden, dass die Betriebskosten der Fahrzeugflotte bei gleichbleibender Servicequalität um bis zu 8,6 % gesenkt werden können. Das entspricht einer Gewinnsteigerung für die Gesamtflotte um bis zu 216,3 % (3,7 Mio. € pro Jahr $\hat{=}$ 7688 € pro Fzg. pro Jahr). Nimmt man eine moderate Verschlechterung der mittleren wöchentlichen Wartezeit in Kauf (+5,9 bis 51,9 % $\hat{=}$ 20,3 bis 168,9 s), ist mit dem Szenario PRLP-GBPM-80 sogar eine Kostensenkung um 17,1 % gepaart mit einer Gewinnsteigerung um 377,2 % (5,9 Mio. € pro Jahr bzw. 11 600 € pro Fzg. pro Jahr) möglich.

7.3 Handlungsempfehlungen, Möglichkeiten zur technischen Umsetzung und Weiterentwicklung

Aus den dargestellten Ergebnissen lassen sich für den operativen Betrieb folgende Handlungsempfehlungen ableiten:

Vermittlungszentrale

Der Vergleich unterschiedlicher Vermittlungsstrategien hat gezeigt, dass die aktuell praktizierte Methode eine geringere Leistungsfähigkeit als alternative Strategien aufweist. Es wird empfohlen, die aktuelle Strategie durch das Verfahren GBPM oder NTNR zu ersetzen. Diese Maßnahme kann mit vertretbaren Anpassungen im operativen Geschäftsablauf zeitnah umgesetzt werden. Die dazu notwendige Heuristik kann aus bestehenden Modellen des Stands der Technik übernommen und in die Vermittlungssoftware integriert werden.

Als zentrale Instanz verfügt die Vermittlungszentrale als einziger Akteur über die notwendigen Daten, Informationen und Nachrichtenkanäle, um eine prädiktive Rebalancingstrategie im Rahmen von Handlungsanweisungen und -empfehlungen vorzugeben. Hierzu müssen die entsprechenden, softwareseitigen Schnittstellen und Modelle für den Produktiveinsatz implementiert werden. Da die Vermittlungszentrale jedoch ggü. den angeschlossenen Taxen keine Weisungsbefugnis hat, muss durch Kommunikation und entsprechende Anreizsysteme sichergestellt werden, dass die Empfehlungen des Rebalancingalgorithmus auch in die Realität umgesetzt werden.

Für die Vermittlungszentrale besteht an dieser Stelle die Chance, bei entsprechendem Kompetenzaufbau, mittelfristig neben der Auftragsvermittlung angeschlossenen Taxiunternehmen zusätzliche Dienstleistungen auf Basis der ihr zur Verfügung stehenden Mobilitätsdaten anzubieten und sich somit von anderen Mitbewerbern abzusetzen.

Die verwendeten Modelle und Algorithmen wurden zum Teil an die örtlichen Angebots- und Nachfragestrukturen des Anwendungsbeispiels angepasst. Die Ergebnisse der Arbeit können deshalb nicht direkt auf andere Städte und Anwendungsszenarien übertragen werden. Es ist jedoch zu erwarten, dass gerade in deutschen und europäischen Städten mit vergleichbarer Siedlungsstruktur und Kundenverhalten ähnliche Ergebnisse erzielt werden können. Derartige Untersuchungen können mit Hilfe des veröffentlichten Quellcodes für Simulation- und Nachfrageprädiktion schnell auf neue Anwendungsfälle angepasst werden.

Taxiunternehmer

Die Ergebnisse dieser Arbeit zeigen, dass durch eine koordinierte Optimierung von Fahrgastvermittlung und Leerfahrten deutliche Kosten- und Qualitätsverbesserungen für alle Akteure erzielt werden können. Diese sind besonders vor dem Hintergrund der geplanten Erhöhungen des Mindestlohns unabdingbar. Im Vergleich zum Untersuchungszeitraum 2019 erhöht sich der gesetzliche Mindestlohn ab 1. Juli 2022 um 13,7 % auf 10,45 €/h. Für den Flottenbetreiber resultiert dies in Arbeitnehmerkosten in Höhe von 14,28 €/h und einer Gesamtkostensteigerung von 8,5 %, die sonst, wie in Unterkapitel 4.3 gezeigt, nur von einer Erhöhung des Fahrpreises abgedeckt werden können. Dies könnte wiederum dazu führen, dass die Kunden auf andere Dienstleister zurückgreifen und somit in Umsatzeinbußen für die Taxiunternehmer resultieren.

Sowohl für Einzelunternehmer, als auch für Flottenbetreiber zeigen Datenanalyse und Simulationsergebnisse, dass sich die derzeitige Schicht- und Einsatzplanung nicht in allen Zeiten an der Kundennachfrage orientiert. Eine entsprechende Reduktion an Fahrzeugen/Einsatzzeiten kann unmittelbar die Betriebskosten senken, ohne dass daraus negative Effekte bzgl. der Servicequalität entstehen. Zentraler Stellhebel an dieser Stelle ist die Anzahl an verfügbaren Taxikonzessionen.

Gleichzeitig zeigt die Analyse, dass aktuell freie Kapazitäten für komplementäre Geschäftsmodelle und Dienstleistungen (Essensauslieferung, Kurierdienste, etc.) verwendet werden können und damit zusätzliche Erlöse erzielen können.

In der Untersuchung wird davon ausgegangen, dass das Verhalten aller Fahrzeuge/Fahrer durch eine zentrale Instanz beeinflussbar ist. In Realität sind diese Handlungsanweisungen durch geeignete Instrumente und Anreizsysteme umzusetzen und die Bereitschaft aller Akteure notwendig, um das gezeigte globale Optimum zu erreichen.

7.4 Relevanz

In der bisherigen Diskussion wurden vor allem die Auswirkungen verschiedener Optimierungsmaßnahmen auf Basis der Simulationsergebnisse betrachtet. Abschließend erfolgt eine Einordnung der in dieser Dissertation vorgestellten Modelle und Ergebnisse bezüglich ihrer wissenschaftlichen, gesellschaftlichen und gewerblichen Relevanz.

7.4.1 Wissenschaftlich

Diese Arbeit gibt eine umfassende Einordnung des Stands der Wissenschaft und Technik für die Optimierung von Flottenstrategien in Ridesourcing-Systemen und bewertet diese kritisch. Es wird dabei explizit auf die möglichen Optimierungspfade Vermittlungsstrategie, Rebalancingstrategie, Nachfrageprädiktion und Flottengrößenoptimierung eingegangen. Durch die Analyse konnten geeignete Optimierungsansätze für das Anwendungsbeispiel Taxiverkehr München identifiziert und Forschungslücken dargelegt werden. Als Datengrundlage wurde in dieser Arbeit über fünf Jahre der umfassendste, im deutsch-sprachigen Raum verfügbare, Mobilitätsdatensatz für Taxiflotten erhoben und analysiert. Die Untersuchung von Ridesourcing-Diensten in der Wissenschaft konzentriert sich im Wesentlichen auf Gebiete, in denen öffentliche Datensätze zur Verfügung stehen (New York, San Francisco etc.) Neben [12] und [75] liefert diese Arbeit einen wertvollen Beitrag als internationales Vergleichsszenario für europäische Städte.

Die in dieser Dissertation vorgestellten Algorithmen zur Optimierung des Flottenverhaltens und die funktionalen Erweiterungen von AMoDeus [228], sowie das Prädiktionsframework [229] zur Vorhersage der Kundennachfrage sind OpenSource veröffentlicht und können somit zukünftige wissenschaftliche Fragestellungen unterstützen. Die im Rahmen dieser Arbeit entstandenen Peer-Review-Veröffentlichungen [142, 157, 158, 160, 204, 230, 231] sowie weitere öffentlich verfügbare Beiträge [224, 225, 232] stehen der wissenschaftlichen Community zusätzlich zur Verfügung.

7.4.2 Gesellschaftlich

Das Taxigewerbe liefert als Teil und Ergänzung des öffentlichen Personennahverkehrs einen wichtigen Beitrag zur Sicherung des Mobilitätsbedarfs aller Alters- und Gesellschaftsschichten. Neben der spontanen Mobilitätserfüllung bei Geschäftsreisen oder Freizeitaktivitäten leistet das Taxigewerbe einen wichtigen Beitrag für Kranken- und Arztfahrten mobil eingeschränkter Personengruppen. Auch in Gebieten, in denen örtlich oder zeitlich keine ausreichende Versorgung mit Verkehrsmitteln des ÖPNV sichergestellt werden kann oder diese ineffizient wäre, stellt das Taxigewerbe die Grundversorgung sicher. Unter zunehmendem Konkurrenzdruck neuer Mobilitätsangebote, die nicht an die Betriebs- und Beförderungspflicht des Taxigewerbes gebunden sind, ist auch das Taxigewerbe darauf angewiesen, seine eigene Kosteneffizienz und Servicequalität durch innovative Maßnahmen weiterzuentwickeln. Die Ergebnisse dieser Arbeit zeigen diesbezüglich Optimierungspfade auf und können damit langfristig zu einer bezahlbaren, nachhaltigen und

effizienten Grundversorgung im ÖPNV durch den Erhalt des Taxigewerbes beitragen. Die Erkenntnisse bezüglich der benötigten Flottengröße können von Städten und ÖPNV-Aufgabenträgern dazu genutzt werden, die Anzahl an herauszugebenden Konzessionen zu bewerten und ggf. anzupassen.

7.4.3 Gewerblich

Neben der wissenschaftlichen und gesellschaftlichen Relevanz bietet die vorliegende Arbeit unmittelbar anwendbare und übertragbare Ergebnisse und Szenarien für das Münchner Taxigewerbe im Speziellen und für vergleichbare Systeme in deutschen und europäischen Städten im Allgemeinen. Durch die gezielte Optimierung von Vermittlungs- und Rebalancingstrategie und einer bedarfsgerechten Schicht und Einsatzplanung können im Taxiverkehr die Servicequalität gesteigert und gleichzeitig Betriebskosten gesenkt werden.

Die dargestellten Optimierungspfade können für die Branche einen wertvollen Beitrag leisten, damit das Taxigewerbe auch in Zukunft konkurrenzfähig, dezentral organisiert und unabhängig bleiben kann.

Die Ergebnisse dieser Arbeit können dazu beitragen, innerhalb der Akteurslandschaft (Vermittlungszentralen, Großunternehmer, Einzelunternehmer) Transparenz zu schaffen und die allgemeine Akzeptanz von Transformations- und Änderungsprozessen begünstigen.

Durch die quelloffene Veröffentlichung des Simulation- und Prädiktionsmodells können auch zukünftige Fragestellungen des Gewerbes mittels Simulation vorab ohne Risiko untersucht und Handlungsempfehlungen abgeleitet werden.

8 Zusammenfassung und Ausblick

Mobilität bedeutet Beweglichkeit. Die Beweglichkeit von Personen und Gütern in Bezug auf ihren Ort aber im Synonym auch die Fähigkeit sich fortlaufend an veränderte Bedingungen anpassen zu können [233]. Die Art und Weise, wie wir uns fortbewegen, ist unter dem Einfluss von technologischen Innovationen, gesellschaftlichem Wandel, sich verändernden Räumen und Siedlungsstrukturen oder disruptiven Ereignissen, wie einer globalen Pandemie, im ständigen Wandel. Gleichzeitig erfordern endliche Ressourcen bei einem insgesamt steigenden Mobilitätsbedarf effiziente Lösungsansätze für die Mobilität von heute und Morgen.

Ein Beispiel für eine aktuell stattfindende Transformation in der Mobilität ist die zunehmende Nutzung von MoD- und MaaS-Angeboten anstelle herkömmlicher Mobilitätsformen, wie z. B. des privaten Pkw. Mobilitätsangebote der Zukunft setzen dabei auf digitale Geschäftsprozesse und vernetzte Fahrzeugflotten. Diese Eigenschaften bilden die Grundlage für datengetriebene Analysen, Optimierungen und Algorithmen für einen effizienten Betrieb.

Ziel dieser Arbeit war es, Optimierungspotentiale für den Betrieb von Ridesourcing-Diensten zu identifizieren, mögliche Optimierungspfade aufzuzeigen und deren Wirksamkeit zu bewerten.

Hierzu wurde zu Beginn eine allgemeine Einordnung zentraler Begriffe und Akteurs-Konstellationen vorgenommen und Hintergründe im Kontext von Ridesourcing-Systemen dargestellt. Im Rahmen einer Literaturanalyse wurden vier wesentliche Optimierungspfade für den Betrieb von Ridesourcing-Systemen identifiziert (Kapitel 2). Diese umfassen die Vermittlung von freien Fahrzeugen zu Kunden (Vermittlungsstrategie), das Umverteilen freier Fahrzeuge (Rebalancing), die Vorhersage der zukünftigen Kundennachfrage bzw. des Angebots (Prädiktion), sowie die Bestimmung der notwendigen Anzahl an Fahrzeugen (Fleet-Sizing).

Als Anwendungsbeispiel dieser Arbeit dient der Münchner Taxiverkehr. Dazu wurden über einen Zeitraum von fünf Jahren Bewegungsdaten einer Münchner Taxiflotte erhoben und aufbereitet (Kapitel 3). In einer Analyse des Datensatzes wurden zeitliche, räumliche und externe Einflussfaktoren auf das Angebots- und Nachfrageverhalten dargestellt und relevante Systemindikatoren und monetäre Kennzahlen ausgewertet (Kapitel 4). Der hohe Kostendruck innerhalb der Branche wurde vor dem Hintergrund zukünftiger Anpassungen des Mindestlohns und dem Nachfrageeinbruch in Folge der globalen COVID-19 Pandemie deutlich. Als Ergebnis der Datenanalyse wurden wirtschaftliche und technische Optimierungspotentiale von Ridesourcing-Systemen anhand des Anwendungsbeispiels aufgezeigt.

Auf Basis der Analyse des Stand der Technik sowie des erhobenen Mobilitätsdatensatzes wurde im Anschluss ein Simulationsmodell für die Evaluation prädiktiver Flottenstrategien aufgebaut (Kapitel 5). Dazu wurden Teilmodelle für Vermittlungs- und Rebalancingstrategie, Nachfrageprädiktion und Flottengrößenanpassung entwickelt und in das bestehende Simulationsframework AMoDeus [19] integriert. Ein Kernaspekt dieser Arbeit bildete dabei die Entwicklung einer prädiktiven, gewinnmaximierenden Rebalancingstrategie samt dem zugehörigen Modell zur Vorhersage des räumlich, zeitlichen Fahrgastaufkommens. Das Simulationsmodell wurde anhand des vorliegenden Referenzdatensatzes validiert.

Um den Einfluss einzelner Optimierungsmaßnahmen und deren Zusammenspiel zu quantifizieren, wurden die jeweiligen Kombinationen von insgesamt drei Vermittlungsstrategien, drei Rebalancingstrategien und acht verschiedenen Flottengrößen im Rahmen von 1716 Einzelsimulationen untersucht (Kapitel 6).

Die Ergebnisse wurden einer Simulation des gegenwärtigen Ist-Zustandes (Referenzszenario) gegenübergestellt. Der Untersuchungszeitraum der Simulationsstudie erstreckte sich über das gesamte Jahr 2019 und bildet damit erstmalig auch saisonal schwankende Angebots- und Nachfrageverläufe ab.

Die Simulationsstudien zeigen, dass durch die geeignete Wahl von Vermittlungs- und Rebalancingstrategie hauptsächlich eine Verbesserung, kundenrelevanter Kennwerte (Wartezeit, Erfüllbarkeit) zu erreichen ist. In keinem der untersuchten Szenarien konnte auf Grund einer geänderten Vermittlungs- bzw. Rebalancingstrategie eine nennenswerte Kosteneinsparung erzielt werden. Hauptkostentreiber konventioneller Fahrzeugflotten sind, wie auch in der Potentialanalyse gezeigt, die Lohnkosten für angestellte Fahrer, sowie Fixkosten für Anschaffung und Unterhalt der Fahrzeugflotte. Es wurde gezeigt, dass eine Kosten- und Gewinnoptimierung nur durch eine Verkleinerung der Fahrzeugflotte bzw. deren Betriebszeiten erreicht werden kann. Eine Verkleinerung der Fahrzeugflotte ohne Einbußen in Bezug auf die Servicequalität sind nur durch gleichzeitige Anpassung der Vermittlungs-/Rebalancingstrategie zu erreichen.

Die Ergebnisse dieser Arbeit wurden in Kapitel 7 eingehend diskutiert, die aufgestellten Forschungsfragen beantwortet, Handlungsempfehlungen formuliert, Möglichkeiten zur technischen Umsetzung aufgezeigt und die Relevanz der Forschungsergebnisse hervorgehoben.

Diese Arbeit hinterlässt Anknüpfungspunkte für die weitere Untersuchung und Optimierung von Ridesourcing-Systemen (Unterkapitel 7.1). Größtes Optimierungspotential besteht hierbei in einer weiteren Verbesserung der Schicht und Einsatzplanung der Fahrzeuge. Als Ausgangspunkt könnte hierzu eine mittelfristige Prognose der zu erwartenden Kundennachfrage dienen und damit das optimale Verhältnis von Fahrzeugen und Anfragen modellbasiert bestimmt werden.

Für die praktische Umsetzung der vorgestellten Ansätze ist darüber hinaus zu untersuchen, wie zukünftig durch geeignete Anreizstrukturen eine entsprechende Akzeptanz und Mitwirkung aller beteiligten Akteure erreicht werden kann.

Abbildungsverzeichnis

Abbildung 2.1:	Zusammenhang zwischen Angebot und Nachfrage in MaaS/MoD Systemen in Anlehnung an [23, S. 3].	4
Abbildung 2.2:	Beispiele für Zeitreihen in Ridesourcingsystemen: Links: Angebot an Fahrzeugen, Rechts: Kundennachfrage im Zeitraum 2.–7. Juli 2018.	14
Abbildung 2.3:	Beispiel räumlich/zeitlich veränderlicher Abfahrtsorte (orange) von Taxifahrten in München (Karte: Stamen Desing   . Daten: OpenStreetMap, unter ODbL).	16
Abbildung 2.4:	Aufbau der Arbeit	27
Abbildung 3.1:	Links: Top 10 Veranstaltungsorte, Rechts: Top 10 OSM-Kategorien des Veranstaltungsdatensatzes	32
Abbildung 4.1:	Zeitlicher Verlauf des Angebots- und Nachfrageaufkommens. Stündliche Mittelwerte, sowie 10. und 90. Quantil für den Auswertungszeitraum 09.03.2015-01.01.2020	34
Abbildung 4.2:	Links: Relativer Anteil Fahrten pro Wochentag. Rechts: mittlere, stündliche Anzahl an Fahrten pro Wochentag (Konfidenzintervall 0.95). Auswertungszeitraum: 09.03.2015-01.01.2020	34
Abbildung 4.3:	k-Means Clusteranalyse des wöchentlichen Nachfrageverlaufs ($k = 4$). Mittlere Anzahl an Fahrten, Konfidenzintervall ($c = 0,95$). Auswertungszeitraum: 09.03.2015-01.01.2020	35
Abbildung 4.4:	Kummulierte Anzahl an Fahrten pro Kalenderwoche in 2019. Zuordnung der Clusteranalyse aus Abbildung 4.3	35
Abbildung 4.5:	Heatmap Abfahrts- und Ankunftsorte im Auswertungszeitraum: 09.03.2015-01.01.2020 (Rasterformat H3 [109] - Auflösung 8, Karte: Stamen Design   . Daten: OpenStreetMap, unter ODbL)	37
Abbildung 4.6:	Heatmap Abfahrts- und Ankunftsorte von Fahrten zu/ab Flughafen München im Auswertungszeitraum: 09.03.2015-01.01.2020 (Rasterformat H3 [109] - Auflösung 8, Karte: Stamen Design   . Daten: OpenStreetMap, unter ODbL)	37
Abbildung 4.7:	Räumliche Verteilung der Clusteranalyse (Auswertungszeitraum: 09.03.2015-01.01.2020; Rasterformat H3 [109] - Auflösung 8; Karte: Stamen Design   . Daten: OpenStreetMap, unter ODbL)	39
Abbildung 4.8:	Nachfrageverlauf Clusteranalyse (Auswertungszeitraum: 09.03.2015-01.01.2020; Rasterformat H3 [109] - Auflösung 8; Karte: Stamen Design   . Daten: OpenStreetMap, unter ODbL)	39
Abbildung 4.9:	Einflussfaktor Wetter an Werktagen (Konfidenzintervall ($c = 0,95$), Auswertungszeitraum 09.03.2015-31.12.2018) nach [260]	40
Abbildung 4.10:	Auswirkungen von Verspätungen im S- und U-Bahnverkehr auf die Nachfrage bei Carsharing und Taxi nach [157].	42
Abbildung 4.11:	Mittlere Anzahl an Fahrzeugen nach Vermittlungsstatus (Auswertungszeitraum: 09.03.2015-01.01.2020)	43

Abbildung 4.12:	Links: Relative Häufigkeitsverteilung Kundenwartezeit/Einstiegsdauer. Rechts: Kumulative Häufigkeitsverteilung Kundenwartezeit/Einstiegsdauer. (Auswertungszeitraum: 09.03.2015–01.01.2020)	44
Abbildung 4.13:	Mittlere Kundenwartezeit (blau)/Anzahl an verfügbaren Fahrzeugen (orange) im Wochenverlauf mit Standardabweichung.(Auswertungszeitraum: 09.03.2015–01.01.2020	44
Abbildung 4.14:	Wöchentlicher netto Gewinn/Verlust pro Fahrzeug. Links: 2019 (Lohnkosten: 12,56 €/h), Rechts: 2022 (Lohnkosten: 14,28 €/h)	47
Abbildung 4.15:	Kundennachfrage in Folge des 1. Lockdowns im Zeitraum 16.03.2020-28.06.2020 (orange) in Vergleich zu 18.03.2019-30.06.2019 (blau).	48
Abbildung 4.16:	Änderung Nachfrage (links) und Angebot (rechts) in Folge des 1. Lockdowns im Zeitraum 16.03.2020-28.06.2020 (orange) in Vergleich zu 16.03.2020-28.06.2020 (blau). Konfidenzintervall $c = 0,95$	48
Abbildung 5.1:	Architektur des Simulationsmodells zur Bewertung prädiktiver Flottenstrategien für Ridesourcing Dienste.....	53
Abbildung 5.2:	Zustandsdiagramm eines Taxi-Agenten	55
Abbildung 5.3:	Vermittlungssektoren und Taxistände der Münchner Referenzflotte [204]. (Karte: Stamen Design ). Daten: OpenStreetMap, unter ODbL).	56
Abbildung 5.4:	Schematische Darstellung des Vermittlungsalgorithmus der Münchner Referenzflotte (vgl. [204], [202]).....	57
Abbildung 5.5:	Schematische Darstellung eines bipartiten Graphen für die Zuordnung von Fahrzeugen zu Kunden.....	58
Abbildung 5.6:	Schematische Darstellung des Vermittlungsalgorithmus auf GBPM-Basis.	58
Abbildung 5.7:	Schematische Darstellung des Vermittlungsalgorithmus auf GBPM-Basis.	59
Abbildung 5.8:	Links: Kerngebiet der Referenzstrategie. Rechts: Auswahlwahrscheinlichkeit Taxistände, aufgrund real beobachteter Daten im Referenzzeitraum 2019 (Karte: Stamen Design ). Daten: OpenStreetMap, unter ODbL).	60
Abbildung 5.9:	Standard Rebalancing Verhalten nach Ende einer Kundenfahrt in der Referenzstrategie.	61
Abbildung 5.10:	Ausgleichendes, intervallgesteuertes Rebalancing Verhalten der Referenzstrategie.	61
Abbildung 5.11:	Links: Aufbau der 2-stufigen räumlichen Diskretisierung. Rechts: Parameterwahl am Beispiel der Münchner Referenzflotte (Karte: Carto ). Daten: OpenStreetMap, unter ODbL).....	62
Abbildung 5.12:	Vereinfachter Ablauf der prädiktiven, gewinnmaximierenden Rebalancing Strategie	63
Abbildung 5.13:	Modulare Architektur des Prädiktionsframeworks	68
Abbildung 5.14:	Architektur hybrides LSTM mit Metadaten. (n , Anzahl der Lags, T Vorhersagehorizont)	72
Abbildung 5.15:	Architektur hybrides ConvLSTM mit Metadaten. (i, j , Anzahl der Reihen, Spalten des uniformen Rasters, n , Anzahl der Lags, T Vorhersagehorizont).....	73
Abbildung 5.16:	Einschrittprognose des Modells LSTM mit Metadaten im Zeitraum 23.09.2019–29.09.2019. Vorhersageintervall $\Delta t = 20$ min	75
Abbildung 5.17:	Algorithmus zur dynamischen Anpassung der Flottengröße (Angebot an Fahrzeugen).....	76
Abbildung 6.1:	Verwendetes hybrides Straßennetzwerk der Simulation (Daten: OpenStreetMap, unter ODbL)	78

Abbildung 6.2:	Anpassung der Straßenabschnittsgeschwindigkeit am Beispiel der Simulationswoche 04.11.2019–11.11.2019 nach 280 000 Iterationen. Links: Fahrtzeiten vor und nach Anpassung im Vergleich zur Referenz. Rechts: Fahrtstrecken vor und nach Anpassung im Vergleich zur Referenz.....	79
Abbildung 6.3:	Übersicht Anzahl Kundenaufträge im Simulationsszenario	79
Abbildung 6.4:	Aggregierte Abweichung Simulation/Referenzdaten für 52 Wochen in 2019.....	82
Abbildung 6.5:	Verlauf der Flottengröße für das Referenzszenario (Samplingfrequenz 5 min), Arbeitsstunden am Beispiel der KW 45 2019	82
Abbildung 6.6:	Vergleich Flottenauslastung Simulation/Referenzszenario am Beispiel der KW 45 2019	83
Abbildung 6.7:	Vergleich Fahrtstrecke und -dauer Simulation/Referenzszenario am Beispiel der KW 45–2019	84
Abbildung 6.8:	Wöchentliche prozentuale Abweichung der kumulierten Distanz nach Fahrzeugstatus.....	85
Abbildung 6.9:	Vergleich Kundenwartezeit Simulation/Referenzdatensatz am Beispiel der KW 45 2019. Links: Histogramm der Wartezeiten (Bingröße 1 min) Rechts: Kumulative Häufigkeitsverteilung (GDF) der Wartezeiten	85
Abbildung 6.10:	Vergleich Kundenwartezeit Simulation/Referenzdatensatz für alle simulierten Wochen in 2019. Links: Mittlere Wartezeit pro Simulationswoche (X), Q_{25} - Q_{75} (I). Rechts: Wöchentliche prozentuale Abweichung der mittleren Wartezeit	86
Abbildung 6.11:	Vergleich Auftragserefüllungsquote Simulation/Referenz. Links: Summe bedienter Kunden pro Woche, Rechts: Verteilung der Ablehnungsquote pro Simulationswoche in Prozent	86
Abbildung 6.12:	Einfluss der Vermittlungsstrategie auf die mittlere wöchentliche Wartezeit (Links), die mittlere wöchentliche Vermittlungsdauer (Mitte) und die wöchentliche Ablehnungsquote (Rechts).....	88
Abbildung 6.13:	Einfluss der Vermittlungsstrategie auf die Anfahrstrecke: Wöchentlicher Mittelwert in km (Links), wöchentlicher Median (Mitte), wöchentliche Gesamtstrecke im Vergleich zu REF-REF-100 (Rechts)	88
Abbildung 6.14:	Einfluss der Vermittlungsstrategie auf die Kennwerte: Mittlere Flottenauslastung, Kosten 2019 (Differenz zu REF-REF-100 in %) und Umsatz 2019 (Differenz zu REF-REF-100 in %).....	89
Abbildung 6.15:	Einfluss der Rebalancingstrategie auf die mittlere wöchentliche Wartezeit (Links), die mittlere und die wöchentliche Ablehnungsquote (Rechts)	91
Abbildung 6.16:	Änderung der Kundenwartezeit durch prädiktives Rebalancing für 100 % (Links) und 80 % Flottengröße.	91
Abbildung 6.17:	Einfluss der Rebalancingstrategie auf Anfahrs- (oben) und Rebalancingdistanzen (unten)	92
Abbildung 6.18:	Einfluss der Rebalancingstrategie auf die Kennwerte: Mittlere Flottenauslastung, Kosten 2019 (Differenz zu REF-REF-100 in %) und Umsatz 2019 (Differenz zu REF-REF-100 in %).....	93
Abbildung 6.19:	Beispiel zeitlicher Verlauf des Flottenstatus für PRLP4x4-GBPM-80 für die Simulationswoche KW 45–2019	94
Abbildung 6.20:	Einfluss der Flottenanpassung auf die mittlere wöchentliche Wartezeit (Links) und die wöchentliche Ablehnungsquote (Rechts).....	95
Abbildung 6.21:	Einfluss der Flottenanpassung auf die Kennwerte: Kosten 2019 (Differenz zu REF-REF-100 in %) und Umsatz 2019 (Differenz zu REF-REF-100 in %)	95

Tabellenverzeichnis

Tabelle 2.1:	Zeitreihenvorhersage in ihrer Anwendung bei Ridesourcing Datensätzen	17
Tabelle 2.2:	Literaturübersicht koordinierter Rebalancing Verfahren	19
Tabelle 3.1:	Zusammenfassung Taxi Bewegungsdaten.....	29
Tabelle 3.2:	Übersicht Datenfelder Taxi Bewegungsdaten	30
Tabelle 3.3:	Datentransformation und Filterung	30
Tabelle 3.4:	Überblick ÖPNV Verspätungsdatensatz aus [157].....	31
Tabelle 3.5:	Übersicht Datenfelder Veranstaltungsdatensatz	32
Tabelle 4.1:	Relative mittlere Änderung der Kundennachfrage in Folge von Niederschlag	41
Tabelle 4.2:	Fahrtbezogene Kennwerte der Münchner Referenzflotte im Auswertungszeitraum 09.03.2015-01.01.2020	42
Tabelle 4.3:	Mittlerer strecken- und zeitbezogener Anteil Fahrzeugstatus.....	43
Tabelle 4.4:	Kostenabschätzung (netto) für den Betrieb eines Taxis im Flotteneinsatz im Jahr 2019 auf Basis von [153] [192] *Wert nicht angegeben, übernommen aus [153], **Mittelwert aus [153] und [192], ***Bruttolohn inkl. Sozialversicherungsabgaben	46
Tabelle 4.5:	Kostenentwicklung (netto) für den Betrieb eines Fahrzeugs im Flottenbetrieb (n=490 Fzg.) bis 2022 auf Basis des Referenzdatensatzes. **Mittelwert aus [153] und [192], ***Bruttolohn inkl. Sozialversicherungsabgaben	47
Tabelle 4.6:	Gewinn/Verlustrechnung (netto) für den COVID-19 Zeitraum (16.03.2020-28.06.2020) im Vergleich zum Vorjahreszeitraum (16.03.2020-28.06.2020)	49
Tabelle 5.1:	Räumliche Verteilung der Abfahrtsorte [205].....	63
Tabelle 5.2:	Beispiel für die Umwandlung der Rohdaten in eine raum-/zeitdiskrete Zeitreihe	68
Tabelle 5.3:	Lagged Supervised Learning Problem.....	69
Tabelle 5.4:	Beispiel für den Eingangsvektor der Lag Variablen für $n = 36$	70
Tabelle 5.5:	Beispiel für den Eingangsvektor der Metadaten.....	71
Tabelle 5.6:	Prognosegüte der Einschrittprognose einzelner Vorhersagemethoden im Zeitraum 01.01.2019-31.12.2019.....	74
Tabelle 5.7:	Prognosegüte des Modells LSTM mit Metadaten für die Vorhersage von 2 Zeitschrit- ten im Zeitraum 01.01.2019-31.12.2019.....	74
Tabelle 6.1:	Allgemeingültig übergreifende Simulationsparameter für alle simulierten Strategien ...	80
Tabelle 6.2:	Verwendete Notation zur Beschreibung der Simulationsszenarien	81
Tabelle 6.3:	Simulationsparameter Referenzstrategie.....	81
Tabelle 6.4:	Aggregierte prozentuale Abweichung Simulation/Referenzdaten für 52 Wochen in 2019	82
Tabelle 6.5:	Parameter Simulationsszenarien bei Änderung der Vermittlungsstrategie.....	87
Tabelle 6.6:	Parameter Simulationsszenarien bei Änderung der Rebalancingstrategie	90

Literaturverzeichnis

- [1] Europäische Kommission. „*Sustainable and Smart Mobility Strategy – putting European transport on track for the future*,“ Brüssel, 2020. Verfügbar: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:52020DC0789> [aufgerufen am 29. 11. 2021].
- [2] International Transport Forum, *ITF Transport Outlook 2021*, OECD, 2021, DOI: 10.1787/16826a30-en. Verfügbar: <https://doi.org/10.1787/16826a30-en>.
- [3] United Nations. „*Mobility and Transport*,“ New York, USA, 2021. Verfügbar: <https://unhabitat.org/topic/mobility-and-transport> [aufgerufen am 28. 11. 2021].
- [4] INRIX, „INRIX Traffic Scorecard: Fahrten in deutsche Innenstädte gehen während der Pandemie um 40 % zurück,“ Kirkland, Washington, 2021. Verfügbar: <https://inrix.com/press-releases/2020-traffic-scorecard-de/> [aufgerufen am 25. 11. 2021].
- [5] G. Duranton und M. A. Turner, „The Fundamental Law of Road Congestion: Evidence from US Cities,“ *American Economic Review*, Bd. 101, Rn. 6, S. 2616–52, 2011, DOI: 10.1257/aer.101.6.2616. Verfügbar: <https://www.aeaweb.org/articles?id=10.1257/aer.101.6.2616>.
- [6] Bund für Umwelt und Naturschutz Deutschland e. V. (BUND). „*Verkehrsinfrastruktur: Straßenbau erhöht den Verkehr, nicht die Mobilität!*,“ 2020. Verfügbar: <https://www.bund.net/themen/mobilitaet/infrastruktur/> [aufgerufen am 29. 11. 2021].
- [7] T. Henzelmann, T. Schönberg, C. Neuenhahn, T. Wunder und D. Frei, *Urbane Mobilität 2030: zwischen Anarchie und Hypereffizienz Autonomes Fahren, Elektrifizierung und die Sharing Economy bestimmen den Stadtverkehr von morgen*, München, ROLAND BERGER GMBH, 2017. Verfügbar: https://www.rolandberger.com/publications/publication_pdf/roland_berger_urbane_mobilitaet_2030.pdf.
- [8] T. Keeney, „*Mobility-As-A-Service: Why Self-Driving Cars Could Change Everything*,“ Ark Invest, New York, 2017. Verfügbar: <http://www.ibisworld.com/industry/default.aspx?indid=1951>.
- [9] Uber. „*Company Information | Uber Newsroom*,“ 2020. Verfügbar: <https://www.uber.com/en-PK/newsroom/company-info/> [aufgerufen am 10. 01. 2020].
- [10] J. Hartmann, „Taxi Deutschland: Uber agiert weiterhin illegal,“ *TAXItimes*, 2021. Verfügbar: <https://www.taxi-times.com/taxi-deutschland-uber-agiert-weiterhin-illegal/> [aufgerufen am 12. 08. 2020].
- [11] Deutscher Taxi- und Mietwagenverband e. V. „*BZP Geschäftsbericht 2019/2020*,“ 2020. Verfügbar: <https://bundesverband.taxi/wp-content/uploads/2021/01/20210118-GB-LAYOUT-2015.pdf>.
- [12] C. Ruch, S. Hörl, J. Hakenberg und E. Frazzoli, „The Impact of Fleet Coordination on Taxi Operations,“ 2019, DOI: 10.3929/ETHZ-B-000379519.
- [13] M. M. Vazifeh, P. Santi, G. Resta, S. H. Strogatz und C. Ratti, „Addressing the minimum fleet problem in on-demand urban mobility,“ *Nature*, Bd. 557, Rn. 7706, S. 534–538, 2018, DOI: 10.1038/s41586-018-0095-1.

- [14] F. Dandl, M. Hyland, K. Bogenberger und H. S. Mahmassani, „Evaluating the impact of spatio-temporal demand forecast aggregation on the operational performance of shared autonomous mobility fleets,“ *Transportation*, Bd. 46, Rn. 6, S. 1975–1996, 2019, DOI: 10.1007/s11116-019-10007-9. Verfügbar: <https://doi.org/10.1007/s11116-019-10007-9>.
- [15] T. Oda und C. Joe-Wong, „MOVI: A Model-Free Approach to Dynamic Fleet Management,“ in *IEEE INFOCOM 2018 - IEEE Conference on Computer Communications*, 2018, DOI: 10.1109/infocom.2018.8485988. Verfügbar: <https://doi.org/10.1109/infocom.2018.8485988>.
- [16] L. Moreira-Matias, J. Gama, M. Ferreira, J. Mendes-Moreira und L. Damas, „Predicting Taxi–Passenger Demand Using Streaming Data,“ *IEEE Transactions on Intelligent Transportation Systems*, Bd. 14, Rn. 3, S. 1393–1402, 2013, DOI: 10.1109/tits.2013.2262376. Verfügbar: <https://doi.org/10.1109/tits.2013.2262376>.
- [17] MarketsandMarkets. „*Fleet Management Market*,“ 2019. Verfügbar: https://www.marketsandmarkets.com/Market-Reports/fleet-management-systems-market-1020.html?gclid=Cj0KCQiAuefvBRDXARIsAFEOQ9GIZeOFHI%7B%5C_%7DIBIxZBZRptB3QDtHToiq3qjf0OABBowCzNUabIBT787UaAlSkEALw%7B%5C_%7Dwcb [aufgerufen am 10. 01. 2020].
- [18] *Multi-Agent Transport Simulation MATSim*, London, Ubiquity Press, S. 618, 2016, ISBN: 978-1-909188-75-4. DOI: 10.5334/baw.
- [19] C. Ruch, S. Horl und E. Frazzoli, „AMoDeus, a Simulation-Based Testbed for Autonomous Mobility-on-Demand Systems,“ in *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, 2018, DOI: 10.1109/itsc.2018.8569961.
- [20] E. Guhl und W. Koner, *Das Leben der Griechen und Römer nach antiken Bildwerken*, Weidmann, 1864.
- [21] G. von Ende, *Berliner Hufgeklapper: Pferde als Spiegel der Vergangenheit*, tredition, 2020, ISBN: 9783347020979.
- [22] J. Lucendo, *Universelle Erfinder: Geschichte und Biographie der Erfinder*, Jorge Lucendo, 2019, ISBN: 9781393599722.
- [23] S. Shaheen, A. Cohen, B. Yelchuru und S. Sarkhili, „Mobility on Demand Operational Concept Report,“ U.S. Department of Transportation, Washington, DC Rep. FHWA-JPO-18-611, 2017. Verfügbar: www.its.dot.gov/index.htm.
- [24] S. Shaheen, A. Cohen und I. Zohdy, „Shared Mobility: Current Practices and Guiding Principles,“ U.S. Department of Transportation, Federal Highway Administration, Washington, DC Rep. Fhwa-Hop-16-022 2. 2016.
- [25] D. A. Hensher, C. Q. Ho, C. Mulley, J. D. Nelson, G. Smith und Y. Z. Wong, „Chapter 2 - What is MaaS and how it fits into the transport landscape,“ in *Understanding Mobility as a Service (MaaS)*, D. A. Hensher, C. Q. Ho, C. Mulley, J. D. Nelson, G. Smith und Y. Z. Wong, Hrsg. Elsevier, 2020, S. 13–33, ISBN: 978-0-12-820044-5. DOI: <https://doi.org/10.1016/B978-0-12-820044-5.00002-6>.
- [26] United States Department of Transportation. „*Mobility on Demand(MOD)*,“ 2021. Verfügbar: <https://www.its.dot.gov/factsheets/mobilityondemand.htm> [aufgerufen am 15. 08. 2021].
- [27] MaaS ALLIANCE. „*What is MaaS?*,“ 2021. Verfügbar: <https://maas-alliance.eu/homepage/what-is-maas/> [aufgerufen am 15. 08. 2021].
- [28] A. Vij, S. Ryan, S. Sampson und S. Harris, „Consumer preferences for on-demand transport in Australia,“ *Transportation Research Part A: Policy and Practice*, Bd. 132, S. 823–839, 2020, DOI: <https://doi.org/10.1016/j.tra.2019.12.026>.

- [29] Dudenredaktion (o. J.) „Taxi,“ 2021. Verfügbar: <https://www.duden.de/rechtschreibung/Taxi> [aufgerufen am 15. 08. 2021].
- [30] L. Rayle, D. Dai, N. Chan, R. Cervero und S. Shaheen, „Just a better taxi? A survey-based comparison of taxis, transit, and ridesourcing services in San Francisco,“ *Transport Policy*, Bd. 45, S. 168–178, 2016, DOI: 10.1016/j.tranpol.2015.10.004.
- [31] t3n. „Bitte einsteigen: Ein Besuch bei den Gründern von myTaxi,“ 2021. Verfügbar: <https://t3n.de/magazin/grunderstory-mytaxi-bitte-einsteigen-229511/> [aufgerufen am 15. 08. 2021].
- [32] taxi.eu. „Firmenportrait,“ 2019. Verfügbar: https://www.taxi.eu/wp-content/uploads/2019/03/Firmenportrait-de_2019.pdf [aufgerufen am 15. 08. 2021].
- [33] Forschungs-Informations-System Mobilität und Verkehr. „Ridesourcing und Rideselling,“ 2019. Verfügbar: <https://www.forschungsinformationssystem.de/servlet/is/72108/> [aufgerufen am 15. 08. 2021].
- [34] C. Yang und E. J. Gonzales, „Modeling taxi trip demand by time of day in New York City,“ *Transportation Research Record*, Bd. 2429, Rn. 1, S. 110–120, 2014.
- [35] Y. Liu, P. Bansal, R. Daziano und S. Samaranayake, „A framework to integrate mode choice in the design of mobility-on-demand systems,“ Bd. 105, S. 648–665, 2019, DOI: 10.1016/j.trc.2018.09.022. Verfügbar: <https://doi.org/10.1016/j.trc.2018.09.022>.
- [36] H. Simsek, „Free Now erhöht die Vermittlungsgebühren für Taxis,“ *TAXItimes*, 2020. Verfügbar: <https://www.taxi-times.com/free-now-erhoeht-die-vermittlungsguebuehren-fuer-taxis/> [aufgerufen am 12. 08. 2020].
- [37] S. Banerjee, C. Riquelme und R. Johari, „Pricing in Ride-Share Platforms: A Queueing-Theoretic Approach,“ *SSRN Electronic Journal*, 2015, DOI: 10.2139/ssrn.2568258. Verfügbar: <https://doi.org/10.2139/ssrn.2568258>.
- [38] S. Harding, M. Kandlikar und S. Gulati, „Taxi apps, regulation, and the market for taxi journeys,“ *Transportation Research Part A: Policy and Practice*, Bd. 88, S. 15–25, 2016, DOI: 10.1016/j.tra.2016.03.009. Verfügbar: <https://doi.org/10.1016/j.tra.2016.03.009>.
- [39] J. Cramer und A. B. Krueger, „Disruptive Change in the Taxi Business: The Case of Uber,“ *American Economic Review*, Bd. 106, Rn. 5, S. 177–182, 2016, DOI: 10.1257/aer.p20161002. Verfügbar: <https://doi.org/10.1257/aer.p20161002>.
- [40] J. Castiglione, T. Chang, D. Cooper, J. Hobson, W. Logan, E. Young und B. Charlton, „TNCs Today: A Profile of San Francisco Transportation Network Company Activity,“ San Francisco County Transportation Authority, San Francisco, USA, 2017. Verfügbar: https://www.sfcta.org/sites/default/files/2019-02/TNCs_Today_112917_0.pdf [aufgerufen am 12. 08. 2020].
- [41] J. Willmroth, „Freie Fahrt für freie Taxler,“ *Süddeutsche Zeitung Online*, 2019. Verfügbar: <https://www.sueddeutsche.de/auto/fahrdienste-taxi-uber-1.4336689>.
- [42] N. Lomas, „Anti-Uber taxi strikes kick off again in Spain,“ *TechCrunch*, 2019. Verfügbar: <https://techcrunch.com/2019/01/21/anti-uber-taxi-strikes-kick-off-again-in-spain/>.
- [43] P. Rodero. „Spain taxi drivers end Uber strike after license limits agreed,“ 2018. Verfügbar: <https://www.reuters.com/article/us-uber-spain-strike-idUSKBN1KN0JH> [aufgerufen am 15. 08. 2018].
- [44] D. Kyvrikosaios und A. Konstantinidis. „Taxi drivers protest against Uber ‘invasion’ in Greece,“ 2018. Verfügbar: <https://www.reuters.com/article/us-greece-protests-taxis-uber-idUSKCN1GI1ST> [aufgerufen am 15. 08. 2018].
- [45] M. Slater-Robins und B. Tasch. „French taxi drivers shut down Paris as protests over Uber turn violent,“ 2016. Verfügbar: <https://www.businessinsider.com/uber-protests-in-paris-2016-1> [aufgerufen am 15. 08. 2018].

- [46] F. Heunemann und H. Schwan, „Uber hält Urteil für überflüssig,“ *Frankfurter Allgemeine Zeitung*, 2021. Verfügbar: <https://www.faz.net/aktuell/rhein-main/wirtschaft/uber-verliert-berufungsverfahren-in-frankfurt-17353777.html>.
- [47] A. Buhtz, „Uber-Fahrer haben Recht auf Anstellung,“ *Zeit Online*, 2021. Verfügbar: <https://www.zeit.de/mobilitaet/2021-02/grossbritannien-uber-fahrer-festanstellung-rechtsstreit>.
- [48] J. Cooper und R. Mundy, *Taxi! Urban Economies and the Social and Transport Impacts of the Taxicab*, Routledge, 2016, DOI: 10.4324/9781315611884. Verfügbar: <https://doi.org/10.4324/9781315611884>.
- [49] L. Balafoutas, A. Beck, R. Kerschbamer und M. Sutter, „What Drives Taxi Drivers? A Field Experiment on Fraud in a Market for Credence Goods,“ *The Review of Economic Studies*, Bd. 80, Rn. 3, S. 876–891, 2013, DOI: 10.1093/restud/rds049.
- [50] B. Koehler, „Licence Values in Taxi Markets,“ *Economic Affairs*, Bd. 25, Rn. 2, S. 52–54, 2005, DOI: 10.1111/j.1468-0270.2005.00553.x.
- [51] B. M. Rosenzahl, „New York to Spend \$65 Million to Rescue Cab Drivers. Is It Enough?,“ *The New York Times*, 2021. Verfügbar: <https://www.nytimes.com/2021/03/09/nyregion/nyc-taxi-drivers-bailout.html>.
- [52] K. M. Gwilliam, „Regulation of Taxi Markets in Developing Countries: Issues and Options,“ The World Bank, Washington, DC, USA, 2005. Verfügbar: <https://openknowledge.worldbank.org/bitstream/handle/10986/11780/33896a10TRN131Taxi1Reg.pdf?sequence=1&isAllowed=y> [aufgerufen am 12.08.2020].
- [53] Bundesamt für Güterverkehr, „Marktbeobachtung Güterverkehr: Marktanalyse des Fernbuslinienverkehrs 2019,“ Bundesamt für Güterverkehr, Köln, 2020. Verfügbar: https://www.bag.bund.de/SharedDocs/Downloads/DE/Marktbeobachtung/Sonderberichte/SB_Fernbus_2019.pdf?__blob=publicationFile [aufgerufen am 12.08.2020].
- [54] G. Topham, „How London got rid of private cars – and grew more congested than ever,“ *The Guardian*, 2020. Verfügbar: <https://www.theguardian.com/politics/2020/feb/11/how-london-got-rid-of-private-cars-and-grew-more-congested-than-ever>.
- [55] Z. Li, C. Liang, Y. Hong und Z. Zhang, „How Do On-demand Ridesharing Services Affect Traffic Congestion? The Moderating Role of Urban Compactness,“ *Production and Operations Management*, 2021, DOI: 10.1111/poms.13530.
- [56] M. E. Sutherland, „Lyft and Uber increase congestion in San Francisco,“ *Nature Human Behaviour*, Bd. 3, Rn. 7, S. 657–657, 2019, DOI: 10.1038/s41562-019-0660-0.
- [57] Z. Li, Y. Hong und Z. Zhang, „An Empirical Analysis of On-demand Ride-sharing and Traffic Congestion,“ in *Proceedings of the 50th Hawaii International Conference on System Sciences (2017)*, 2017, DOI: 10.24251/hicss.2017.002.
- [58] R. D. Cairns und C. Liston-Heyes, „Competition and regulation in the taxi industry,“ *Journal of Public Economics*, Bd. 59, Rn. 1, S. 1–15, 1996, DOI: 10.1016/0047-2727(94)01495-7.
- [59] J.-T. Bekken und F. Longva, „Impact of Taxi Market Regulation,“ Transportøkonomisk institutt, TØI, Oslo, Norway, 2017. Verfügbar: <https://www.toi.no/getfile.php?mmfileid=5006> [aufgerufen am 12.08.2020].
- [60] A. Asadullah, I. Faik und A. Kankanhalli, „Digital Platforms: A Review and Future Directions,“ in *PACIS 2018 Proceedings*, 2018, S. 248. Verfügbar: <https://aisel.aisnet.org/pacis2018/248>.
- [61] J. Hartmann, „Free Now-Start in München: Billiger als Uber, Vierfacher Provisionspreis,“ *TAXItimes*, 2019. Verfügbar: <https://www.taxi-times.com/free-now-start-in-muenchen-billiger-als-uber-vierfacher-provisionspreis/> [aufgerufen am 12.08.2020].

- [62] X. Qian und S. V. Ukkusuri, „Taxi market equilibrium with third-party hailing service,“ *Transportation Research Part B: Methodological*, Bd. 100, S. 43–63, 2017, DOI: 10.1016/j.trb.2017.01.012. Verfügbar: <https://doi.org/10.1016/j.trb.2017.01.012>.
- [63] K. Paul, „Uber and Lyft drivers join day-long strike over working conditions,“ *The Guardian*, 2021. Verfügbar: <https://www.theguardian.com/technology/2021/jul/21/uber-lyft-drivers-strike-app-based-work-gig-economy>.
- [64] T. Sonnemaker, „Uber and Lyft drivers who say they don't want to drive for the ride-share companies right now are holding out for higher pay and better working conditions. Others say they may never return.“ *Business Insider*, 2021. Verfügbar: <https://www.businessinsider.com/why-uber-lyft-expensive-taking-long-driver-shortage-2021-4>.
- [65] „EU will Arbeitsbedingungen für Uber-Fahrer verbessern,“ *Frankfurter Allgemeine Zeitung*, 2021. Verfügbar: <https://www.faz.net/aktuell/wirtschaft/eu-will-arbeitsbedingungen-fuer-uber-fahrer-verbessern-17214710.html>.
- [66] A. Macho und J. Guldner, „Die dunkle Seite der Digitalisierung“, *Wirtschaftswoche*, 2019. Verfügbar: <https://www.wiwo.de/my/unternehmen/dienstleister/arbeitsbedingungen-bei-uber-die-dunkle-seite-der-digitalisierung/25009890.html?ticket=ST-7162060-bYth2fbRH67proFiocaQ-ap6>.
- [67] Statista. „Ridehailing & Taxi - Weltweit,“ 2021. Verfügbar: <https://de.statista.com/outlook/mmo/mobilitaetsdienste/ridehailing-taxi/weltweit> [aufgerufen am 15.08.2021].
- [68] M. Kümmel, „Taxis, Passengers and Stable Marriage,“ Dissertation, Technische Universität München, 2016.
- [69] U. Ritzinger, J. Puchinger und R. F. Hartl, „A survey on dynamic and stochastic vehicle routing problems,“ *Int. J. Prod. Res.*, Bd. 54, Rn. 1, S. 215–231, 2016, DOI: 10.1080/00207543.2015.1043403.
- [70] V. Pillac, M. Gendreau, C. Guéret und A. L. Medaglia, „A review of dynamic vehicle routing problems,“ *Eur. J. Oper. Res.*, Bd. 225, Rn. 1, S. 1–11, 2013, DOI: 10.1016/j.ejor.2012.08.015.
- [71] M. Klöppel, „Transport System with Shared Vehicles,“ Dissertation, Technische Universität München, 2021.
- [72] G. B. Dantzig und J. H. Ramser, „The Truck Dispatching Problem,“ *Manage. Sci.*, Bd. 6, Rn. 1, S. 80–91, 1959, DOI: 10.1287/mnsc.6.1.80.
- [73] H. Farreny und H. Prade, *Heuristics—intelligent search strategies for computer problem solving, by Judea Pearl. (Reading, Ma: Addison-Wesley, 1984)*. Bd. 1, S. 69–70, 1986, DOI: 10.1002/int.4550010107.
- [74] D.-H. Lee, H. Wang, R. L. Cheu und S. H. Teo, „Taxi Dispatch System Based on Current Demands and Real-Time Traffic Conditions,“ *Transportation Research Record: Journal of the Transportation Research Board*, Bd. 1882, Rn. 1, S. 193–200, 2004, DOI: 10.3141/1882-23.
- [75] M. Maciejewski und J. Bischoff, „Large-scale Microscopic Simulation of Taxi Services,“ *Procedia Computer Science*, Bd. 52, S. 358–364, 2015, DOI: 10.1016/j.procs.2015.05.107.
- [76] M. Kümmel, F. Busch und D. Z. Wang, „Taxi Dispatching and Stable Marriage,“ *Procedia Comput. Sci.*, Bd. 83, S. 163–170, 2016, DOI: 10.1016/j.procs.2016.04.112.
- [77] M. Maciejewski, J. Bischoff und K. Nagel, „An Assignment-Based Approach to Efficient Real-Time City-Scale Taxi Dispatching,“ *IEEE Intelligent Systems*, Bd. 31, Rn. 1, S. 68–77, 2016, DOI: 10.1109/mis.2016.2.

- [78] S. K. Verma und H. T. Vo, „A Predictive Taxi Dispatching System for Improved User Satisfaction and Taxi Utilization,“ in *2015 IEEE Int. Conf. Smart City/SocialCom/SustainCom*, 2015, S. 175–182, ISBN: 978-1-5090-1893-2. DOI: 10.1109/SmartCity.2015.67.
- [79] X. Zhan, X. Qian und S. V. Ukkusuri, „A Graph-Based Approach to Measuring the Efficiency of an Urban Taxi Service System,“ *IEEE Transactions on Intelligent Transportation Systems*, Bd. 17, Rn. 9, S. 2479–2489, 2016, DOI: 10.1109/tits.2016.2521862.
- [80] W. Domschke, A. Drexl, R. Klein und A. Scholl, *Einführung in Operations Research*, Springer Berlin Heidelberg, 2015, DOI: 10.1007/978-3-662-48216-2.
- [81] H. W. Kuhn, „The Hungarian Method for the assignment problem,“ *Nav. Res. Logist. Q.*, Bd. 2, S. 83–97, 1955.
- [82] L. Suhl und T. Mellouli, *Optimierungssysteme*, Springer Berlin Heidelberg, 2013, DOI: 10.1007/978-3-642-38937-5.
- [83] S. Hörl, C. Ruch, F. Becker, E. Frazzoli und K. W. Axhausen, „Fleet control algorithms for automated mobility A simulation assessment for Zurich,“ in *Transp. Res. Board 97th Annu. Meet.* 2018, DOI: 10.3929/ethz-b-000254412.
- [84] F. Miao, S. Han, S. Lin, Q. Wang, J. A. Stankovic, A. Hendawi, D. Zhang, T. He und G. J. Pappas, „Data-Driven Robust Taxi Dispatch Under Demand Uncertainties,“ *IEEE Transactions on Control Systems Technology*, Bd. 27, Rn. 1, S. 175–191, 2019, DOI: 10.1109/tcst.2017.2766042.
- [85] H. Billhardt, A. Fernández, S. Ossowski, J. Palanca und J. Bajo, „Taxi dispatching strategies with compensations,“ *Expert Systems with Applications*, Bd. 122, S. 173–182, 2019, DOI: 10.1016/j.eswa.2019.01.001.
- [86] M. Hyland und H. S. Mahmassani, „Dynamic autonomous vehicle fleet operations: Optimization-based strategies to assign AVs to immediate traveler demand requests,“ *Transportation Research Part C: Emerging Technologies*, Bd. 92, S. 278–297, 2018, DOI: 10.1016/j.trc.2018.05.003.
- [87] Beijing Xiaoju Technology Co Ltd. „DiDi official website,“ 2020. Verfügbar: <https://www.didiglobal.com/> [aufgerufen am 29. 01. 2020].
- [88] Z. Xu, Z. Li, Q. Guan, D. Zhang, Q. Li, J. Nan, C. Liu, W. Bian und J. Ye, „Large-Scale Order Dispatch in On-Demand Ride-Hailing Platforms,“ in *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018, DOI: 10.1145/3219819.3219824.
- [89] L. Zhang, T. Hu, Y. Min, G. Wu, J. Zhang, P. Feng, P. Gong und J. Ye, „A Taxi Order Dispatch Model based On Combinatorial Optimization,“ in *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2017, DOI: 10.1145/3097983.3098138.
- [90] K. T. Seow, N. H. Dang und D.-H. Lee, „Towards An Automated Multiagent Taxi-Dispatch System,“ in *2007 IEEE International Conference on Automation Science and Engineering*, 2007, DOI: 10.1109/coase.2007.4341673.
- [91] K. T. Seow und D.-H. Lee, „Performance of Multiagent Taxi Dispatch on Extended-Runtime Taxi Availability: A Simulation Study,“ *IEEE Transactions on Intelligent Transportation Systems*, Bd. 11, Rn. 1, S. 231–236, 2010, DOI: 10.1109/tits.2009.2033128.
- [92] M.-F. Chiang, T.-A. Hoang und E.-P. Lim, „Where are the passengers?,“ in *Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2015, DOI: 10.1145/2820783.2820807.
- [93] H. wen Chang, Y. chin Tai und J. Y. jen Hsu, „Context-aware taxi demand hotspots prediction,“ *International Journal of Business Intelligence and Data Mining*, Bd. 5, Rn. 1, S. 3, 2010, DOI: 10.1504/ijbidm.2010.030296.

- [94] N. J. Yuan, Y. Zheng, L. Zhang und X. Xie, „T-Finder: A Recommender System for Finding Passengers and Vacant Taxis,“ *IEEE Transactions on Knowledge and Data Engineering*, Bd. 25, Rn. 10, S. 2390–2403, 2013, DOI: 10.1109/tkde.2012.153.
- [95] B. Li, D. Zhang, L. Sun, C. Chen, S. Li, G. Qi und Q. Yang, „Hunting or waiting? Discovering passenger-finding strategies from a large-scale real-world taxi dataset,“ in *2011 IEEE International Conference on Pervasive Computing and Communications Workshops (PERCOM Workshops)*, 2011, DOI: 10.1109/percomw.2011.5766967.
- [96] G. E. P. Box, G. M. Jenkins und G. C. Reinsel, *Time Series Analysis*, Wiley, 2008, DOI: 10.1002/9781118619193.
- [97] J. Brownlee, *Deep Learning for Time Series Forecasting*. Bd. 1.1, Machine Learning Mastery, 2018. Verfügbar: <https://machinelearningmastery.com/deep-learning-for-time-series-forecasting/>.
- [98] P. H. Rinne, *Taschenbuch Statistik*, 4., vollst, Frankfurt am Main, Harri, Verlag GmbH, 2008.
- [99] J. Vogel, *Prognose von Zeitreihen*, Springer Fachmedien Wiesbaden, 2015, DOI: 10.1007/978-3-658-06837-0.
- [100] S. J. Taylor und B. Letham, „Forecasting at scale,“ 2017, DOI: 10.7287/peerj.preprints.3190v2.
- [101] P. J. Brockwell und R. A. Davis, *Introduction to Time Series and Forecasting*, Springer International Publishing, 2016, DOI: 10.1007/978-3-319-29854-2.
- [102] W. Remus und M. O’Connor, „Neural Networks for Time-Series Forecasting,“ in *International Series in Operations Research & Management Science* Springer US, 2001, S. 245–256, DOI: 10.1007/978-0-306-47630-3_12.
- [103] J. C. B. Gamboa, „Deep Learning for Time-Series Analysis,“ *CoRR*, Bd. abs/1701.01887, 2017.
- [104] G. P. Zhang, „Neural Networks for Time-Series Forecasting,“ in *Handbook of Natural Computing* Springer Berlin Heidelberg, 2012, S. 461–477, DOI: 10.1007/978-3-540-92910-9_14.
- [105] J. F. Torres, D. Hadjout, A. Sebaa, F. Martínez-Álvarez und A. Troncoso, „Deep Learning for Time Series Forecasting: A Survey,“ *Big Data*, Bd. 9, Rn. 1, S. 3–21, 2021, DOI: 10.1089/big.2020.0159.
- [106] K. Fukushima, „Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,“ *Biological Cybernetics*, Bd. 36, Rn. 4, S. 193–202, 1980, DOI: 10.1007/bf00344251.
- [107] S. Hochreiter und J. Schmidhuber, „Long Short-Term Memory,“ *Neural Computation*, Bd. 9, Rn. 8, S. 1735–1780, 1997, DOI: 10.1162/neco.1997.9.8.1735.
- [108] P. Malhotra, L. Vig, G. Shroff und P. Agarwal, „Long Short Term Memory Networks for Anomaly Detection in Time Series,“ in *23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2015*, 2015.
- [109] Uber. „H3 - Hexagonal hierarchical geospatial indexing system,“ 2021. Verfügbar: <https://h3geo.org> [aufgerufen am 15. 07. 2021].
- [110] S2 Geometry contributors. „S2 Geometry,“ 2021. Verfügbar: <https://s2geometry.io> [aufgerufen am 15. 07. 2021].
- [111] G. Niemeyer. „Geohash,“ 2008. Verfügbar: <http://geohash.org> [aufgerufen am 15. 07. 2021].
- [112] S. Kim, S. Hong, M. Joh und S.-K. Song. „DeepRain: ConvLSTM Network for Precipitation Prediction using Multichannel Radar Data,“ 2017. arXiv: 1711.02316.
- [113] L. Moreira-Matias, J. Gama, M. Ferreira, J. Mendes-Moreira und L. Damas, „On Predicting the Taxi-Passenger Demand: A Real-Time Approach,“ in *Progress in Artificial Intelligence* Springer Berlin Heidelberg, 2013, S. 54–65, DOI: 10.1007/978-3-642-40669-0_6. Verfügbar: https://doi.org/10.1007/978-3-642-40669-0_6.

- [114] N. Davis, G. Raina und K. Jagannathan, „A multi-level clustering approach for forecasting taxi travel demand,“ in *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, 2016, DOI: 10.1109/itsc.2016.7795558. Verfügbar: <https://doi.org/10.1109/itsc.2016.7795558>.
- [115] K. Zhao, D. Khryashchev, J. Freire, C. Silva und H. Vo, „Predicting taxi demand at high spatial resolution: Approaching the limit of predictability,“ in *2016 IEEE International Conference on Big Data (Big Data)*, 2016, DOI: 10.1109/bigdata.2016.7840676. Verfügbar: <https://doi.org/10.1109/bigdata.2016.7840676>.
- [116] I. Markou, F. Rodrigues und F. C. Pereira, „Real-Time Taxi Demand Prediction using data from the web,“ in *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, 2018, DOI: 10.1109/itsc.2018.8569015. Verfügbar: <https://doi.org/10.1109/itsc.2018.8569015>.
- [117] J. Xu, R. Rahmatizadeh, L. Boloni und D. Turgut, „Real-Time Prediction of Taxi Demand Using Recurrent Neural Networks,“ *IEEE Transactions on Intelligent Transportation Systems*, Bd. PP, S. 1–10, 2017, DOI: 10.1109/TITS.2017.2755684.
- [118] H. Yao, F. Wu, J. Ke, X. Tang, Y. Jia, S. Lu, P. Gong, J. Ye und Z. Li, „Deep Multi-View Spatial-Temporal Network for Taxi Demand Prediction,“ *CoRR*, Bd. abs/1802.08714, 2018. arXiv: 1802.08714. Verfügbar: <http://arxiv.org/abs/1802.08714>.
- [119] K. F. Chu, A. Y. Lam und V. O. Li, „Travel Demand Prediction using Deep Multi-Scale Convolutional LSTM Network,“ in *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, 2018, DOI: 10.1109/itsc.2018.8569427. Verfügbar: <https://doi.org/10.1109/itsc.2018.8569427>.
- [120] J. Ke, H. Zheng, H. Yang und X. (Chen, „Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach,“ *Transportation Research Part C: Emerging Technologies*, Bd. 85, S. 591–608, 2017, DOI: 10.1016/j.trc.2017.10.016. Verfügbar: <https://doi.org/10.1016/j.trc.2017.10.016>.
- [121] D. Wang, Y. Yang und S. Ning, „DeepSTCL: A Deep Spatio-temporal ConvLSTM for Travel Demand Prediction,“ in *2018 International Joint Conference on Neural Networks (IJCNN)*, 2018, DOI: 10.1109/ijcnn.2018.8489530. Verfügbar: <https://doi.org/10.1109/ijcnn.2018.8489530>.
- [122] N. Davis, G. Raina und K. P. Jagannathan, „Grids versus Graphs: Partitioning Space for Improved Taxi Demand-Supply Forecasts,“ *CoRR*, Bd. abs/1902.06515, 2019. arXiv: 1902.06515.
- [123] X. Zhou, Y. Shen, Y. Zhu und L. Huang, „Predicting Multi-step Citywide Passenger Demands Using Attention-based Neural Networks,“ in *Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining*, 2018, DOI: 10.1145/3159652.3159682. Verfügbar: <https://doi.org/10.1145/3159652.3159682>.
- [124] S. Liao, L. Zhou, X. Di, B. Yuan und J. Xiong, „Large-scale short-term urban taxi demand forecasting using deep learning,“ in *2018 23rd Asia and South Pacific Design Automation Conference (ASP-DAC)*, 2018, DOI: 10.1109/aspdac.2018.8297361. Verfügbar: <https://doi.org/10.1109/aspdac.2018.8297361>.
- [125] U. Vanichrujee, T. Horanont, W. Pattara-atikom, T. Theeramunkong und T. Shinozaki, „Taxi Demand Prediction using Ensemble Model Based on RNNs and XGBOOST,“ in *2018 International Conference on Embedded Systems and Intelligent Technology & International Conference on Information and Communication Technology for Embedded Systems (ICESIT-ICICTES)*, 2018, DOI: 10.1109/icesit-icictes.2018.8442063. Verfügbar: <https://doi.org/10.1109/icesit-icictes.2018.8442063>.
- [126] Y. Tong, Y. Chen, Z. Zhou, L. Chen, J. Wang, Q. Yang, J. Ye und W. Lv, „The Simpler The Better,“ in *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2017, DOI: 10.1145/3097983.3098018. Verfügbar: <https://doi.org/10.1145/3097983.3098018>.

- [127] C. Mao, Y. Liu und Z.-J. (Shen, „Dispatch of autonomous vehicles for taxi services: A deep reinforcement learning approach,“ *Transportation Research Part C: Emerging Technologies*, Bd. 115, S. 102626, 2020, DOI: 10.1016/j.trc.2020.102626. Verfügbar: <https://doi.org/10.1016/j.trc.2020.102626>.
- [128] X. Kong, F. Xia, J. Wang, A. Rahim und S. K. Das, „Time-Location-Relationship Combined Service Recommendation Based on Taxi Trajectory Data,“ *IEEE Transactions on Industrial Informatics*, Bd. 13, Rn. 3, S. 1202–1212, 2017, DOI: 10.1109/tii.2017.2684163. Verfügbar: <https://doi.org/10.1109/tii.2017.2684163>.
- [129] M. Pavone, S. L. Smith, E. Frazzoli und D. Rus, „Robotic load balancing for mobility-on-demand systems,“ *Int. J. Rob. Res.*, Bd. 31, Rn. 7, S. 839–854, 2012, DOI: 10.1177/0278364912444766.
- [130] S. L. Smith, M. Pavone, M. Schwager, E. Frazzoli und D. Rus, „Rebalancing the rebalancers: optimally routing vehicles and drivers in mobility-on-demand systems,“ in *2013 American Control Conference*, 2013, DOI: 10.1109/acc.2013.6580187. Verfügbar: <https://doi.org/10.1109/acc.2013.6580187>.
- [131] F. Miao, S. Han, S. Lin, J. A. Stankovic, D. Zhang, S. Munir, H. Huang, T. He und G. J. Pappas, „Taxi Dispatch With Real-Time Sensing Data in Metropolitan Areas: A Receding Horizon Control Approach,“ *IEEE Transactions on Automation Science and Engineering*, Bd. 13, Rn. 2, S. 463–478, 2016, DOI: 10.1109/tase.2016.2529580. Verfügbar: <https://doi.org/10.1109/tase.2016.2529580>.
- [132] K. Spieser, S. Samaranayake und E. Frazzoli, „Vehicle routing for shared-mobility systems with time-varying demand,“ in *2016 American Control Conference (ACC)*, 2016, S. 796–802, DOI: 10.1109/ACC.2016.7525011.
- [133] R. Zhang, F. Rossi und M. Pavone, „Model predictive control of autonomous mobility-on-demand systems,“ in *2016 IEEE International Conference on Robotics and Automation (ICRA)*, 2016, DOI: 10.1109/icra.2016.7487272. Verfügbar: <https://doi.org/10.1109/icra.2016.7487272>.
- [134] A. Wallar, M. V. D. Zee, J. Alonso-Mora und D. Rus, „Vehicle Rebalancing for Mobility-on-Demand Systems with Ride-Sharing,“ in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2018, DOI: 10.1109/iros.2018.8593743. Verfügbar: <https://doi.org/10.1109/iros.2018.8593743>.
- [135] S. P. Chuah, S. Xiang und H. Wu, „Optimal rebalancing with waiting time constraints for a fleet of connected autonomous taxi,“ in *2018 IEEE 4th World Forum on Internet of Things (WF-IoT)*, 2018, DOI: 10.1109/wf-iot.2018.8355161. Verfügbar: <https://doi.org/10.1109/wf-iot.2018.8355161>.
- [136] J. Xu, R. Rahmatizadeh, L. Boloni und D. Turgut, „Taxi Dispatch Planning via Demand and Destination Modeling,“ in *2018 IEEE 43rd Conference on Local Computer Networks (LCN)*, 2018, DOI: 10.1109/lcn.2018.8638038. Verfügbar: <https://doi.org/10.1109/lcn.2018.8638038>.
- [137] M. Albert, C. Ruch und E. Frazzoli, „Imbalance in Mobility-on-Demand Systems,“ *ACM Transactions on Spatial Algorithms and Systems*, Bd. 5, Rn. 2, S. 1–22, 2019, DOI: 10.1145/3325914. Verfügbar: <https://doi.org/10.1145/3325914>.
- [138] C. Ruch, J. Gächter, J. Hakenberg und E. Frazzoli, „The +1 Method Model-Free Adaptive Repositioning Policies for Robotic Multi-Agent Systems,“ 2019, DOI: 10.3929/ETHZ-B-000322945. Verfügbar: <http://hdl.handle.net/20.500.11850/322945>.
- [139] M. Tsao, D. Milojevic, C. Ruch, M. Salazar, E. Frazzoli und M. Pavone, „Model Predictive Control of Ride-sharing Autonomous Mobility-on-Demand Systems,“ in *2019 International Conference on Robotics and Automation (ICRA)*, 2019, DOI: 10.1109/icra.2019.8794194. Verfügbar: <https://doi.org/10.1109/icra.2019.8794194>.

- [140] Y. Deng, H. Chen, S. Shao, J. Tang, J. Pi und A. Gupta. „*Multi-Objective Vehicle Rebalancing for Ride-hailing System using a Reinforcement Learning Approach*,“ 2020. arXiv: 2007.06801 [eess.SY].
- [141] F. Borrelli, *Constrained Optimal Control of Linear and Hybrid Systems*, Springer Berlin Heidelberg, 2003, DOI: 10.1007/3-540-36225-8. Verfügbar: <https://doi.org/10.1007/3-540-36225-8>.
- [142] B. Jäger, M. Wittmann und M. Lienkamp, „Analyzing and Modeling a City’s Spatiotemporal Taxi Supply and Demand: A Case Study for Munich,“ *J. Traffic Logist. Eng.*, Bd. 4, Rn. 2, S. 147–153, 2016, DOI: 10.18178/jtle.4.2.147-153.
- [143] K. Spieser, K. Treleaven, R. Zhang, E. Frazzoli, D. Morton und M. Pavone, „Toward a Systematic Approach to the Design and Evaluation of Automated Mobility-on-Demand Systems: A Case Study in Singapore,“ in *Road Vehicle Automation* Springer International Publishing, 2014, S. 229–245, DOI: 10.1007/978-3-319-05990-7_20. Verfügbar: https://doi.org/10.1007/978-3-319-05990-7_20.
- [144] C. Zhu und B. Prabhakar, „Reducing inefficiencies in taxi systems,“ in *2017 IEEE 56th Annual Conference on Decision and Control (CDC)*, 2017, DOI: 10.1109/cdc.2017.8264609.
- [145] J. Bischoff und M. Maciejewski, „Simulation of City-wide Replacement of Private Cars with Autonomous Taxis in Berlin,“ *Procedia Computer Science*, Bd. 83, S. 237–244, 2016, DOI: 10.1016/j.procs.2016.04.121. Verfügbar: <https://doi.org/10.1016/j.procs.2016.04.121>.
- [146] B. Jager, F. M. M. Agua und M. Lienkamp, „Agent-based simulation of a shared, autonomous and electric on-demand mobility solution,“ in *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 2017, DOI: 10.1109/itsc.2017.8317947. Verfügbar: <https://doi.org/10.1109/itsc.2017.8317947>.
- [147] New York (N.Y.). Taxi And Limousine Commission. „*New York City Taxi Trip Data, 2009-2018*,“ en. 2019. DOI: 10.3886/ICPSR37254.V1. Verfügbar: <https://www.icpsr.umich.edu/icpsrweb/ICPSR/studies/37254/versions/V1>.
- [148] M. Piorkowski, N. Sarafijanovic-Djukic und M. Grossglauser. „*CRAWDAD dataset epfl/mobility (v. 2009-02-24)*,“ Downloaded from <https://crawdad.org/epfl/mobility/20090224>. Feb. 2009. DOI: 10.15783/C7J010.
- [149] F. Rodrigues, S. S. Borysov, B. Ribeiro und F. C. Pereira, „A Bayesian Additive Model for Understanding Public Transport Usage in Special Events,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Bd. 39, Rn. 11, S. 2113–2126, 2017, DOI: 10.1109/tpami.2016.2635136.
- [150] I. Markou, K. Kaiser und F. C. Pereira, „Predicting taxi demand hotspots using automated Internet Search Queries,“ *Transportation Research Part C: Emerging Technologies*, Bd. 102, S. 73–86, 2019, DOI: 10.1016/j.trc.2019.03.001.
- [151] F. C. Pereira, F. Rodrigues, E. Polisciuc und M. Ben-Akiva, „Why so many people? Explaining Nonhabitual Transport Overcrowding With Internet Data,“ *IEEE Transactions on Intelligent Transportation Systems*, Bd. 16, Rn. 3, S. 1370–1379, 2015, DOI: 10.1109/tits.2014.2368119.
- [152] M. Ester und J. Sander, *Knowledge Discovery in Databases*, Springer Berlin Heidelberg, 2000, DOI: 10.1007/978-3-642-58331-5.
- [153] Linne und Krause, „Gutachten gemäß § 13 Abs. 4 PBefG über die Funktionsfähigkeit des Taxigewerbes in der Landeshauptstadt München,“ Hamburg, 2015.
- [154] P. G. D. Group. „*PostgreSQL: The World’s Most Advanced Open Source Relational Database*,“ Verfügbar: <https://www.postgresql.org> [aufgerufen am 15. 08. 2021].
- [155] P. Project. „*PostGIS - Spatial and Geographic objects for PostgreSQL*,“ Verfügbar: <http://postgis.net> [aufgerufen am 15. 08. 2021].

- [156] Landeshauptstadt München. „*Verordnung der Landeshauptstadt München über Beförderungsentgelte und Beförderungsbedingungen für den Verkehr mit Taxen (Taxitarifordnung)*,“ 2019.
- [157] L. Martin, M. Wittmann und X. Li, „The Influence of Public Transport Delays on Mobility on Demand Services,“ *Electronics*, Bd. 10, Rn. 4, S. 379, 2021, DOI: 10.3390/electronics10040379.
- [158] M. Wittmann, M. Kollek und M. Lienkamp, „Event-driven anomalies in spatiotemporal taxi passenger demand,“ in *2018 21st Int. Conf. Intell. Transp. Syst.* 2018, S. 979–984, DOI: 10.1109/ITSC.2018.8569500.
- [159] muenchen.de. „*Veranstaltungen in München*,“ Verfügbar: <https://www.muenchen.de/veranstaltungen.html> [aufgerufen am 16.08.2021].
- [160] L. Adenaw, J. Kreibich, M. Wittmann, L. Merkle, A. Waclaw und M. Lienkamp, „MAGIS – A Geographic Information System for Mobility Data Analysis,“ in *2019 IEEE Intell. Transp. Syst. Conf.* 2019, S. 135–141, DOI: 10.1109/ITSC.2019.8917054.
- [161] OpenStreetMap contributors. „*Oberbayern dump retrieved from https://www.geofabrik.org*,“ 2020. Verfügbar: <https://www.openstreetmap.org>.
- [162] M. I. M. (LMU). „*Wetterbeobachtungen: Messstation Theresienstr. 37 München*,“ 2019. Verfügbar: <https://www.meteo.physik.uni-muenchen.de/wetter/index.html>.
- [163] M. Maciejewski, J. M. Salanova, J. Bischoff und M. Estrada, „Large-scale microscopic simulation of taxi services. Berlin and Barcelona case studies,“ *Journal of Ambient Intelligence and Humanized Computing*, Bd. 7, Rn. 3, S. 385–393, 2016, DOI: 10.1007/s12652-016-0366-3.
- [164] J. Müller, *Statistical Explanatory and Prediction Models for Free-Floating Carsharing Systems*, Neubiberg, Universitätsbibliothek der Universität der Bundeswehr München, 2016, 2016.
- [165] J. Laviolette, C. Morency, N. Saunier und A. Lacombe, „Temporal and Spatial Analysis of Taxi Demand in Montréal, Canada, Using Clustering Approach,“ *Transportation Research Board 96th Annual Meeting*, 2017, ISBN: 5143404711.
- [166] J. Bischoff, M. Maciejewski und A. Sohr, „Analysis of Berlin’s taxi services by exploring GPS traces,“ in *2015 International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*, 2015, DOI: 10.1109/mtits.2015.7223258.
- [167] X. Hu, S. An und J. Wang, „Taxi Driver’s Operation Behavior and Passengers’ Demand Analysis Based on GPS Data,“ *Journal of Advanced Transportation*, Bd. 2018, S. 1–11, 2018, DOI: 10.1155/2018/6197549.
- [168] J. MacQueen et al., „Some methods for classification and analysis of multivariate observations,“ in *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, 1967, S. 281–297.
- [169] S. P. Lloyd, „Least squares quantization in PCM,“ *IEEE Trans. Inf. Theory*, Bd. 28, S. 129–136, 1982.
- [170] R. Tavenard, J. Faouzi, G. Vandewiele, F. Divo, G. Androz, C. Holtz, M. Payne, R. Yurchak, M. Rußwurm, K. Kolar und E. Woods, „Tslern, A Machine Learning Toolkit for Time Series Data,“ *Journal of Machine Learning Research*, Bd. 21, Rn. 118, S. 1–6, 2020. Verfügbar: <http://jmlr.org/papers/v21/20-091.html>.
- [171] muenchen.de. „*Anzahl der Besucher auf dem Oktoberfest in München von 1980 bis 2019 (in Millionen) [Graph]*,“ publisher: Statista. 2019. Verfügbar: <https://de.statista.com/statistik/daten/studie/165511/umfrage/anzahl-der-besucher-auf-dem-oktoberfest-seit-1980/> [aufgerufen am 15.07.2021].
- [172] BAU-München. „*Bau - Daten & Fakten*,“ Verfügbar: <https://bau-muenchen.com/de/aussteller/informieren/daten-fakten/>.

- [173] bauma. „*bauma 2019 in Zahlen - Presseinformation Nr. 19*,“ 2019. Verfügbar: https://files.bauma.de/corporate/media/de/global_media/global_media_press/press_fair_websites/press_bma/bma_pr_2019/bma_pr_2019_04/bma_pr_2019_04_bauma_in_Zahlen.pdf [aufgerufen am 15. 07. 2021].
- [174] Tollwood. „*Abschluss des Tollwood Winterfestivals 2019 und Ausblick auf das Sommerfestival 2020*,“ 2020. Verfügbar: https://www.tollwood.de/wp-content/uploads/2020/01/pm_tollwoodwinterfestival19_-abschluss.pdf?download [aufgerufen am 15. 07. 2021].
- [175] G. Beiner. „*Expertengespräch mit Gregor Beiner (Geschäftsführer Münchner Taxizentrum) am 10. Mai 2021*,“ 2021.
- [176] S. Lepage und C. Morency, „Impact of Weather, Activities, and Service Disruptions on Transportation Demand,“ *Transportation Research Record*, Bd. 2675, S. 294–304, 2020.
- [177] C. Kamga, M. Yazici und A. Singhal. „*Hailing in the Rain: Temporal and Weather-Related Variations in Taxi Ridership and Taxi Demand-Supply Equilibrium*,“ 2013.
- [178] W. K. Lee und S. Sohn, „A large-scale data-based investigation on the relationship between bad weather and taxi tipping,“ *Journal of Environmental Psychology*, Bd. 70, S. 101458, 2020.
- [179] J. Sun, H. Dong, G. Qin und Y. Tian, „Quantifying the Impact of Rainfall on Taxi Hailing and Operation,“ *Journal of Advanced Transportation*, Bd. 2020, S. 1–14, 2020, DOI: 10.1155/2020/7081628. Verfügbar: <https://doi.org/10.1155/2020/7081628>.
- [180] D. Wetterdienst. „*Wetter- und Klimalexikon: Niederschlagsintensität*,“ 2021. Verfügbar: <https://www.dwd.de/DE/service/lexikon/Functions/glossar.html;jsessionid=7821DDDE73A3E2B24FF24DD0C09707B1.live11043?nn=103346&lv2=101812&lv3=101906> [aufgerufen am 05. 08. 2021].
- [181] I. Markou, F. Rodrigues und F. C. Pereira, „Use of Taxi-Trip Data in Analysis of Demand Patterns for Detection and Explanation of Anomalies,“ *Transportation Research Record: Journal of the Transportation Research Board*, Bd. 2643, Rn. 1, S. 129–138, 2017, DOI: 10.3141/2643-15.
- [182] A. Kuppam, R. Copperman, T. Rossi, V. Livshits, L. Vallabhaneni, T. Brown und K. DeBoer, „Innovative Methods for Collecting Data and for Modeling Travel Related to Special Events,“ *Transportation Research Record: Journal of the Transportation Research Board*, Bd. 2246, Rn. 1, S. 24–31, 2011, DOI: 10.3141/2246-04.
- [183] E. J. Candes, X. Li, Y. Ma und J. Wright. „*Robust Principal Component Analysis?*,“ 2009. arXiv: 0912.3599.
- [184] J. Tyndall, „Free-floating carsharing and extemporaneous public transit substitution,“ *Research in Transportation Economics*, Bd. 74, S. 21–27, 2019.
- [185] S. Vande Walle und T. Steenberghen, „Space and time related determinants of public transport use in trip chains,“ *Transportation Research Part A: Policy and Practice*, Bd. 40, Rn. 2, S. 151–162, 2006.
- [186] M. Bruhn, *Wirtschaftlichkeit des Qualitätsmanagements*, Springer Berlin Heidelberg, 1998, DOI: 10.1007/978-3-642-58752-8.
- [187] A. Tirachini, „Ride-hailing, travel behaviour and sustainable mobility: an international review,“ *Transportation*, Bd. 47, Rn. 4, S. 2011–2047, 2019, DOI: 10.1007/s11116-019-10070-2.
- [188] Deutscher Taxi- und Mietwagenverband e. V. „*BZP Geschäftsbericht 2018/2019*,“ 2019. Verfügbar: <https://bundesverband.taxi/wp-content/uploads/2021/01/AUSZUG-GB-KOMPLETT-kl.pdf>.
- [189] G. Beiner. „*Telefoninterview mit Gregor Beiner (Geschäftsführer Münchner Taxi Zentrum) am 21. 11. 2019*,“ 2019.
- [190] Wikipedia contributors. „*Lohnnebenkosten*,“ 2021. Verfügbar: <https://de.wikipedia.org/wiki/Lohnnebenkosten> [aufgerufen am 30. 07. 2021].

- [191] G. Beiner. „*Expertengespräch mit Gregor Beiner (Geschäftsführer Münchner Taxi Zentrum) am 30. Juli 2021,*“ 2019.
- [192] Deutscher Taxi- und Mietwagenverband e. V. „*BZP Geschäftsbericht 2017/2018,*“ 2018.
- [193] J. Kodzo, „Wie verlief der erste Lockdown?“, *Wirtschaftswoche*, 2021. Verfügbar: <https://www.wiwo.de/politik/deutschland/coronakrise-wie-verlief-der-erste-lockdown/26853384.html> [aufgerufen am 05.08.2021].
- [194] Landesverband Bayerischer Taxi- und Mietwagenunternehmen e.V. „*Corona Taxi-FAQ,*“ 2021. Verfügbar: <https://taxi-bayern.de/corona-taxi-faq> [aufgerufen am 05.08.2021].
- [195] S. Günnewig, „Corona: Taxi-Trennschutz Lösungen“, *TAXItimes*, 2020. Verfügbar: <https://www.taxi-times.com/corona-taxi-trennschutz-loesungen/> [aufgerufen am 05.08.2021].
- [196] Wikipedia contributors. „*COVID-19-Pandemie in Bayern,*“ 2021. Verfügbar: https://de.wikipedia.org/wiki/COVID-19-Pandemie_in_Bayern [aufgerufen am 05.08.2021].
- [197] A. Tirachini und M. del Río, „Ride-hailing in Santiago de Chile: Users’ characterisation and effects on travel behaviour“, *Transport Policy*, Bd. 82, S. 46–57, 2019, DOI: 10.1016/j.tranpol.2019.07.008.
- [198] B.-J. Tang, X.-Y. Li, B. Yu und Y.-M. Wei, „How app-based ride-hailing services influence travel behavior: An empirical study from China“, *International Journal of Sustainable Transportation*, Bd. 14, Rn. 7, S. 554–568, 2019, DOI: 10.1080/15568318.2019.1584932.
- [199] G. Circella, F. Alemi, K. Tiedeman, S. Handy und P. Mokhtarian, „The adoption of shared mobility in California and its relationship with other components of travel behavior“, UC Davis: National Center for Sustainable Transportation, 2018. Verfügbar: <https://escholarship.org/uc/item/1kq5d07p>.
- [200] A. Tirachini und A. Gomez-Lobo, „Does ride-hailing increase or decrease vehicle kilometers traveled (VKT)? A simulation approach for Santiago de Chile“, *International Journal of Sustainable Transportation*, Bd. 14, Rn. 3, S. 187–204, 2019, DOI: 10.1080/15568318.2018.1539146.
- [201] B. Beeger, „Taxi oder Uber: Wer ist günstiger?“, *Frankfurter Allgemeine Zeitung*, 2014. Verfügbar: <https://www.faz.net/aktuell/finanzen/meine-finanzen/geld-ausgeben/taxi-oder-uber-wer-ist-guenstiger-12988536.html> [aufgerufen am 12.08.2020].
- [202] K. Mayer. „*Vermittlung verständlich erklärt,*“ 2018. Verfügbar: <https://isarfunk.de/vermittlung-verstaendlich-erklart/> [aufgerufen am 08.04.2020].
- [203] M. Maciejewski, J. Bischoff, S. Hörl und K. Nagel, „Towards a Testbed for Dynamic Vehicle Routing Algorithms“, in *Communications in Computer and Information Science* Springer International Publishing, 2017, S. 69–79, DOI: 10.1007/978-3-319-60285-1_6. Verfügbar: https://doi.org/10.1007/978-3-319-60285-1_6.
- [204] M. Wittmann, L. Neuner und M. Lienkamp, „A Predictive Fleet Management Strategy for On-Demand Mobility Services: A Case Study in Munich“, *Electronics*, Bd. 9, Rn. 6, S. 1021, 2020, DOI: 10.3390/electronics9061021.
- [205] M. Speicher, „Simulation prädiktiver Flottenstrategien im Taxigewerbe“, Semesterarbeit, Technische Universität München, 2020.
- [206] J. Koch, „Taxi Demand Prediction with ConvLSTM- Networks“, Masterarbeit, Technische Universität München, 2019.
- [207] L. Neuner, „A Predictive Fleet Management Strategy for On-Demand-Mobility“, Masterarbeit, Technische Universität München, 2019.
- [208] M. Speicher, „Methoden des Maschinellen Lernens zur Prädiktion des Fahrgastaufkommens bei on-Demand Mobilitätslösungen“, Bachelorarbeit, Technische Universität München, 2019.

- [209] Gurobi. „*Gurobi Optimizer*,“ 2021. Verfügbar: <https://www.gurobi.com/products/gurobi-optimizer/> [aufgerufen am 14. 04. 2021].
- [210] J. Brownlee, *Introduction to Time Series Forecasting with Python*. Bd. 1.5, Machine Learning Mastery, 2018. Verfügbar: <https://machinelearningmastery.com/introduction-to-time-series-forecasting-with-python/>.
- [211] A. Kneip. „*Zeitreihenanalyse*,“ 2010. Verfügbar: http://statistics.uni-bonn.de/fileadmin/Fachbereich_Wirtschaft/Einrichtungen/Statistik/ss10/Zeitreihen/Zeitreihen_Kapitel_1-3.pdf [aufgerufen am 22. 04. 2020].
- [212] C. Fraundorfer, „ConvLSTM-Networks : Forecast for Spatio-Temporal Mobility Demand,“ Masterarbeit, Technische Universität München, 2019.
- [213] M. Hussak, „Einfluss exogener Variablen auf die Prognosegüte neuronaler Netze bei der Vorhersage des Fahrgastaufkommens im Taxiverkehr,“ Masterarbeit, Technische Universität München, 2019.
- [214] J. Tenhumberg, „Machine-Learning Methoden zur Prädiktion des Fahrgastaufkommens bei on-demand Mobilitätsdienstleistungen,“ Semesterarbeit, Technische Universität München, 2017.
- [215] S. Seabold und J. Perktold, „statsmodels: Econometric and statistical modeling with python,“ in *9th Python in Science Conference*, 2010.
- [216] F. Chollet et al. „*Keras*,“ <https://keras.io>. 2015.
- [217] Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Y. Jia, Rafal Jozefowicz, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dan Mané, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Mike Schuster, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu und Xiaoqiang Zheng. „*TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*,“ Software available from tensorflow.org. 2015. Verfügbar: <http://tensorflow.org/>.
- [218] Tensorflow. „*Time series forecasting*,“ 2017. Verfügbar: https://www.tensorflow.org/tutorials/structured_data/time_series [aufgerufen am 23. 04. 2021].
- [219] K. Potdar, T. Pardawala und C. Pai, „A Comparative Study of Categorical Variable Encoding Techniques for Neural Network Classifiers,“ *International Journal of Computer Applications*, Bd. 175, S. 7–9, 2017, DOI: 10.5120/ijca2017915495.
- [220] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever und R. Salakhutdinov, „Dropout: A Simple Way to Prevent Neural Networks from Overfitting,“ *J. Mach. Learn. Res.*, Bd. 15, Rn. 1, S. 1929–1958, 2014.
- [221] K. Backhaus, B. Erichson und R. Weiber. „„Neuronale Netze“,“ in: *Fortgeschrittene Multivariate Analysemethoden: Eine anwendungsorientierte Einführung*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2015, S. 295–347. ISBN: 978-3-662-46087-0. DOI: 10.1007/978-3-662-46087-0_6.
- [222] L. Prechelt. „„Early Stopping — But When?“,“ in: *Neural Networks: Tricks of the Trade: Second Edition*. Hrsg. von G. Montavon, G. B. Orr und K.-R. Müller. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, S. 53–67. ISBN: 978-3-642-35289-8. DOI: 10.1007/978-3-642-35289-8_5.
- [223] D. P. Kingma und J. Ba. „*Adam: A Method for Stochastic Optimization*,“ 2017. arXiv: 1412.6980.
- [224] M. Wittmann. „*custom-osm-maps-mit-osmium*,“ 2019. Verfügbar: <https://smarte-mobilitaet-blog.ftm.mw.tum.de/index.php/2019/09/23/custom-osm-maps-mit-osmium/> [aufgerufen am 23. 09. 2019].
- [225] M. Wittmann und M. Speicher. „*Docker Simulation Pipeline*,“ 2021. Verfügbar: https://github.com/michaelwittmann/docker_simulation_pipeline_example.

- [226] B. Danquah, S. Riedmaier, Y. Meral und M. Lienkamp, „Statistical Validation Framework for Automotive Vehicle Simulations Using Uncertainty Learning,“ *Applied Sciences*, Bd. 11, Rn. 5, S. 1983, 2021, DOI: 10.3390/app11051983. Verfügbar: <https://doi.org/10.3390/app11051983>.
- [227] P. Duvall, S. M. Matyas und A. Glover, *Continuous Integration: Improving Software Quality and Reducing Risk (The Addison-Wesley Signature Series)*, Addison-Wesley Professional, 2007, ISBN: 0321336380.
- [228] M. Wittmann und M. Speicher. „AModDeus-Munich-Taxi,“ 2021. Verfügbar: <https://github.com/TUMFTM/amodeus-munich-taxi>.
- [229] M. Wittmann und M. Speicher. „Mobility on Demand Prediction Framework,“ 2021. Verfügbar: <https://github.com/TUMFTM/mod-prediction-framework>.
- [230] B. Jäger, M. Wittmann und M. Lienkamp, „Agent-based Modeling and Simulation of Electric Taxi Fleets,“ in *6. Conf. Futur. Automot. Technol.* 2017, S. 11–47.
- [231] M. Wittmann, J. J. Lohrer, J. Betz, B. Jager, M. Kugler, M. Kloppel, A. Waclaw, M. Hann, M. Lienkamp, B. Jäger, M. Kugler, M. Klöppel, A. Waclaw, M. Hann und M. Lienkamp, „A holistic framework for acquisition, processing and evaluation of vehicle fleet test data,“ in *2017 IEEE 20th Int. Conf. Intell. Transp. Syst.* 2017, S. 1–7, DOI: 10.1109/ITSC.2017.8317637.
- [232] M. Wittmann. „Conditional Stateful,“ 2021. Verfügbar: <https://github.com/michaelwittmann/conditionalstateful>.
- [233] Dudenredaktion (o. J.) „Mobilität,“ 2021. Verfügbar: <https://www.duden.de/rechtschreibung/Mobilitaet> [aufgerufen am 15.08.2021].
- [260] M. Kollek, „Identifikation von Einflussfaktoren auf das räumlich- zeitliche Fahrgastaufkommen im Taxigewerbe mit Hilfe von Data-Mining-Methoden,“ Masterarbeit, Technische Universität München, 2017.

Vorveröffentlichungsliste

Während der Anfertigung dieser Dissertation entstanden Veröffentlichungen und Studienarbeiten, in denen Teilaspekte dieser Arbeit vorgestellt wurden.

Zeitschriften; Scopus/Web of Science gelistet (peer-reviewed)

- [157] L. Martin, M. Wittmann und X. Li, „The Influence of Public Transport Delays on Mobility on Demand Services,“ *Electronics*, Bd. 10, Rn. 4, S. 379, 2021, DOI: 10.3390/electronics10040379.
- [204] M. Wittmann, L. Neuner und M. Lienkamp, „A Predictive Fleet Management Strategy for On-Demand Mobility Services: A Case Study in Munich,“ *Electronics*, Bd. 9, Rn. 6, S. 1021, 2020, DOI: 10.3390/electronics9061021.

Konferenzen, Magazine, etc.; Scopus/Web of Science gelistet (peer-reviewed)

- [158] M. Wittmann, M. Kollek und M. Lienkamp, „Event-driven anomalies in spatiotemporal taxi passenger demand,“ in *2018 21st Int. Conf. Intell. Transp. Syst.* 2018, S. 979–984, DOI: 10.1109/ITSC.2018.8569500.
- [160] L. Adenaw, J. Kreibich, M. Wittmann, L. Merkle, A. Waclaw und M. Lienkamp, „MAGIS – A Geographic Information System for Mobility Data Analysis,“ in *2019 IEEE Intell. Transp. Syst. Conf.* 2019, S. 135–141, DOI: 10.1109/ITSC.2019.8917054.
- [231] M. Wittmann, J. J. Lohrer, J. Betz, B. Jäger, M. Kugler, M. Kloppel, A. Waclaw, M. Hann, M. Lienkamp, B. Jäger, M. Kugler, M. Klöppel, A. Waclaw, M. Hann und M. Lienkamp, „A holistic framework for acquisition, processing and evaluation of vehicle fleet test data,“ in *2017 IEEE 20th Int. Conf. Intell. Transp. Syst.* 2017, S. 1–7, DOI: 10.1109/ITSC.2017.8317637.

Zeitschriften, Konferenzen, Magazine, Berichte, Konferenzvorträge und -poster, etc.; nicht Scopus/Web of Science gelistet

- [142] B. Jäger, M. Wittmann und M. Lienkamp, „Analyzing and Modeling a City’s Spatiotemporal Taxi Supply and Demand: A Case Study for Munich,“ *J. Traffic Logist. Eng.*, Bd. 4, Rn. 2, S. 147–153, 2016, DOI: 10.18178/jtle.4.2.147-153.
- [224] M. Wittmann. „*custom-osm-maps-mit-osmium*,“ 2019. Verfügbar: <https://smarte-mobilitaet-blog.ftm.mw.tum.de/index.php/2019/09/23/custom-osm-maps-mit-osmium/> [aufgerufen am 23. 09. 2019].
- [230] B. Jäger, M. Wittmann und M. Lienkamp, „Agent-based Modeling and Simulation of Electric Taxi Fleets,“ in *6. Conf. Futur. Automot. Technol.* 2017, S. 11–47.

Nicht-dissertationsrelevante Veröffentlichungen; Scopus/Web of Science gelistet (peer-reviewed)

M. Fries, A. Baum, M. Wittmann und M. Lienkamp, „Derivation of a real-life driving cycle from fleet testing data with the Markov-Chain-Monte-Carlo Method,“ in *2018 21st Int. Conf. Intell. Transp. Syst.* 2018, S. 2550–2555, DOI: 10.1109/ITSC.2018.8569547.

M. Klöppel, F. Römer, M. Wittmann, B. Hatam, T. Herrmann, L. Sim, J. Lim, Y. Lu, V. Medovy, L. Merkle, W. Ten, A. Ongel, Y. Hong, H. Ng und M. Lienkamp, „Scube—Concept and Implementation of a Self-balancing, Autonomous Mobility Device for Personal Transport,“ *World Electr. Veh. J.*, Bd. 9, Rn. 4, S. 48, 2018, DOI: 10.3390/wevj9040048.

S. Wolff, J. Auernhammer, F. Schockenhoff, C. Angerer und M. Wittmann, „Mobility box: A design research methodology to examine peoples’s needs in relation to autonomous vehicle desings and mobility business model,“ in *Proc. Des. Soc. Des. Conf.* 2020, S. 1185–1194, DOI: 10.1017/dsd.2020.285.

Dissertationsrelevante Open-Source Software

[225] M. Wittmann und M. Speicher. „*Docker Simulation Pipeline*,“ 2021. Verfügbar: https://github.com/michaelwittmann/docker_simulation_pipeline_example.

[228] M. Wittmann und M. Speicher. „*AModDeus-Munich-Taxi*,“ 2021. Verfügbar: <https://github.com/TUMFTM/amodeus-munich-taxi>.

[229] M. Wittmann und M. Speicher. „*Mobility on Demand Prediction Framework*,“ 2021. Verfügbar: <https://github.com/TUMFTM/mod-prediction-framework>.

[232] M. Wittmann. „*Conditional Stateful*,“ 2021. Verfügbar: <https://github.com/michaelwittmann/conditionalstateful>.

Betreute Studienarbeiten

Folgende studentische Arbeiten entstanden im Rahmen der Dissertation unter der inhaltlichen, fachlichen und wissenschaftlichen Betreuung sowie unter maßgeblicher Anleitung des Autors. Im Folgenden sind die für diese Dissertation relevanten und in Bezug stehenden Bachelor-, Semester- und Masterarbeiten aufgeführt. Vielen Dank geht hier an die Bearbeiter für die umfangreiche Unterstützung im Rahmen dieses Forschungsprojekt.

- [205] M. Speicher, „Simulation prädiktiver Flottenstrategien im Taxigewerbe,“ Semesterarbeit, Technische Universität München, 2020.
- [206] J. Koch, „Taxi Demand Prediction with ConvLSTM- Networks,“ Masterarbeit, Technische Universität München, 2019.
- [207] L. Neuner, „A Predictive Fleet Management Strategy for On-Demand-Mobility,“ Masterarbeit, Technische Universität München, 2019.
- [208] M. Speicher, „Methoden des Maschinellen Lernens zur Prädiktion des Fahrgastaufkommens bei on-Demand Mobilitätslösungen,“ Bachelorarbeit, Technische Universität München, 2019.
- [212] C. Fraundorfer, „ConvLSTM-Networks : Forecast for Spatio-Temporal Mobility Demand,“ Masterarbeit, Technische Universität München, 2019.
- [213] M. Hussak, „Einfluss exogener Variablen auf die Prognosegüte neuronaler Netze bei der Vorhersage des Fahrgastaufkommens im Taxiverkehr,“ Masterarbeit, Technische Universität München, 2019.
- [214] J. Tenhumberg, „Machine-Learning Methoden zur Prädiktion des Fahrgastaufkommens bei on-demand Mobilitätsdienstleistungen,“ Semesterarbeit, Technische Universität München, 2017.
- J. Bader, „Entwicklung einer optimalen Flottenstrategie für innovative Mobilitätsdienstleistungen,“ Semesterarbeit, Technische Universität München, 2018.
- P. Bosch-Fauli, „Identifikation und Fusion von Verhaltensmustern in Flottenbewegungsdaten,“ Bachelorarbeit, Technische Universität München, 2016.
- K. Cherkaoui, „Comparison between Carsharing and Taxi Operations and Descriptive Analytics of Cannibalization Effects,“ Bachelorarbeit, Technische Universität München, 2019.
- E. Gießler, „Aufbau eines Frameworks für die Prädiktion des Mobilitätsbedarfs in on-Demand Mobilitätssystemen,“ Masterarbeit, Technische Universität München, 2019.
- M. Gößl, „Prädiktion des Fahrgastaufkommens bei on-Demand Mobilitätsdienstleistungen mit einem Machine Learning Ansatz,“ Masterarbeit, Technische Universität München, 2017.
- [260] M. Kollek, „Identifikation von Einflussfaktoren auf das räumlich- zeitliche Fahrgastaufkommen im Taxigewerbe mit Hilfe von Data-Mining-Methoden,“ Masterarbeit, Technische Universität München, 2017.
- P. Kopeinig, „Sustainability assessment of the integration of electric mobility in Cape Town ' s passenger transport,“ Semesterarbeit, Technische Universität München, 2018.

- T. Küttner, „Machine-Learning-Methoden zur Prädiktion des Fahrgastaufkommens bei on-demand Mobilitätsdienstleistungen,“ Masterarbeit, Technische Universität München, 2017.
- L. Merkle, „Positionsbestimmung eines autonomen Mikromobils durch Computer-Vision,“ Diss., Technische Universität München, 2017.
- L. Neuner, „Analysis of the Potential of a Predictive Fleet Strategy in the Taxi Industry,“ Bachelorarbeit, Technische Universität München, 2019.
- T. Oblinger, „Identifikation von Kennwerten zur Klassifizierung von Fahrprofilen,“ Semesterarbeit, Technische Universität München, 2016.
- H. Ostermeier, „Internet-Datenquellen zur Prädiktion von Fahrgastzahlen von on-demand-Dienstleistungen,“ Semesterarbeit, Technische Universität München, 2018.
- A. Raab, „Entwicklung eines multifunktionalen OBD-II Datenloggers,“ Bachelorarbeit, Technische Universität München, 2017.
- B. Scheu, „Analyzing the Influence of Public Transit Outages on Taxi and Carsharing Demand,“ Bachelorarbeit, Technische Universität München, 2019.
- F. Schmid, „Entwicklung eines OBD-II Datenloggers,“ Semesterarbeit, Technische Universität München, 2017.
- F. Schmid, „Entwicklung und Erprobung eines multi-funktionalen OBD-II Datenloggers,“ Masterarbeit, Technische Universität München, 2018.
- J. Schmid, „Auswirkungen von Veranstaltungen auf das Mobilitätsverhalten,“ Bachelorarbeit, Technische Universität München, 2016.
- C. Seitz, „Klassifizierung von Mobilitätsdaten in Bezug auf potentielle Anwendungsfälle in der Fahrzeugtechnik,“ Semesterarbeit, Technische Universität München, 2016.
- J. Vitzthum, „Empirische Analyse des Nachfrageverhaltens im Taxiverkehr in internationalen Metropolen,“ Masterarbeit, Technische Universität München, 2018.
- B. Wolff, „Entwicklung und Erprobung eines mobilen Messsystems zur Bestimmung der Immissionsbelastung in Städten,“ Masterarbeit, Technische Universität München, 2017.
- N. Yogeshwar, „Entwicklung und Simulation einer prädiktiven Vermittlungsstrategie für Taxiflotten,“ Masterarbeit, Technische Universität München, 2019.