



ModelRad

Die Modellierung des Radverkehrs – Einflussfaktoren und Parametrisierung

September 2023

PTV Transport Consult GmbH

Stumpfstraße 1

76131 Karlsruhe, Deutschland

<http://consult.ptvgroup.com>

Dr. -Ing. Juliane Pillat

juliane.pillat@ptvgroup.com

Dipl.-Ing. Christian Weiß

christian.weiss@ptvgroup.com

Frankfurt University of Applied Sciences

Research Lab for Urban Transport

Nibelungenplatz 1 – HoST

60318 Frankfurt am Main, Deutschland

www.relut.de

Prof. Dr.-Ing. Dennis Knese

knese@fb1.fra-uas.de

Nicole Reinfeld, M. Sc.

nicole.reinfeld@fb1.fra-uas.de

PTV Planung Transport Verkehr GmbH

Haid-und-Neu-Straße 15

76131 Karlsruhe, Deutschland

www.ptvgroup.com

Dipl. rer.pol.techn. Silke Forkert

silke.forkert@ptvgroup.com

Inhalt

Vademecum	6
Teil I: Einflussfaktoren auf die Modus- und Routenwahl mit dem Fahrrad – ein priorisierter Soll-Katalog	7
1. Einleitung	7
2. Die Modus- und Routenwahl in der Verkehrsmodellierung	7
3. Soll-Katalog der Einflussfaktoren auf die Modus- und Routenwahl	9
3.1 Methodische Vorgehensweise	9
3.2 Einflussfaktoren auf die Moduswahl	9
3.3 Einflussfaktoren auf die Routenwahl	23
3.4 Limitationen	35
4. Priorisierung der Einflussfaktoren im Soll-Katalog	37
Teil II: Gegenüberstellung des Soll-Katalogs mit dem Status quo – ein Soll-Ist-Katalog aus den Perspektiven der Datenverfügbarkeit und Modellierung	41
1. Einleitung	41
2. Darstellung des Ist-Zustandes aus Perspektive der Modellierung	41
3. Soll-Ist-Vergleich	52
4. Weiterer Forschungsbedarf	65
Teil III: Ermittlung/Aktualisierung ausgewählter Parameter basierend auf existierender Datenbasis & Erhebungskonzept für fehlende Daten/Parameter	67
1. Integration der beispielhaft ermittelten Parameter im Rahmen eines Use Cases	67
2. Erhebungskonzept für fehlende Daten und Parameter	75
Fazit	89
Anhang	90
Literaturverzeichnis	102

Abbildungsverzeichnis

Abbildung 1: Vorgehen Erstellung Soll-Katalog (eigene Darstellung)	9
Abbildung 2: Einflussfaktoren bei der Moduswahl	10
Abbildung 3: Einfluss der Parkgebühren auf Modal Split des MIV-Verkehrs (eigene Darstellung basierend auf Hess, 2001)	17
Abbildung 4: Einflussfaktoren bei der Routenwahl mit dem Fahrrad	23
Abbildung 5: Vorgehen Priorisierung und Identifikation des Forschungsbedarfs	37
Abbildung 6: Objektive Längsneigung-Geschwindigkeit-Funktionen	43
Abbildung 7: Subjektive Längsneigung-Geschwindigkeit-Funktion	44
Abbildung 8: Grundgeschwindigkeit des Radverkehrs im Verkehrsmodell Dresden	46
Abbildung 9: Berechnung des Widerstandsfaktors bei der Erweiterung des Verkehrsmodells der Region Stuttgart um den Radverkehr	48
Abbildung 10: Zeitzuschläge für Brücken und Unterführungen im Verkehrsmodell Augsburg..	50

Tabellenverzeichnis

Tabelle 1: Einfluss der Determinanten der Moduswahl..... 11

Tabelle 2: Effekte verlängerter Reisezeit für den MIV und ÖV 18

Tabelle 3: Zusammenfassung Einfluss der Determinanten der Routenwahl 34

Tabelle 4: Priorisierte Einflussfaktoren auf die Moduswahl 38

Tabelle 5: Priorisierte Einflussfaktoren auf die Routenwahl 40

Tabelle 6: In den Verkehrsmodellen berücksichtigte Einflussfaktoren 42

Tabelle 7: Grundgeschwindigkeit des Radverkehrs in Abhängigkeit der Führungsform in den Verkehrsmodellen für den Regionalverband Großraum Braunschweig, die Stadt Braunschweig und die Stadt Wolfsburg 45

Tabelle 8: Grundgeschwindigkeit des Radverkehrs im Verkehrsmodell Regensburg 46

Tabelle 9: Faktoren zur Verlängerung der Reisezeit in Abhängigkeit der Landnutzung 49

Tabelle 10: Abbiegezeiten des Radverkehrs im Verkehrsmodell München..... 51

Tabelle 11: Widerstand der Kontinuität aus dem nationalen Personenverkehrsmodell der Schweiz 52

Tabelle 12: Revealed und stated Preferences im Kontext verschiedener Methoden zur Erhebung von Mobilitätsdaten..... 54

Tabelle 13: Soll-Ist-Katalog Moduswahl 57

Tabelle 14: Soll-Ist-Katalog Routenwahl 62

Tabelle 15: Literaturquellen für den Use Case 67

Tabelle 16: Ergebnisse des Use Case..... 72

Tabelle 17: Vor- und Nachteile der Erhebungsformen 79

Tabelle 18: Erhebungsgegenstand und geeignete Erhebungsform 81

Abkürzungsverzeichnis

d. h.	das heißt
MIV	motorisierter Individualverkehr
ÖV	öffentlicher Personenverkehr
Pkw	Personenkraftwagen
RP	Revealed Preferences
SP	Stated Preferences
u. a.	unter anderem
z. B.	zum Beispiel
z. T.	zum Teil

Vademecum

Dieser Bericht veröffentlicht die Ergebnisse des Forschungsprojektes „ModelRad – Status quo und Entwicklungsoptionen der Datengrundlage für die Modellierung des Radverkehrs“. Teil I bezieht sich auf die Einflussfaktoren, die im Radverkehr sowohl auf die Modus- als auch auf die Routenwahl wirken und liefert einen priorisierten Soll-Katalog dieser Einflussfaktoren. In Teil II dieses Berichtes wird auf die von der PTV Group erstellten Verkehrsmodelle eingegangen, und dabei vor allem die Integration radverkehrsspezifischer Faktoren in ebendiesen betrachtet. Des Weiteren wird eine Gegenüberstellung des Soll-Katalogs mit dem Status quo durchgeführt. Im Fokus stehen hierbei die Perspektiven der Datenverfügbarkeit und der Modellierung der radverkehrsrelevanten Parameter. Den Abschluss von Teil II bildet ein kurzer Ausblick auf mögliche weitere Forschungsthemen. In Teil III wird dargestellt, wie notwendige Parameter basierend auf existierenden Publikationen hergeleitet werden können. Für weitere fehlende Daten und Parameter wird ein Erhebungskonzept basierend auf Expert*innen-Interviews präsentiert.

Teil I: Einflussfaktoren auf die Modus- und Routenwahl mit dem Fahrrad – ein priorisierter Soll-Katalog

1. Einleitung

Der Radverkehr ist der Modus, dessen Beliebtheit und dessen Nutzungshäufigkeit in Deutschland im vergangenen Jahrzehnt am schnellsten und stärksten gewachsen ist (vgl. Ahrens et al. 2014, Gerike et al. 2021). Er wird aufgrund seiner Klimafreundlichkeit und seiner Umweltverträglichkeit mit dem Ziel einer weiteren Zunahme seines Anteils am Modal Split besonders gefördert (vgl. BMU 2018). Auf Grund seines steigenden Anteils am Modal Split und der stetigen Förderung nimmt folglich seine Bedeutung in der Verkehrsplanung, und somit die Relevanz seiner wirklichkeitsnahen Modellierung in Verkehrsmodellen, zu. Dieser Aufgabe ist dieses Forschungsprojekt gewidmet.

Verkehrsmodelle sind Werkzeuge in der Verkehrsplanung. In ihnen werden die Mobilitätsentscheidungen der Bevölkerung und die sich daraus ergebenden Verkehrszustände in den realen Verkehrssystemen nachgebildet. Darauf aufbauend kann z. B. die Wirkung geplanter bzw. gewünschter verkehrlicher Maßnahmen oder externer Entwicklungen abgeschätzt werden. Sie unterstützen somit die Entscheidungsfindung in der Verkehrsplanung. Mit Verkehrsmodellen kann der Verkehr von Räumen unterschiedlicher Größe, von Gemeinden bis zu ganzen Ländern, abgebildet werden. Verkehrsmodelle bestehen in der Regel aus zwei Teilmodellen. Das Angebotsmodell bildet die Verkehrsinfrastruktur mit ihren Eigenschaften vereinfacht ab. Es wird erstellt, um die Aufwände und die Widerstände der Ortsveränderungen und der Wahlalternativen zu quantifizieren. Das zweite Teilmodell ist das Nachfragemodell. In ihm werden die Wahlentscheidungen der Verkehrsteilnehmenden nachgebildet. Für jede Ortsveränderung wird u. a. die Wahl des Ziels, des Modus und der Route modelliert. Zu den Ergebnissen eines Verkehrsmodells gehören u. a. die Verkehrsmengen auf den betrachteten Straßen und Wegen. Diese können anschließend z. B. zur Dimensionierung von Verkehrsanlagen oder Berechnungen von Emissionen verwendet werden.

Der Radverkehr wurde in Verkehrsmodellen bislang meist vereinfacht abgebildet. Der Fokus lag bisher auf der genauen Abbildung des MIVs und des ÖVs. Ihrer wirklichkeitsnahen Abbildung kam aufgrund der höheren Anteile am Modal-Split, der höheren verkehrlichen Bedeutung und der höheren Finanzintensität der mit Verkehrsmodellen zu untersuchenden Maßnahmen eine höhere Relevanz zu. Zudem stellt die Abbildung des Radverkehrs als ein Modus mit eher kürzeren Wegen in den betrachteten Verkehrsmodellen aufgrund derer makroskopischen Natur eine Herausforderung dar. Modi mit längeren Wegen, wie der ÖV und der MIV, lassen sich leichter in makroskopischen Verkehrsmodellen abbilden. Für die Modellierung des Radverkehrs als eher kleinräumiger Modus sind zudem einige Daten erforderlich, die bisher noch nicht vorlagen (z. B. Führungsform des Radverkehrs, Beschaffenheit der Oberfläche etc.)

2. Die Modus- und Routenwahl in der Verkehrsmodellierung

Der Prozess der Verkehrsmodellierung besteht aus mehreren aufeinanderfolgenden Stufen: **Verkehrserzeugung bzw. Aktivitätenwahl, Ziel- und Moduswahl** sowie der **Routenwahl**. Im Folgenden werden sie genauer beschrieben.

Innerhalb der **Verkehrserzeugung bzw. Aktivitätenwahl** werden in einem ersten Schritt die Potenziale für die abzubildenden Ortsveränderungen berechnet. Dies erfolgt in der Regel differenziert nach Aktivitäten.

Im Rahmen der **Moduswahl** wird nachgebildet, welchen Verkehrsmodus die Verkehrsteilnehmenden für ihre Ortsveränderungen wählen. Beispiele für Modi des Personenverkehrs sind der MIV, ggf. unterteilt in Pkw-Selbstfahrende und Pkw-Mitfahrende, der ÖV, der Radverkehr und der Fußverkehr, sowie Kombinationen wie Park+Ride oder Bike+Ride. Im Rahmen der Modellierung des Güterverkehrs werden verschiedene Lkw-Gewichtsklassen als eigenständige Modi abgebildet. Für die Modellierung der Moduswahl sind für die Modi ihre Aufwände der Raumüberwindung auszuwählen. Anschließend sind diese für die Quelle-Ziel-Beziehungen zu quantifizieren. Für den MIV werden in der Regel die Aufwände Reiseweite, Reisezeit und die Kosten berücksichtigt. Für den ÖV werden neben diesen „klassischen“ Aufwänden ÖV-spezifische Aufwände wie die Umsteigehäufigkeit, der Diskomfort durch Überlastung, die Bedienungshäufigkeit, die Fahrzeugfolgezeit sowie die Zu- und die Abgangszeit berücksichtigt. Für den Radverkehr wurden bisher häufig lediglich die Reiseweite und/oder die Reisezeit berücksichtigt. Im Sinne einer möglichst wirklichkeitsnahen Abbildung des Radverkehrs besteht die Frage, ob für den Radverkehr weitere Aufwände zu berücksichtigen sind und wie diese abgebildet und in die Modellierung der Moduswahl integriert werden können. Nach der Quantifizierung der Aufwände werden diese je nach Modellstruktur bewertet oder zu einem Nutzen verknüpft.

Es existieren verschiedene Ansätze für die Stufe der Moduswahl. Sie unterscheiden sich in der Reihenfolge der Berechnung der Ziel- und der Moduswahl.

Im **Trip Interchange Modell** erfolgt die Berechnung der Moduswahl nach der Berechnung der Zielwahl. Die Verkehrsströme der Verkehrstrommatrizen werden nach ihrer Berechnung auf die verfügbaren Modi aufgeteilt. Dies erfolgt in Abhängigkeit der Aufwände der Modi auf der jeweiligen Relation. Das Ergebnis sind modusfeine Verkehrstrommatrizen.

Das zweite Modell ist das **Trip End Modell**. In diesem erfolgt die Modellierung der Moduswahl vor der Modellierung der Zielwahl. Die Verkehrsaufkommen aus der Verkehrserzeugung werden nach ihrer Berechnung auf die verfügbaren Modi aufgeteilt. Dies erfolgt auf der Grundlage empirischer Daten bzw. modusspezifischer Verfügbarkeiten und Erreichbarkeiten. In der darauffolgenden Modellierung der Zielwahl werden aus diesen modusfeinen Verkehrsaufkommen die Verkehrstrommatrizen für jeden Modus getrennt berechnet.

Als dritte Variante existieren **Simultanmodelle**. Diese berechnen die Ziel- und die Moduswahl teilweise oder vollständig simultan. Simultane Ansätze bilden den Stand der Technik und werden sowohl für städtische Modelle (z. B. Dresden, Augsburg, Hamburg, München) als auch für regionale (Region Braunschweig, Region Stuttgart, Landesverkehrsmodelle NRW und Bayern) bzw. nationale Modelle (Schweiz, Österreich) verwendet, falls diese mehrere Modi beinhalten.

In der Stufe der Verkehrsumlegung werden die Verkehrsströme der Modi auf das Netzmodell umgelegt. Das Ergebnis sind die Verkehrsbelastungen der Netzelemente. Zunächst werden dabei für die Quelle-Ziel-Beziehungen im Netz mögliche Routen gesucht bzw. ermittelt. Die Routensuche erfolgt auf der Grundlage der Widerstände der einzelnen Netzelemente (Strecken, Abbieger und Anbindungen bzw. im ÖV auch Haltestellen unter Beachtung von Umstiegsbeziehungen). Im zweiten Schritt, der **Routenwahl**, werden die Verkehrsströme auf die gefundenen Routen aufgeteilt und umgelegt. Dies erfolgt in Abhängigkeit der Widerstände der ermittelten Routen, welche sich aus den Widerständen ihrer Netzelemente ergeben. Folglich ist die Grundlage der Modellierung der Routenwahl die Definition der Widerstände der Netzelemente.

3. Soll-Katalog der Einflussfaktoren auf die Modus- und Routenwahl

3.1 Methodische Vorgehensweise

Dieses Kapitel beinhaltet eine systematische Darstellung der Einflussfaktoren auf die Modus- und Routenwahl aus der bisherigen empirischen Forschung und aus bestehenden Verkehrsmodellen innerhalb eines sog. Soll-Katalogs. Außerdem wurden Fachmeinungen über die Präsentation in Workshops mit Verkehrsmodellierenden eingebunden. Die Einflussfaktoren im Soll-Katalog wurden analog zum Vier-Stufen-Modell getrennt für die Modus- und Routenwahl recherchiert. Zur Literaturrecherche wurden Suchmaschinen und Plattformen wie Google Scholar und Web of Science genutzt. Um die Determinanten der Entscheidungen zu identifizieren, die dazu führen, einen Modus oder eine Route zu wählen, wurden 63 Forschungsarbeiten zur Verkehrsmittelwahl (einschließlich neun Metastudien) und 47 Veröffentlichungen zur Routenwahl mit dem Fahrrad (einschließlich vier Literaturüberblicken) untersucht (vgl. Abbildung 1). Im ersten Schritt wurden die Ergebnisse aus den Studien zusammengetragen. So konnten 383 Aussagen zu Determinanten der Moduswahl sowie 423 Aussagen zu Determinanten der Routenwahl mit dem Fahrrad identifiziert werden. Im zweiten Schritt wurden die Ergebnisse nach Einflussfaktoren auf die Moduswahl und nach Modus kategorisiert. Für die Routenwahl erfolgte die Kategorisierung nur nach Einflussfaktoren, da die Studien explizit schon für den Modus des Radfahrens recherchiert wurden. Die Analyse wurde hauptsächlich für objektive, d. h., messbare Determinanten durchgeführt. Subjektive Einflussfaktoren werden am Ende des Kapitels diskutiert. Die Einflussfaktoren werden im Folgenden dargestellt und erläutert.

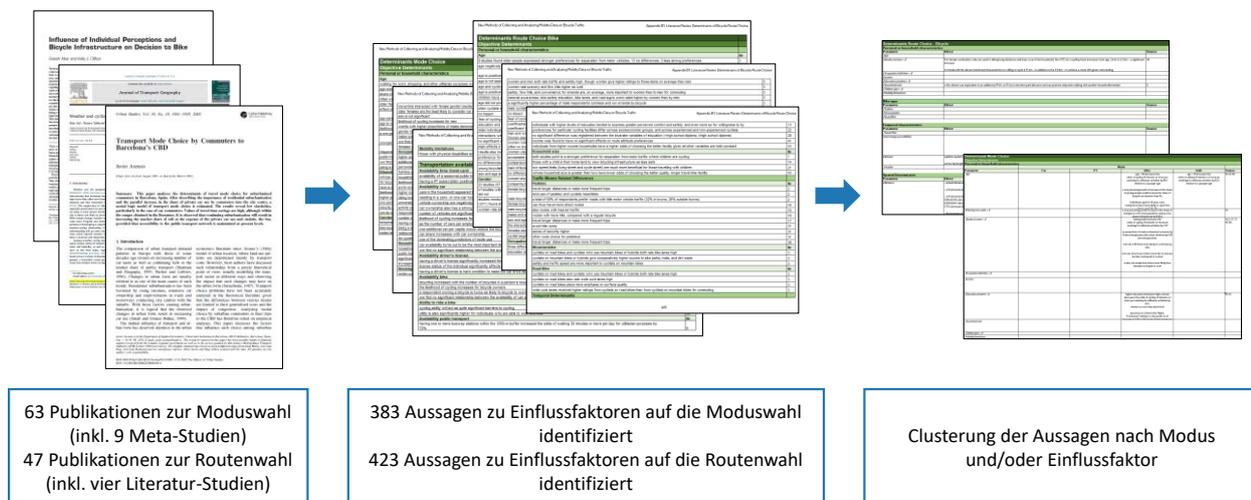


Abbildung 1: Vorgehen Erstellung Soll-Katalog (eigene Darstellung)

3.2 Einflussfaktoren auf die Moduswahl

Abbildung 2 zeigt, wie die objektiven Einflussfaktoren auf die Moduswahl kategorisiert werden können: Soziodemografische und -ökonomische Merkmale, Verkehrsmittelverfügbarkeit, Kostenkomponenten, zeitliche Merkmale, räumliche Merkmale, Wetter und andere wegebezogene Einflussfaktoren. Einige Einflussfaktoren lassen sich nicht trennscharf den übergeordneten Kategorien zuordnen. Beispielsweise können die Verfügbarkeit einer Fahrradabstellanlage und die Entfernung zur nächsten Haltestelle des ÖV sowohl der Verfügbarkeit von Verkehrsmitteln bzw. der Ausstattung mit Verkehrsmitteln als auch räumlichen Merkmalen zugeordnet werden. Deshalb sei an dieser Stelle darauf hingewiesen, dass der Soll-Katalog eine ganzheitliche Übersicht bieten soll und die Kategorisierung nur eine untergeordnete Rolle spielt. Die Effektrichtungen (positiver,

negativer, kein signifikanter Einfluss) der 62 objektiven Einflussgrößen wurden separiert nach Modus zusammengefasst (vgl. Tabelle 1). Als Modi werden der MIV (sowohl für Alleinnutzende als auch als Fahrgemeinschaft und Sharing), der ÖV (als Sammelbegriff für alle öffentlichen Verkehrsmittel wie Bus, Bahn, Tram, Metro, Zug, autonomes Shuttle), das Fahrrad (inkl. herkömmliche Fahrräder, Pedelecs und Sharing) und das Zufußgehen betrachtet. So beziehen beispielsweise Corcoran et al. (2014), Heaney et al. (2019), Wicki et al. (2019) sowie An et al. (2019) Bikesharing in ihre Analysen ein. Wicki et al. (2019) integrieren zudem die Moduswahl eines autonomen Shuttles als Variante des ÖV. Habib (2019) betrachtet die Moduswahl eines Ubers (Ridehailing) und Hess (2001) berücksichtigt Fahrgemeinschaften. Die einzelnen Einflussfaktoren auf die Wahl zwischen den zuvor genannten Modi werden im Folgenden diskutiert. Dazu werden die Einflussgrößen hinsichtlich ihrer Effektrichtung (positiver, negativer oder kein statistisch signifikanter Effekt) auf die Moduswahl entsprechend Tabelle 1 eingeordnet und beispielhaft mit objektiv quantifizierbaren Aussagen erläutert. Abschließend erfolgt eine kurze Darstellung subjektiver Einflussfaktoren.

Soziodemografische und -ökonomische Merkmale

Die meisten Studien stellen fest, dass die Variablen *Alter* und *Geschlecht* einen Einfluss auf die Verkehrsmittelwahl haben. Ton et al. (2019) argumentieren hingegen, dass fehlende Unterschiede in den Daten ihrer Studie auf das Untersuchungsgebiet in den Niederlanden und die dort herrschende Fahrradkultur (vgl. Carstensen & Ebert, 2012) zurückzuführen sein könnte.



Abbildung 2: Einflussfaktoren bei der Moduswahl

Tabelle 1: Einfluss der Determinanten der Moduswahl

Hinweise: + = positiver Effekt, - = negativer Effekt, o = kein signifikanter Effekt, hochgestellte Nummerierung = Nummer der Quelle (siehe Literaturverzeichnis), * (ja = 1).

Soziodemografie/-ökonomie	Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen
Alter	+ ²³ / o ⁵²	-15,22,47/ o ⁵²	+10,23/ ⁹ ,21,22,26,43,53/ o ^{45,52,58,61}	+ ⁹ ,23/ ²² ,53,61/ o ⁵²
Geschlecht (weiblich = 1)	- ³ ,22/ o ^{27,52}	+ ³ / ¹¹ ,53/ o ⁵²	-1,6,8,9,10,17,19,26,37,39,45,53/ o ^{25,52,58}	- ⁵³ ,55/ o ^{1,8,52}
Migrationshintergrund*	o ⁵²	o ⁵²	- ³⁷ ,39,43/ o ^{8,52}	+ ⁸ / o ⁵²
Mobilitätseinschränkungen*		- ⁵⁶	- ²⁶	- ⁸
Haushaltsgröße		+ ⁵²	+ ⁵² / o ⁴⁵	- ⁵²
Kinder im Haushalt	o ⁵²	- ⁴⁷ ,52,61	o ^{45,52}	o ⁵²
Schüler*in oder Student*in*		+1,15,47,52	+1,41,43,47,52/ o ⁴⁵	+ ⁴⁷ / o ¹
Arbeitszeit (Vollzeit = 1)	o ^{11,52}	+ ¹⁵ / o ^{11,52}	+ ²⁶ / ²⁶ ,37/ o ⁵²	o ⁵²
Einkommen	+ ²⁷ ,47	+ ⁶² / ⁶²	+10,39,45/ ³⁹ ,41,58/ o ^{8,43,52,53}	+ ⁴⁷ ,52/ ⁹ / o ⁸

Verkehrsmittelverfügbarkeit	Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen
Anzahl Pkw	+ ²⁷ ,47,61,63/ o ^{11,52}	-11,15,22,62/ o ⁵²	- ⁸ ,9,10,21,25,26,37,39,43/ o ^{13,52}	- ⁸ ,9/ o ⁵²
Dienstwagen*	+ ⁵² ,53	o ⁵²	- ⁵²	+ ⁵²
Führerschein*	+11,15	-11,15		
Anzahl Fahrräder			+ ⁸ ,9,25,37,45	
Fähigkeit, Fahrrad zu fahren*			+ ⁹ ,53	
Fahrradabstellanlage*	o ⁵²	o ⁵²	+ ²⁵ ,53,59	+ ⁵²
Entfernung Bikesharing-Station			+ ⁶³	
Zeitkarte ÖV*	- ²³ ,52,63	+ ⁶³ / o ⁵²	+ ²³ ,52	+ ²³ / ⁵²
ÖV-Angebot*	o ²⁷	+ ⁹ ,47,62	+ ⁵⁹	+ ⁹
Entfernung Haltestelle	+ ³ ,16	- ³ ,16,63	- ²¹ / o ⁴⁵	- ¹⁶

Kostenmerkmale	Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen
Kraftstoffkosten	-1,3,41,61,63	+ ³ ,62	+ ⁴⁰ ,41	
Ticketpreis ÖV	+ ³ ,11,41	- ³ ,11,47,56,61,62,63		
Parkgebühren	- ²² ,27,41,63		+ ⁴³	
Leihgebühren			- ⁵⁶ ,63	
Straßennutzungsentgelte	- ⁴¹	+ ⁴¹		
Anreize Arbeitgeber*	+ ²⁷ ,52	+ ⁵²	+ ⁵² ,53	o ⁵²

Tabelle 1: Einfluss der Determinanten der Moduswahl (Fortsetzung)

Hinweise: + = positiver Effekt, - = negativer Effekt, o = kein signifikanter Effekt, hochgestellte Nummerierung = Nummer der Quelle (siehe Literaturverzeichnis), * (ja = 1)

Zeitliche Merkmale	Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen
Reisezeit	- _{1,3,22,23,61,63}	- _{1,3,11,15,22,23,56,61,63}	- _{1,22,23,52,61,63}	- _{1,22,23,52}
Wochentag (≠ Wochenende)		+ ⁶	+ _{2,6,29,52} / - ₁₂ / o ⁸	- ₈ / o ⁵²
Ferien*			- ₅₄ / o ¹²	
Feiertag*			+ ₁₂ / - ₅₄	
Jahreszeit (≠ Winter)			+ _{29,63} / o ⁵²	+ ⁵²
Hauptverkehrszeit*			o ⁵²	- ⁵²
Dunkelheit*			- _{8,38,59}	o ⁸
Parkplatzsuche			+ ³⁹	
Wartezeit ÖV	+ ¹⁵	- _{15,56}		
Zusätzlicher Fußweg		- _{6,15,55}		
Anzahl der Umstiege		- _{15,22}		
Umsteigedauer	+ _{3,15}	- ³		
Takt des ÖV	o ³	- ₁₅ / o ³		
Räumliche Merkmale	Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen
Distanz	+ ³	+ ³ / - _{3,6}	- _{6,8,10,17,25,39,45}	- _{6,8}
Topographie			- _{2,6,9,10,21,25,39,43,59} / o ^{8,53}	- _{8,9}
Infrastruktur (Fahrrad) vorhanden*			+ _{6,13,21,25,36,37,39,41,43,47,53,59,63} / o ²	
Infrastruktur (Gehweg) vorhanden*	o ¹¹	o ¹¹		+ ⁶
Flächennutzung (Dichte)	- _{3,11,16,61} / o ^{16,52}	+ _{3,6,11,16,47,52,61}	+ _{22,52} / - _{10,43} / o ^{8,21,25,39,41,45,61}	+ _{6,16,22,52,61} / o ⁸
Flächennutzung (Vielfalt)	- _{11,16,61}	+ _{11,16,52,61}	+ _{52,61} / - ₃₇ / o ^{2,8,25}	+ _{8,16,52,61}
Flächennutzung (Design)	- _{16,61} / o ²⁷	+ _{16,61}	+ _{9,10,61} / o ^{8,25}	+ _{16,61} / o ^{8,9}
Natur*	o ⁵²	o ⁵²	+ _{10,59} / - ₄₅ / o ⁵²	+ ₉ / o ⁵²

Tabelle 1: Einfluss der Determinanten der Moduswahl (Fortsetzung)

Hinweise: + = positiver Effekt, - = negativer Effekt, o = kein signifikanter Effekt, hochgestellte Nummerierung = Nummer der Quelle (siehe Literaturverzeichnis), * (ja = 1)

Wetter		Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen	
Temperatur		-.56	+2,5,10,12,17,24-26,29,38-41,58/ o43,45,54		
Hitze*			-.24,41,54		
Schnee/Eis*			-.2,17,25,38,41,54,59		
Luftfeuchtigkeit			-.2,38,54		
Regen*		-.47	-.2,5,10,12,13,17,25,26,29,39-41,54,58,59/ o43	-.8	
Windgeschwindigkeit			-.2,12,17,38,54/ o43		
Bewölkung*			-.54		
Unwetterwarnung*			-.54		

Sonst. anlassbezogene Merkmale		Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen	
Mitreisende*		-.52	-.52	+52	
Gepäck*			-.59		
Auslastung		-.56	-.10,39/o21		
Reisezweck: Freizeit	o52	o52	+8,52	+8	
Reisezweck: Arbeit	o52	+52	+6,52	+52	
Reisezweck: Schule	o52	+52	+52	o52	
Reisezweck: Einkaufen	o52	o52	+52/o8	+8	
Sicherheit (objektiv)			+40,43		

Subjektive Merkmale		Effekt			
Einflussfaktor	MIV	ÖV	Fahrrad	Zufußgehen	
Sicherheit (subjektiv)					
Wahrnehmung					
Zufriedenheit					
Kultur					
Psychologische Determinanten					
Lebensstil					
Erfahrungen					
Gewohnheiten					

Nicht anwendbar

Studien wie z. B. von Rietveld & Daniel (2004) oder Winters et al. (2011) finden einen negativen Zusammenhang zwischen Alter und Fahrradnutzung, d. h., dass die Fahrradnutzung mit dem Alter abnimmt. Erstgenannte geben an, dass ein Anstieg des Anteils junger Menschen um einen Prozentpunkt den Anteil der Fahrradnutzung um mehr als 4 % erhöhen würde (Ausgangsniveau 35,1 % Fahrradnutzung). Cervero et al. (2019) lassen in ihrer Analyse eine quadratische Funktion des Alters einfließen. Das bedeutet, dass die Fahrradnutzung mit dem Alter bis zu einem Grenzwert zunimmt und anschließend wieder abnimmt. Helbich et al. (2014) finden Unterschiede je nach Reisezweck: Bei Freizeit-Fahrten hat das Alter einen positiven Einfluss auf die Wahl des Fahrrads, bei Pendel-Fahrten zur Arbeit einen negativen. Dementsprechend kann der Zusammenhang zwischen dem Alter einer Person und der Wahl des Fahrrads nicht generalisiert werden (vgl. Heinen et al., 2010). Von den untersuchten Studien geben zwölf Studien an, dass Frauen weniger häufig das Fahrrad bei der Verkehrsmittelentscheidung wählen als Männer. So zeigen Rybarczyk & Wu (2014), dass die Wahrscheinlichkeit, mit dem Fahrrad zur Arbeit zu pendeln, für Männer nahezu dreimal so hoch sei als für Frauen.

Drei Studien finden einen sinkenden Zusammenhang zwischen dem Anteil an Personen mit *Migrationshintergrund* und der Fahrradnutzung: ein Anstieg des Anteils der Menschen mit Migrationshintergrund in der Bevölkerung um einen Prozentpunkt verringert den Anteil der Fahrradnutzung um 0,62 %, ausgehend von einer durchschnittlichen Fahrradnutzung von 35,1 % (vgl. Rietveld & Daniel, 2004). Dieses Ergebnis sollte vor dem Hintergrund der ggf. fehlenden Verkehrsmittelverfügbarkeit und der Fähigkeit, mit dem Fahrrad zu fahren, interpretiert werden. In zwei Studien, die ebenfalls eine Variable für den Migrationshintergrund einbezogen haben, werden keine signifikanten Unterschiede festgestellt.

Weitere personen- bzw. haushaltsbezogenen Einflussfaktoren wie *Mobilitätseinschränkungen*, die *Haushaltsgröße*, *Kinder im Haushalt*, der Status *Schüler*in oder Student*in*, das *Arbeitszeitmodell* und das *Einkommen* wurden ebenfalls untersucht. Allerdings wurden in den Ergebnissen der betrachteten Forschungsarbeiten keine objektiv quantifizierbaren Aussagen zu diesen Einflussfaktoren getroffen, sodass in den folgenden Abschnitten nur verallgemeinernde Aussagen dargestellt werden können. So nutzen mobilitätseingeschränkte Personen in den analysierten Studien vergleichsweise seltener aktive Mobilitätsformen wie das Radfahren (vgl. Helbich et al., 2014) und Zufußgehen (vgl. Cervero & Duncan, 2003). Dies gilt auch für die Wahl des ÖV (vgl. Wicki et al., 2019). Zu beachten gilt, dass in der Studie von Wicki et al. (2019) ein autonomes Shuttle als Form des ÖV untersucht wird, und die Ergebnisse ggf. nicht auf den gesamten ÖV übertragbar sind. Die Haushaltsgröße wurde nur in zwei der untersuchten Studien in die Analyse einbezogen. Während sie bei Rybarczyk & Wu (2014) keinen statistisch signifikanten Einfluss auf die Wahl des Fahrrads hat, erhöht eine größere Haushaltsgröße in der Untersuchung von Ton et al. (2019) die Wahrscheinlichkeit, den ÖV zu nutzen oder mit dem Rad zu fahren und reduziert die Wahrscheinlichkeit, zu Fuß zu gehen. Vier der analysierten Studien haben untersucht, ob Kinder im Haushalt die Wahl des Verkehrsmittels beeinflussen. Drei Studien geben an, die Wahrscheinlichkeit, einen Weg mit dem ÖV zurückzulegen, würde sinken, wenn Kinder dabei wären. Im Hinblick auf die anderen Modi sind die Ergebnisse nicht signifikant.

Eine Vollzeitbeschäftigung im Vergleich zu einer Teilzeitbeschäftigung hat keinen statistisch signifikanten Effekt auf die Wahl des MIV (2 Studien) oder das Zufußgehen (1 Studie). Bei der Wahl des ÖV gibt es positive Effekte (1 Studie) sowie nicht signifikante Ergebnisse (2 Studien). Bei der Wahl des Fahrrads kommen die Studien zu unterschiedlichen Ergebnissen (1 Studie positiv, 2 Studien negativ, 1 Studie nicht signifikant). Helbich et al. (2014) stellen sowohl einen

positiven als auch einen negativen Effekt fest: Bei Freizeitfahren hat eine Vollzeitbeschäftigung im Vergleich zu einer Teilzeitbeschäftigung einen negativen Effekt auf die Wahl des Fahrrads, während bei Pendel-Fahrten zur Arbeit ein positiver Effekt vorliegt.

Mit steigendem Einkommen wird häufiger der MIV als Modus gewählt (2 Studien). Das Vorzeichen bei der Wahl des ÖV, Fahrrads oder Zufußgehens variiert je nach Studie. Das Einkommen wird wegen der mangelnden Datenverfügbarkeit auf disaggregierter Ebene dabei unterschiedlich in den Analysen operationalisiert. Cervero & Duncan (2003) nutzen beispielsweise den Anteil der Haushalte mit geringem Einkommen. Parkin et al. (2008) vergleichen Gruppen mit unterschiedlich hohen Einkommen miteinander. Die Autor*innen nutzen die Berufsbezeichnung als Proxy (Ersatzgröße) für das Einkommen. Zusätzlich wird der Anteil der Haushalte, die unter eine Einkommensarmutsgrenze fallen, als Proxy für Kriminalität, sichere Abstellanlagen, die Verfügbarkeit von Fahrrädern und das Image des Fahrrads im Modell berücksichtigt. Rybarczyk & Wu (2014) wählen die Anzahl der Fahrzeuge im Haushalt als Proxy für das Einkommen. Santos et al. (2013) nutzen das Bruttoinlandsprodukt pro Kopf, um den Lebensstandard in unterschiedlichen Untersuchungsgebieten zu vergleichen. Heinen et al. (2010) kritisieren an bisherigen Studien, dass kein Rückschluss auf die Kausalität der Beziehung zwischen sozioökonomischen Faktoren und Radfahren möglich sei. Der Bildungsabschluss wurde in der Darstellung der Einflussfaktoren explizit nicht separat berücksichtigt, da eine hohe Korrelation mit dem Einkommen vorliegt. Insbesondere dann kann dies zu Verzerrungen führen, wenn beide Variablen in der Analyse berücksichtigt werden (wie beispielsweise bei Winters et al., 2007). Demgegenüber steht der Status als Schüler*in oder Student*in zum Zeitpunkt der durchgeführten Studien. Der Status erhöht die Wahrscheinlichkeit für die Wahl des ÖV (4 Studien), des Fahrrads (5 Studien, 1 Studie nicht signifikant) und des Zufußgehens (1 Studie, 1 Studie nicht signifikant) als Modus.

Verkehrsmittelverfügbarkeit

Bei der Verfügbarkeit von Verkehrsmitteln und der Ausstattung des Individuums/Haushalts können mit Blick auf den MIV die *Anzahl der Pkw im Haushalt*, das Vorhandensein eines *Führerscheins* oder eines *Dienstwagens* differenziert werden. Die Anzahl der Pkw wird dabei in den Studien pro Haushaltsmitglied oder pro Beschäftigte*n, oder aggregiert als Motorisierungsrate einbezogen. Mit zunehmender Anzahl an Pkw werden positive (4 Studien) bzw. nicht signifikante (2 Studien) Effekte auf die Wahl des MIV gefunden. Der Einfluss auf die anderen Verkehrsmittel ist negativ (ÖV: 4 Studien, Fahrrad: 9 Studien, Zufußgehen: 2 Studien) bzw. nicht signifikant. So geben Eluru et al. (2012) an, dass eine Verringerung des durchschnittlichen Pkw-Besitzes pro Haushalt um 1 den MIV-Anteil um 35,39 % verringern und den Anteil des ÖV um 15,85 % erhöhen würde. Der Modal Split im Untersuchungsgebiet Montreal (Kanada) liegt dabei bei 67,8 % MIV, 21,4 % ÖV sowie 10,8 % Fahrrad und Zufußgehen. Rietveld & Daniel (2004) schließen in ihrer Studie, dass ein zusätzlicher Pkw pro Kopf den Anteil des Fahrrads am Verkehrsaufkommen um 26 % verringern würde (Ausgangsniveau der Fahrradnutzung: 35,1 %). Die Verfügbarkeit eines Führerscheins wird in zwei Studien thematisiert. Sie finden beide einen positiven Effekt auf die MIV-Nutzung und einen negativen Effekt auf die Wahl des ÖV. Die Verfügbarkeit eines Dienstwagens wurde ebenfalls in zwei Studien einbezogen. Die Verfügbarkeit eines Dienstwagens führt in den Niederlanden laut Ton et al. (2019) zu einer Erhöhung des MIV-Anteils um 13,5 % (Ausgangswert: 44,8 %), einer Verringerung des Fahrradanteils um 21,3 % (Ausgangswert: 43,5 %) und einer Erhöhung des Zufußgehens um 7,8 % (Ausgangswert: 10,0 %) am Modal Split. Der ÖV-Anteil sei davon nicht betroffen (Ausgangswert: 1,6 %).

Mit Blick auf den ÖV sind die Verfügbarkeit einer *Zeitkarte*, das *ÖV-Angebot* per se und die *Entfernung zur nächsten Haltestelle* zu unterscheiden. Die Ergebnisse von Ton et al. (2019) zeigen, dass die Verfügbarkeit einer ÖV-Zeitkarte in allen Haushalten zu einer Verringerung des MIV-Anteils um 1,9 %, einer Erhöhung des Radverkehrsanteils um 2,8 % und einer Verringerung des Zufußgehens um 0,9 % am Modal Split führen würde. Der ÖV-Anteil sei davon nicht betroffen. Hardinghaus et al. (2021) finden gleiche Effektrichtungen, mit Ausnahme des Einflusses auf das Zufußgehen: Dort habe das ÖV-Ticket einen positiven Effekt. Eine Verbesserung des ÖV-Angebots hat keinen signifikanten Effekt auf die MIV-Nutzung (1 Studie), allerdings einen positiven Effekt auf die verbleibenden Verkehrsmittel (ÖV: 3 Studien, Fahrrad: 1 Studie, Zufußgehen: 1 Studie). Derselbe Effekt wird bei der Entfernung zur nächsten Haltestelle ersichtlich. Wird die Entfernung zur nächsten Haltestelle verlängert, hat dies einen negativen Einfluss auf die Wahl von ÖV (3 Studien), Fahrrad (1 Studie, 1 Studie nicht signifikant) und Zufußgehen (1 Studie). Die Verkehrsmittelwahl verlagert sich auf den MIV (2 Studien). In Elastizitäten ausgedrückt bedeutet dies, dass eine Steigerung der Entfernung zur nächsten Haltestelle für Bus bzw. Zug um 1 % zu einer Veränderung der Wahrscheinlichkeit um 0,007 % bzw. 0,041 % führt, den MIV zu wählen (vgl. Asensio, 2002). Die Wahlwahrscheinlichkeit für den Bus würde sich entsprechend um -0,157 % bzw. 0,174 % und die Wahlwahrscheinlichkeit für den Zug um 0,037 % bzw. -0,155 % verändern (vgl. ebd.). Ewing & Cervero (2010) haben in einer Meta-Studie Elastizitäten im Hinblick auf die Entfernung zur nächsten ÖV-Haltestelle basierend auf jeweils drei Studien gebildet. Aufgrund der unterschiedlichen abhängigen Variablen in den Studien (z. B. Wahl des ÖV, Anzahl ÖV-Wege, Anteil ÖV-Wege) sind die Elastizitäten schwer zu interpretieren und werden entsprechend nicht weiter ausgeführt.

Für das Fahrradfahren spielen neben der *Anzahl an Fahrrädern im Haushalt*, die Verfügbarkeit einer *Fahrradabstellanlage* sowie die *Fähigkeit, Fahrrad zu fahren* eine Rolle. Während für die Anzahl an Fahrrädern im Haushalt, die Verfügbarkeit einer Fahrradabstellanlage sowie die Fähigkeit, Fahrrad zu fahren positive Effekte auf die Wahl des Fahrrads und zum Teil die Wahl des Zufußgehens nachgewiesen werden, wird die *Erreichbarkeit der Abstellanlage* in den vorliegenden Studien nicht thematisiert. Eine mögliche Ursache liegt in der Datenverfügbarkeit. Daten zur Erreichbarkeit der Abstellanlage müssen explizit erhoben werden. Dies ist beispielsweise in der bevölkerungsrepräsentativen Mobilitätsbefragung „Mobilität in Deutschland“ (MiD) der Fall. Die Frage nach der Erreichbarkeit der Abstellanlage wird dort im Modul „Nahmobilität und Radverkehr“ einem Teil der Befragten vorgelegt. Bisherige Studien berücksichtigen Fahrradabstellanlagen am Arbeitsplatz (=Zielort) bei der Wahl des Fahrrads zum Pendeln (u. a. Stinson & Bhat, 2004, Hunt & Abraham, 2007). Die Abstellanlage am Wohnort wurde bisher nur von Nkurunziza et al. (2012) berücksichtigt: Fehlende sichere Abstellanlagen am Wohnort führten dort zu einer geringeren Wahrscheinlichkeit, das Fahrrad zu wählen. Heinen & Bühler (2019) haben 95 Studien in Hinblick auf das Fahrradparken in einem Review zusammengefasst und analysiert. Die Erreichbarkeit der Abstellanlage wurde nicht berücksichtigt. Außerdem spielt das Sharing-Angebot eine Rolle bei der Entscheidung, welches Verkehrsmittel gewählt wird: So finden Kowald et al. (2022) bei steigender Entfernung der Bike-Sharing-Entleih- und Rückgabe-Stationen einen sinkenden Nutzen bei den Befragten.

Kostenkomponenten

Die untersuchten Kostenkomponenten beinhalten *Kraftstoffkosten*, den *Ticketpreis im ÖV*, *Parkgebühren*, *Leihgebühren für Bike- und Carsharing*, *Straßennutzungsentgelte* und *Anreize des Arbeitgebers*. Steigende Kosten haben unabhängig von der Kostenart einen negativen Effekt auf

die Wahrscheinlichkeit, das entsprechende Verkehrsmittel zu wählen. Außerdem werden in den zugrundeliegenden Studien bei steigenden Kosten Kreuz-Elastizitäten – also Verlagerungseffekte auf andere Modi – nachgewiesen.

Eine Erhöhung der Kraftstoffkosten (inkl. Straßennutzungsentgelte) um 1 % führt unter Konstanthaltung aller weiteren Faktoren zu einer Veränderung von -0,092 %/0,082 %/0,188 % den MIV/den Bus/den Zug zu wählen (vgl. Asensio, 2002). Wenn die Ticketpreise für den Bus um 1 % steigen, verändert dies die Wahrscheinlichkeit, den MIV/den Bus/den Zug zu wählen um 0,008 %/-0,210 %/0,051 % (vgl. ebd.). Übertragen auf den Ticketpreis für eine Zugfahrt verändert sich die Wahrscheinlichkeit, den MIV/den Bus/den Zug zu wählen, um 0,023 %/0,109 %/-0,091 % (vgl. ebd.). Pucher & Buehler (2006) haben den Anstieg des Benzinpreises auf den Fahrradanteil am Modal Split untersucht: Eine Erhöhung des Benzinpreises um zehn Cent pro Liter führt zu einem Anstieg des Fahrradanteils auf Arbeitswegen um 0,3 Prozentpunkte (im Vergleich zu einem durchschnittlichen Fahrradanteil von 52 % bei Wegen zur Arbeit). Steigende Parkgebühren führen zu einer Verlagerung von der Wahl, im MIV zu fahren (sowohl allein als auch in einer Fahrgemeinschaft) hin zum ÖV (vgl. Abbildung 3). Bezogen auf das Fahrrad bedeutet eine Erhöhung der Parkgebühren für den MIV um 14 Cent pro Stunde, einen Anstieg der Nutzung des Fahrrads um 5,2 % ausgehend von einem Fahrradanteil von 35,1 % (vgl. Rietveld & Daniel, 2004).

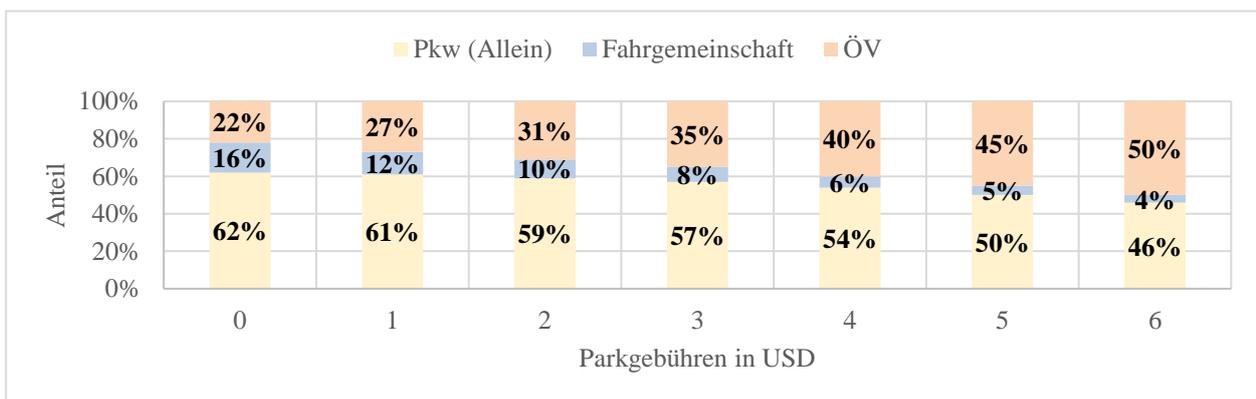


Abbildung 3: Einfluss der Parkgebühren auf Modal Split des MIV-Verkehrs (eigene Darstellung basierend auf Hess, 2001)

Für die Einflussfaktoren Leihgebühren und Straßennutzungsentgelte wurden in den analysierten Studien keine Elastizitäten oder Effektstärken berechnet. Dementsprechend enthält Tabelle 1 nur die Effektrichtung. Ein weiterer Einkommens-/Kosteneffekt sind Anreize des Arbeitgebers wie beispielsweise Kompensationen. Falls das Pendeln auf dem Arbeitsweg mit dem Fahrrad vom Arbeitgeber kompensiert werden würde, würde dies gemäß Ton et al. (2019) zu einer Verringerung des MIV-Anteils um 4,1 % (Ausgangswert: 44,8 %), einer Erhöhung des Radverkehrsanteils um 6,3 % (Ausgangswert: 43,5 %) und einer Verringerung des Zufußgehens um 2,2 % (Ausgangswert: 10,0 %) führen. Der ÖV-Anteil sei davon nicht betroffen (Ausgangswert: 1,6 %). Heinen et al. (2010) sehen auch Duschmöglichkeiten am Arbeitsplatz als einen Anreiz, mit dem Fahrrad zur Arbeit zu pendeln.

Zeitliche Merkmale

Neben der Reisezeit beeinflussen weitere Faktoren wie *Wochentage*, *Ferien*, *Feiertage*, die *Jahreszeit* und die Tageszeit (im Sinne von *Hauptverkehrszeiten* und Wegen bei *Dunkelheit*) die Moduswahl. Darüber hinaus spielen je nach Modus die *Parkplatzsuche*, *zusätzliche Wartezeiten* oder *Fußwege*, *Umstiegszeiten*, die *Häufigkeit von Umstiegen* und der *ÖV-Takt* eine Rolle. In Studien, die den Einfluss einer längeren Reisezeit auf den Nutzen eines Verkehrsmittels

untersuchen, hat die Reisezeit sowohl für den MIV (6 Studien) und den ÖV (9 Studien) als auch für das Fahrrad (6 Studien) und das Zufußgehen (4 Studien) einen negativen Einfluss. Tabelle 2 zeigt Effekte verlängerter Reisezeiten aus den untersuchten Studien für den Kfz-Verkehr und den ÖV.

Tabelle 2: Effekte verlängerter Reisezeit für den MIV und ÖV

Verlängerte Reisezeit	Effekt auf	
	MIV	ÖV
MIV	+ 1 % Reisezeit: -0,271 % Wahrscheinlichkeit (vgl. Asensio, 2002) +5/+10 Minuten: -11,60 %/ -22,49 % MIV-Anteil (Ausgangswert: 67,8 % MIV-Anteil) (vgl. Eluru et al., 2012)	+ 1 % Reisezeit: Bus +0,296 % Wahrscheinlichkeit (vgl. Asensio, 2002) + 1 % Reisezeit: Zug +0,538 % Wahrscheinlichkeit (vgl. Asensio, 2002) +5/+10 Minuten: +5,20 %/ +10,07 % ÖV-Anteil (Ausgangswert: 21,4 % ÖV-Anteil) (vgl. Eluru et al., 2012)
ÖV	+ 1 % Reisezeit Bus: +0,021 % Wahrscheinlichkeit (vgl. Asensio, 2002) + 1 % Reisezeit Zug: +0,072 % Wahrscheinlichkeit (vgl. Asensio, 2002) -5/-10 Minuten: -11,51 %/ -21,68 % MIV-Anteil (Ausgangswert: 67,8 % MIV-Anteil) (vgl. Eluru et al., 2012)	+ 1 % Reisezeit Bus: Bus -0,504 % / Zug +0,119 % Wahrscheinlichkeit (vgl. Asensio, 2002) + 1 % Reisezeit Zug: Bus +0,207 %/ Zug -0,239 % Wahrscheinlichkeit (vgl. Asensio, 2002) -5/-10 Minuten: +5,15 %/ +9,71 % ÖV-Anteil (Ausgangswert: 21,4 % ÖV-Anteil) (vgl. Eluru et al., 2012)

Ton et al. (2019) untersuchen die Reisezeit in Relation zwischen Verkehrsmitteln und finden bei längeren Reisezeiten einen Modal Shift von aktiven Mobilitätsformen (Fahrradfahren und Zufußgehen) hin zum motorisierten Verkehr. Cervero et al. (2019) geben an, eine Änderung des Verhältnisses der Reisezeit zwischen Fahrrad und MIV von 1 (gleiche Reisezeiten) zu 2 (was bedeutet, dass das Fahrrad doppelt so lange braucht wie der MIV) sei mit einem Rückgang des Radverkehrs um 2,9 Prozent verbunden. Rietveld & Daniel (2004) vergleichen ebenfalls die Reisezeit mit dem Fahrrad und dem MIV und geben an, dass eine um 10 % kürzere Dauer mit Fahrrad im Vergleich zum MIV die Nutzung des Fahrrads um 3,4 % erhöhen würde (Ausgangswert: 35,1 % Fahrradanteil). Akar & Clifton (2009) untersuchen die Wahl des Verkehrsmittels zum Universitätscampus in Maryland (USA): Eine Verringerung der Reisezeit um 10 Minuten würde dazu führen, dass die Wahrscheinlichkeit, mit dem Fahrrad zu fahren, ausgehend von 5,1 % um 6 % steigen würde. Wochentage haben im Vergleich zum Wochenende einen positiven Effekt auf die Wahl des ÖV (1 Studie) und einen negativen Effekt auf das Zufußgehen (1 Studie, 1 Studie nicht signifikant). Vier Studien finden einen positiven Effekt auf die Anzahl an Radfahrenden. Im Gegensatz dazu zeigen Corcoran et al. (2014) einen positiven Effekt auf die Nutzendenzahlen von Bikesharing-Angeboten am Wochenende auf. Bei Ferien und Feiertagen wird die Anzahl an Studien geringer, die diese Einflussfaktoren betrachtet haben (jeweils 2 Studien). Die unterschiedlichen Vorzeichen bei den Effekten können auf die verwendete Datengrundlage zurückgeführt werden: Wessel (2020) berücksichtigt die Anzahl an Radfahrenden von Zählstellen, während Corcoran et al. (2014) Nutzendenzahlen von Bikesharing-Stationen verwenden. Wessel (2020) gibt an, offizielle Feiertage würden die Zahl der Radfahrenden um 54,3 %, Schulferien um 17,5 % und Semesterferien um 14,4 % verringern. Bei der Jahreszeit

finden zwei Studien einen positiven Effekt der Jahreszeiten Frühling, Sommer und Herbst auf den Radverkehrsanteil und eine Studie auf das Zufußgehen. Die Hauptverkehrszeit beziehen nur Ton et al. (2019) in die Analyse ein. Die Autor*innen finden einen negativen Effekt auf das Zufußgehen und keinen statistisch signifikanten Effekt auf das Radfahren. Die Ergebnisse dreier Studien deuten auf einen negativen Effekt von Dunkelheit auf das Radfahren hin. Der Effekt auf das Zufußgehen ist statistisch nicht signifikant (vgl. u. a. Cervero & Duncan, 2003).

Die folgenden Einflussfaktoren beschäftigen sich mit Wartezeiten. So hat eine steigende Parkplatzsuchdauer einen positiven Effekt auf die Wahl des Fahrrads (Parkin et al., 2008). Sämtliche mit dem ÖV in Verbindung zu bringende Wartezeiten, wie die Ankunftszeit des ÖV an der Haltestelle (2 Studien), zusätzliche Fußwege zur Haltestelle oder zum Zielort (3 Studien), die Anzahl der Umstiege (2 Studien) und die Wartezeit zwischen den Umstiegen (1 Studie) sowie der Takt des ÖV (1 Studie) haben bei Verschlechterung einen negativen Effekt auf die Wahl des ÖV als Verkehrsmittel. Die Verlagerung erfolgt zum Teil bei längeren Wartezeiten an der Haltestelle (1 Studie) und längeren Umsteige-Wartezeiten (2 Studien) auf den MIV.

Räumliche Merkmale

Neben der *Distanz* gehören die *Topographie*, infrastrukturelle Gegebenheiten (getrennt nach *Radinfrastruktur* und *Gehwegen*), die Flächennutzung (in den Dimensionen *Dichte*, *Vielfalt* und *Design*) sowie die *Naturumgebung* inklusive *Lautstärke- und Luftverschmutzung* zu den räumlichen Einflussfaktoren der Verkehrsmittelwahl. Die Distanz ist über die Geschwindigkeit hoch mit der Reisezeit korreliert. Dementsprechend ist der Einfluss der Reisedistanz auf die Verkehrsmittelwahl in den meisten Studien insbesondere für aktive Mobilitätsformen ebenfalls negativ (Fahrrad: 7 Studien, Zufußgehen: 2 Studien). Die folgenden Effektstärken in den vorliegenden Studien stellen keine Funktionen der Distanz da, sondern sind als mittlere Effekte über alle Beobachtungen zu betrachten. Für einen Anstieg der Pendelentfernung zur Arbeit um 1 %, nimmt die Wahrscheinlichkeit, den MIV zu wählen, um 0,040 % zu (vgl. Asensio, 2002). Für den Zug nimmt die Auswahlwahrscheinlichkeit um 0,261 % zu, während sie für den Bus um 1,066 % sinkt (vgl. ebd.). Die Streuung der Ergebnisse wird bei der Betrachtung des Fahrrads deutlich. Cervero et al. (2019) geben an, dass im Durchschnitt über alle Beobachtungen in der Studie der Fahrradanteil um 0,6 Prozentpunkte sinkt, wenn die Pendeldistanz um 1 km zunimmt. Die Studie enthält allerdings keine Aussage zur mittleren Distanz sowie zum mittleren Fahrradanteil. Die Ergebnisse von Flynn et al. (2012) zeigen eine Verringerung der Wahrscheinlichkeit, mit dem Fahrrad zu fahren, um etwa 8 % bei Zunahme der Entfernung um eine Meile (entspricht ca. 1,6 km) (Ausgangswert von 34,5 % Fahrradanteil). Auch diese Studie enthält keine Angabe zur durchschnittlichen Distanz der Wege. Pucher & Buehler (2006) finden bei einem Anstieg der mittleren Arbeitswegentfernung um 1 km einen verringerten Fahrradanteil um 0,029 Prozentpunkte (im Vergleich zu einem durchschnittlichen Fahrradanteil von 52 % bei Wegen zur Arbeit). Die Topographie hat in den untersuchten Studien einen negativen Effekt darauf, das Fahrrad (9 Studien, 2 nicht signifikant) oder das Zufußgehen (2 Studien) als Modus zu wählen. So zeigen die Ergebnisse von Cervero et al. (2009), dass eine Steigung von mehr als 3 % die Wahrscheinlichkeit, 30 Minuten oder mehr pro Wochentag im Alltag mit dem Fahrrad zu fahren, um 72 % senkt. Für das Zufußgehen verringert eine Steigung von mehr als 4 % die Wahrscheinlichkeit, an einem Wochentag 30 Minuten oder mehr im Alltag zu Fuß zu gehen, um 58 % (vgl. ebd.). Cervero et al. (2019) quantifizieren den Effekt der Zunahme der mittleren Steigung eines Radwegs um 1 Prozentpunkt mit einer Reduktion des Radverkehrsanteils um 1,8 Prozentpunkte.

Darüber hinaus beeinflusst die Infrastruktur die Moduswahl. So finden 13 Studien einen positiven Einfluss auf die Wahl des Fahrrads, wenn entsprechende Infrastruktur vorhanden ist oder verbessert wird. Wenn es pro Kilometer 0,25 weniger Hindernisse wie z. B. Pfosten gibt, erhöht sich der Anteil der Fahrradnutzung um 1,3 % ausgehend von einem Fahrradanteil von 35,1 % (vgl. Rietveld & Daniel, 2004). Gehwege haben als Infrastruktur einen positiven Effekt auf das Zufußgehen (vgl. Broach & Dill, 2016). Cervero (2002) findet keine statistisch signifikanten Effekte auf die Wahl des MIV und ÖV. Die Flächennutzung wird in der Literatur ebenfalls als Determinante der Moduswahl herangezogen. Sie wird in die Dimensionen Dichte, Vielfalt und Design unterteilt. Da die Effektrichtung je nach Studie und Untersuchungsgebiet variiert, wird im Rahmen des Berichts auf eine detaillierte Diskussion verzichtet. Verwiesen werden kann an dieser Stelle auf die Meta-Studie von Ewing & Cervero (2010), die mehr als 200 Studien zur gebauten Umwelt analysiert hat. Die Umgebung/Natur hat ebenfalls einen Einfluss auf die Moduswahl, wobei die Ergebnisse in den zugrundeliegenden Studien nicht eindeutig sind. Außerdem nennen Winters et al. (2011) Lautstärke und Luftverschmutzung als Hemmnisse, Fahrrad zu fahren.

Wetter

Der Einfluss des Wetters kann unterteilt werden in *Temperatur, Hitze, Schnee/Eis, Luftfeuchtigkeit, Regen, Windgeschwindigkeit, Bewölkung* und den Einfluss von *Unwetterwarnungen* bzw. dem *Wetterbericht*. In den vorliegenden Studien werden hauptsächlich signifikante Effekte auf die Wahl des Fahrrads festgestellt. Nur zwei der Studien konnten Effekte bei der Wahl des ÖV und eine Studie bei der Wahl des Zufußgehens feststellen. In 14 Studien führen steigende Temperaturen zu einer höheren Wahrscheinlichkeit, das Fahrrad als Verkehrsmittel zu wählen. In drei Studien hat die Temperatur keinen statistisch signifikanten Effekt. Brandenburg et al. (2007) diskutieren den Einfluss des Wetters getrennt für Pendelnde mit dem Fahrrad und Freizeit-Radfahrende. Während warme Temperaturen für beide Gruppen die Radfahranteile erhöhen, reagieren Freizeit-Radfahrende sensibler auf kalte Temperaturen und Regen. So geben Flynn et al. (2012) an, ein Anstieg der Temperatur um ein Grad Fahrenheit (entspricht 0,6 Grad Celsius) erhöhe die Wahrscheinlichkeit, mit dem Fahrrad zur Arbeit zu fahren, um etwa 3 % (Ausgangswert von 34,5 % der Fahrten zur Arbeit und durchschnittliche Temperatur 45,3 Grad Fahrenheit – entspricht 7,4 Grad Celsius). Die Studie wurde in Vermont, USA durchgeführt. Pucher & Buehler (2006) geben in einer kanadischen Studie an, ein Temperaturanstieg um ein Grad Celsius erhöhe den Fahrradanteil um 0,019 Prozentpunkte im Vergleich zu einem durchschnittlichen Fahrradanteil von 52 % bei Wegen zur Arbeit und einer durchschnittlichen Temperatur von 10,3 Grad Celsius. In drei Studien wird angegeben, der Zusammenhang gelte nur bis zu einem Schwellenwert, sodass bei Hitze die Radfahranteile wieder abnehmen würden. Bei Heaney et al. (2019) beträgt der Schwellenwert, ab dem die Anzahl an Nutzenden von Bikesharing-Angeboten rückläufig wird, 28,1 Grad Celsius. In der Studie von Wessel (2020) beträgt die Temperaturschwelle 29,5 Grad Celsius. Gebhart & Noland (2014) geben 32,2 Grad Celsius als Grenzwert an. Schnee und Eis hingegen sind Faktoren, die als Hemmnisse gesehen werden, mit dem Fahrrad zu fahren (7 Studien). So verringert ein Zoll (entspricht 2,54 cm) Schnee auf dem Boden die Wahrscheinlichkeit, mit dem Fahrrad zu fahren, um etwa 10 % (Ausgangswert: 34,5 % der Fahrten zur Arbeit) (vgl. Flynn et al., 2012).

Auch die Luftfeuchtigkeit hat einen negativen Effekt auf die Wahl des Fahrrads (3 Studien). Ausgehend von einer durchschnittlichen Luftfeuchtigkeit von 63,86 % führt eine Änderung der Luftfeuchtigkeit um 1 % zu einer Verringerung der Wege mit dem Fahrrad um 0,94 % (Ausgangswert sind durchschnittlich 122 Radfahrende pro Stunde) (vgl. Gebhart & Noland, 2014).

Neben der Wahl des Fahrrads (15 Studien) beeinflusst Regen auch die Wahl des ÖV und des Zufußgehens negativ (jeweils 1 Studie). So fahren Arbeitnehmende nahezu doppelt so häufig mit dem Fahrrad zur Arbeit, wenn es morgens nicht regnete (vgl. Flynn et al., 2012). Bei Pucher & Buehler (2006) reduziert ein Anstieg der Niederschlagsmenge um 1 cm den Fahrradanteil um 0,049 Prozentpunkte (im Vergleich zu einem durchschnittlichen Fahrradanteil von 52 % bei Wegen zur Arbeit). Gebhart & Noland (2014) geben an, dass 0,75 % weniger Fahrten stattfinden, wenn es regnet (Ausgangswert sind durchschnittlich 122 Radfahrende pro Stunde). Wessel (2020) identifiziert einen deutlich stärkeren Rückgang der gezählten Radfahrenden pro Stunde: Bei Regen in den letzten drei Stunden sinkt der Radverkehrsanteil um 24,2 % (durchschnittliche Anzahl an Radfahrenden pro Stunde in der Studie bei 140,9). Außerdem zeigen die Ergebnisse, dass fälschlicherweise vorhergesagter Regen die Fahrradnutzung um 3,6 % verringert (vgl. ebd.). Gegenteilig führe eine Vorhersage ohne Regen zu einer um 11,5 % höheren Zahl der Fahrradfahrenden bei Regen als bei einer korrekten Vorhersage des Regens (vgl. ebd.). Wird Regen nur für die Morgenstunden vorhergesagt, ist die Zahl der Radfahrenden für den ganzen Tag um 9,2 % niedriger (vgl. ebd.). Regenvorhersagen für die Mittagsstunden senken die Fahrradzahlen in geringerem Maße (5,2 %) (vgl. ebd.).

Flynn et al. (2012) untersuchen zusätzlich den Einfluss der Windgeschwindigkeit. Die Ergebnisse zeigen, dass eine Erhöhung der Windgeschwindigkeit um eine Meile pro Stunde (entspricht 1,6 km pro Stunde), die Wahrscheinlichkeit, mit dem Rad zu fahren, um etwa 5 % senkt. Wessel (2020) nimmt zusätzlich den Bewölkungsgrad als auch Unwetterwarnungen in die Analyse auf. Bei leichter Bewölkung in der Region der Fahrradzahlstation sinkt die stündliche Fahrradnutzung um 10,8 %, dunkle Wolken führen zu einem Rückgang um 18,9 %. Die Zahl der Fahrradfahrenden bei klarem Himmel ist um 4 % höher als bei einem vollständig bedeckten Himmel (vgl. ebd.). Wenn ein Wetterwarnsymbol für die Region der Zählstation angezeigt wird, gehen die stündlichen Fahrradfahrten um etwa 12,5 % zurück (vgl. ebd.).

Sonstige anlassbezogene Einflussfaktoren

Sonstige anlassbezogenen Einflussfaktoren umfassen die Anzahl an *Mitreisenden*, ob *Gepäck* transportiert werden muss, die *Auslastung* des Verkehrsmittels oder der genutzten Infrastruktur, verschiedene *Reisezwecke* wie Freizeit, Arbeit, Schule und Einkaufen und die *objektive Sicherheit*. Die Ergebnisse von Ton et al. (2019) belegen beispielsweise, dass bei Begleitung durch Mitreisende, die Wahrscheinlichkeit sinkt, den ÖV oder das Fahrrad zu nutzen. Das Zufußgehen wird wiederum attraktiver (vgl. ebd.). Winters et al. (2011) finden einen negativen Einfluss von Gepäck auf die Wahl des Fahrrads. Ein Hemmnis, den ÖV zu nutzen, ist eine steigende Auslastung (vgl. Wicki et al., 2019). Parkin et al. (2008) bestätigen diesen Zusammenhang auch für das Radfahren: Die Intensität der Mobilitätsnachfrage wird in der Analyse durch die Anzahl der Arbeitnehmenden pro Weglänge einbezogen und hat einen negativen Effekt auf die Wahl des Fahrrads. Cervero et al. (2019) geben an, eine Zunahme der Straßen mit sehr geringem Verkehrsaufkommen um 10 Prozentpunkte würde zu einer Zunahme des Radverkehrs um 0,65 Prozentpunkte führen. Eine Zunahme der Straßen mit geringem Verkehrsaufkommen um 10 Prozentpunkte, führe zu einem Anstieg des Radverkehrs um 0,73 Prozentpunkte (vgl. ebd.). Goldmann & Wessel (2021) finden hingegen keinen statistisch signifikanten Zusammenhang zwischen Staus und dem Radverkehrsanteil am Modal Split.

Einige Studien zeigen, dass die Determinanten und ihre Auswirkungen auf die Verkehrsmittelwahl je nach Reisezweck und Nutzersegment unterschiedlich sind. Cervero et al. (2009) bewerten

beispielsweise die Auswirkungen von Faktoren der gebauten Umwelt auf das Gehen und Radfahren im Alltag. Brandenburg et al. (2007) vergleichen Freizeit- und Pendelradfahrten in Wien anhand von Interviews vor Ort und Videoaufzeichnungen. Die deskriptiven Analysen zeigen, dass Freizeitradfahrende im Vergleich zu Pendelnden empfindlicher auf schlechtes Wetter reagieren. Während der Reisezweck Freizeit in vergleichsweise wenigen Studien explizit untersucht oder aufgenommen wird (u. a. Cervero & Duncan, 2003, Ton et al., 2019, Brandenburg et al., 2007), nutzt der Großteil der Studien Pendelfahrten (u. a. Broach & Dill, 2016, Ton et al., 2019, Hess, 2001, Heinen et al., 2010, Parkin et al., 2008, Pucher & Buehler, 2006, Rybarczyk & Wu, 2014, Santos et al., 2013, Wardman et al., 2007, Zhang, 2004 sowie Flynn et al., 2012). So muss bei der Übertragung angegebener Elastizitäten oder Effekte darauf geachtet werden, welche Stichprobe der jeweiligen Studie zugrunde liegt und ob diese mit dem betrachteten Anwendungsfall übereinstimmt.

Ein weiteres Merkmal ist die (objektive) Sicherheit. Sie wird in den Studien meist durch die Anzahl an Unfällen oder getöteten Personen im Straßenverkehr abgebildet. Rietveld & Daniel (2004) geben an, dass, wenn durchschnittlich in einem Zeitraum von vier Jahren eine Person pro eine Million Kilometer Radverkehrsinfrastruktur weniger Opfer eines schweren Unfalls wird, der Radverkehrsanteil um 1,1 % steigt (Ausgangswert: 35,1 %). Pucher & Buehler (2006) definieren den Effekt in die gegenteilige Richtung: Für jeden zusätzlichen im Straßenverkehr getöteten Radfahrenden pro 100.000 Radfahrende, sinkt der Radverkehrsanteil um 0,15 Prozentpunkte (Ausgangsniveau ist ein Fahrradanteil von 52 % bei Wegen zur Arbeit). Die Sicherheit hat einen zweifachen Einfluss auf die Wahl des Verkehrsmittels. Einerseits beeinflusst die objektive Sicherheit, gemessen an der Zahl der Todesopfer oder der Unfälle pro Jahr, die Wahl des Fahrrads (vgl. Cervero et al., 2009; Rietveld & Daniel, 2004, Goldmann & Wessel, 2021, Pucher & Buehler, 2006). Andererseits beeinflusst zusätzlich die subjektiv wahrgenommene Sicherheit die Entscheidung des Individuums, welches Verkehrsmittel gewählt wird.

Subjektive Einflussfaktoren

Zu den statistisch signifikanten subjektiven Determinanten in der Literatur gehören neben der *subjektiven Sicherheit, die Wahrnehmung, Zufriedenheit und Kultur* (z. B. Pucher et al., 1999 oder Wardman et al., 2007), *psychologische Determinanten, der Lebensstil* (z. B. Scheiner & Holz-Rau, 2007) sowie *Erfahrungen und Gewohnheiten* (u. a. Ton et al., 2019, Wicki et al. 2019). Krizek et al. (2009) zeigen beispielsweise, dass vom Kfz-Verkehr getrennte Radverkehrsanlagen als subjektiv sicherer wahrgenommen werden als eine Radverkehrsführung im Mischverkehr. Wahrgenommene staatliche Ausgaben für die Radverkehrsinfrastruktur können so den Fahrradanteil am Modal Split erhöhen (vgl. z. B. Dill & Carr, 2003). Rietveld & Daniel (2004) geben an, dass der Radverkehrsanteil um 0,05 % sinkt, wenn der Anteil unzufriedener Menschen mit dem Radverkehr um einen Prozentpunkt ansteigt. Kulturelle Unterschiede werden deutlich, wenn das Verhalten verschiedener Länder verglichen wird. Beispielsweise wird das Fahrrad in den USA hauptsächlich für Freizeitfahrten genutzt und weniger für alltägliche Wege (vgl. Pucher et al., 1999 sowie Pucher et al., 2011). Hunecke (2015) kategorisiert die psychologischen Determinanten der Verkehrsmittelwahl in Absichten/Kontrollüberzeugungen, Einstellungen, Normen und Werte. Ein Beispiel für Kontrollüberzeugungen ist die Nichtnutzung des MIV (vgl. Gardner & Abraham, 2008 und Hunecke et al., 2007): Personen, die den MIV nicht benutzen, sind subjektiv nicht davon überzeugt, dass sie ihn benutzen müssen. Wetterfestigkeit für Radfahrende ist eine weitere Überzeugung, die für die subjektive Überzeugung steht, auch bei schlechtem Wetter Rad fahren zu können (vgl. Haustein et al., 2007). Da subjektive Einflussfaktoren nur

schwierig in aggregierten Modellen der Verkehrsmodellierung wie dem klassischen Vier-Stufen-Modell integriert werden können, erfolgt keine tiefere Betrachtung subjektiver Faktoren.

3.3 Einflussfaktoren auf die Routenwahl

Die Einflussfaktoren auf die Routenwahl wurden unter der Bedingung recherchiert, dass das Fahrrad als Modus gewählt wurde. Abbildung 4 zeigt, welchen Kategorien die Einflussfaktoren bei der Routenwahl mit dem Fahrrad zugeordnet werden können: Soziodemografische und -ökonomische Merkmale, Fahrradart, zeitliche Merkmale, räumliche Merkmale und Wetter. Wie bei der Darstellung der Einflussfaktoren bei der Moduswahl lassen sich auch die Einflussfaktoren bei der Routenwahl mit dem Fahrrad nicht trennscharf den übergeordneten Kategorien zuordnen. Da es bei der Routenwahl nicht möglich ist, generalisierende Effektrichtungen (analog Tabelle 1) zu bestimmen, werden quantifizierbare Effekte aus den Studien beispielhaft angeführt. Die Angaben können als Test-Szenarien dazu genutzt werden, Verkehrsmodelle so zu kalibrieren, dass diese die Ergebnisse der Studien abbilden. Die daraus resultierenden Parametersätze können verglichen und als Spannen definiert werden, die für zukünftige Verkehrsmodelle verwendet werden können. Dieses Vorgehen und die Ergebnisse werden im weiteren Verlauf des Projekts anhand eines Use Cases für den Einflussfaktor Topographie demonstriert und dokumentiert. Tabelle 3 fasst die Ergebnisse am Ende des Kapitels zusammen.

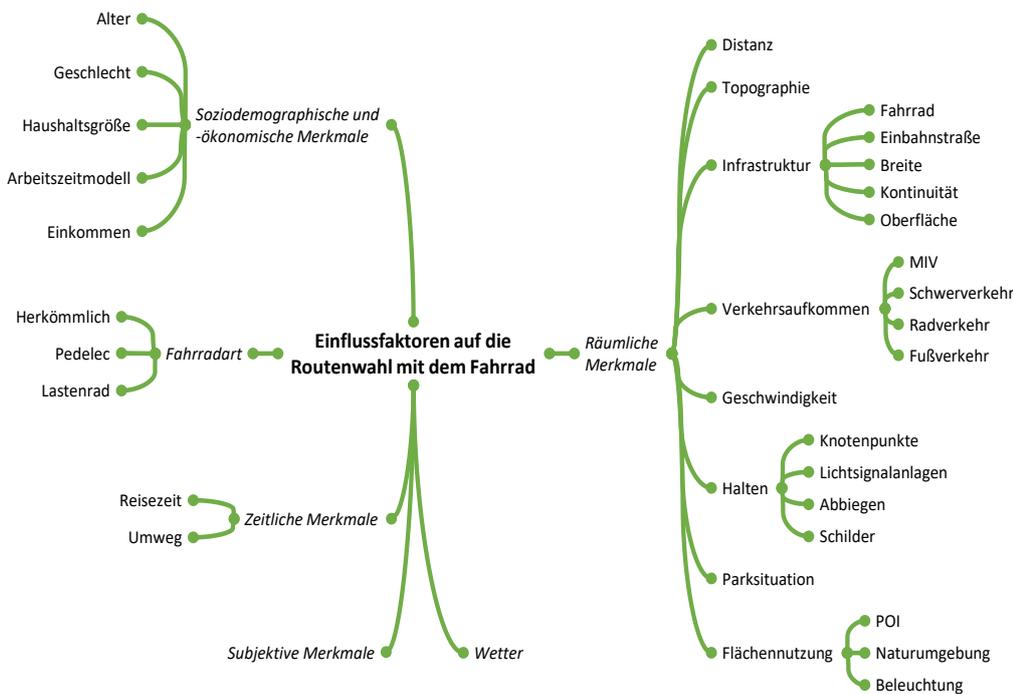


Abbildung 4: Einflussfaktoren bei der Routenwahl mit dem Fahrrad

Soziodemografische und -ökonomische Merkmale

Hinsichtlich der Merkmale von Personen und Haushalten weisen die Studien widersprüchliche Ergebnisse auf. Aldred et al. (2017) untersuchen in 54 Studien, ob die angegebenen Präferenzen für eine getrennte Fahrradinfrastruktur nach *Geschlecht und Alter* variieren. Neun Studien (36 %) belegen stärkere Präferenzen für eine Trennung vom motorisierten Verkehr für ältere Menschen, 13 (52 %) finden keine altersspezifischen Unterschiede, und drei (12 %) berichten, dass jüngere Menschen stärkere Präferenzen für getrennte Infrastruktur hätten (vgl. ebd.). In Bezug auf andere infrastrukturelle Präferenzen stellt Antonakos (1994) fest, dass Erfahrung mit dem Radfahren und

Alter negativ mit der Präferenz für Radwege, Fußwege und Straßen ohne Radinfrastruktur verbunden wären. Poorfakhraei & Rowangould (2015) belegen, dass die Präferenz für Radverkehrsanlagen gegenüber Straßen ohne Radinfrastruktur mit dem Alter zunehmen würde. Darüber hinaus berichten Bovy & Bready (1985), dass ältere Radfahrende bereit wären, mehr Reisezeit für eine bessere Streckenqualität zu opfern als jüngere. Sener et al. (2009) analysieren, dass junge Radfahrende (18-34 Jahre) empfindlicher auf die Reisezeit reagieren würden als ältere Radfahrende (35 Jahre oder älter). Im Freizeitradverkehr korreliert das Alter positiv mit der Bedeutung, die der Qualität des Straßenbelags und der Landschaft beigemessen wird, und negativ mit weniger Zwischenstopps, während beim Pendeln das Alter positiv mit der Berücksichtigung der Bequemlichkeit korreliert (vgl. Antonakos, 1994).

In Bezug auf geschlechtsspezifische Unterschiede finden Aldred et al. (2017) 23 Studien (58 %), in denen Frauen eine stärkere Präferenz für das Radfahren auf separater Radinfrastruktur offenbaren als im Mischverkehr Rad zu fahren. Von den Studien mit größeren Stichprobengrößen (> 100) und mindestens 20 % Nicht- oder Wenig-Radfahrenden finden 77 % (17) geschlechtsspezifische Unterschiede (vgl. ebd.). Bei Studien, die in Ländern mit geringem Radverkehrsaufkommen durchgeführt wurden, zeigen 69 % (20) geschlechtsspezifische Unterschiede, während 27 % (3) der Studien in Ländern mit mittlerem bis hohem Radverkehrsaufkommen Unterschiede feststellen (vgl. ebd.). Dies unterstreicht die Notwendigkeit, sowohl bei der Routenwahl als auch bei der Moduswahl das Untersuchungsgebiet der Studien zu berücksichtigen. Weitere Studien zeigen eine stärkere Präferenz von Frauen für Fahrradstraßen und -wege im Vergleich zur Führung im Mischverkehr (vgl. Antonakos, 1994; González et al., 2016; Vedel et al. 2017), Strecken in der Natur (vgl. Antonakos, 1994; Vedel et al. 2017) und Strecken mit wenigen Steigungen für den Arbeitsweg (vgl. Antonakos, 1994; Sener et al., 2009). Als quantifizierbare Angabe bedeutet dies, dass für Pendlerinnen, die lange Strecken mit dem Fahrrad zurücklegen und einen Pkw im Haushalt haben, die "willingness to cycle" für einen Radweg von 2 km auf 2,3 km ansteigt (vgl. Vedel et al., 2017). Eine Frau mit den genannten Merkmalen wäre bereit, 0,17 km zusätzlich zu der mittleren Entfernung von 0,9 km mit dem Fahrrad zu fahren, um eine Route mit grüner Umgebung zu erreichen (vgl. ebd.). Darüber hinaus wird festgestellt, dass Sicherheit, das Verhalten der MIV-Nutzenden, Fahrradsicherheitserziehung und Straßenschilder für Frauen wichtiger sind als für Männer (vgl. Antonakos, 1994). Bernardi et al. (2018) stellen fest, dass männliche Radfahrende längere Alternativen als weniger attraktiv wahrnehmen als weibliche.

Nur wenige Arbeiten (u. a. Clark et al., 2019; Krenn et al., 2014; Stinson & Bhat, 2003, Tilahun et al., 2007) untersuchen den Einfluss der *Arbeitszeit* (Vollzeit- vs. Teilzeitbeschäftigung), des *Einkommens* sowie des *Bildungsstands* als Determinanten für die Routenwahl und kommen zu widersprüchlichen Ergebnissen. Hinsichtlich der *Haushaltsgröße* geben Broach & Dill (2016) an, dass ein Umweg von 10 % (= im Mittel 53 m) nur dann gewählt wird, wenn man mit einem anderen Haushaltsmitglied unterwegs ist. Keine der vorliegenden Studien beinhaltet Angaben zur *Branche* der Befragten und weiterführende Informationen wie beispielsweise die *politische Einstellung*.

Fahrradart

Neben einer Differenzierung nach dem Individuum, das Fahrrad fährt, empfiehlt Hardinghaus (2021) auch eine Unterscheidung nach der Fahrradart. Alrutz et al. (2015), Dill & Rose (2012), Dozza et al. (2016), MacArthur et al. (2014) und Schleinitz (2014) vergleichen *Pedelecs* und

konventionelle Fahrräder miteinander. Sie stellen fest, dass Pedelec-Fahrende längere Strecken, direktere Strecken mit Steigungen und auch Strecken mit stärkerem Verkehr im Vergleich zu Radfahrenden mit konventionellen Fahrrädern wählen. Arning et al. (2023) präsentieren eine Übersicht über Verkehrsmodelle, die Pedelecs als Verkehrsmittel integrieren.

Zeitliche Merkmale

Die betrachteten Studien zeigen Einigkeit darüber, dass das zeitliche Merkmal *Reisezeit* bzw. das räumliche Merkmal *Entfernung* zu den wichtigsten Determinanten der Routenwahl gehören (z. B. Bovy & Bready, 1985; Broach et al., 2012; Caulfield et al., 2012; González et al., 2016; Hood et al., 2011). Im Sinne eines *Umwegs* fahren Radfahrende in einer Studie in Delft (Niederlande) durchschnittlich 1,37 km mehr als der kürzeste mögliche Alternativweg, was 15 % der Streckenlänge entspricht (vgl. Bovy & Bready, 1985).

Räumliche Merkmale

Für die Routenwahl mit dem Fahrrad können die meisten Einflussfaktoren räumlichen Merkmalen zugeordnet werden. Dazu zählen die Distanz, Topographie, Radinfrastruktur, das Verkehrsaufkommen (unterteilt in Kraftfahrzeuge, Schwerverkehr, Fahrradverkehr und Zu Fußgehende), parkende Fahrzeuge, Knotenpunkte, Abbiege- und Haltevorgänge, Verkehrssignalanlagen und Schilder, die Geschwindigkeit des angrenzenden Verkehrs, Brücken, Points of Interest (POI), Natur, Flächennutzung, Oberfläche der Fahrbahn, Breite der Fahrbahn, Kontinuität der Infrastruktur, Bahngleise, festgelegte Fahrradkorridore, Beschilderung, dichte Laternenbeleuchtung und Einbahnstraßen.

Wie bereits bei der Moduswahl erläutert, ist die *Distanz* mit der Reisezeit hoch korreliert. Der Anstieg um eine feste Entfernung, z. B. 1 km, wird dabei als umso kostspieliger empfunden, je kürzer die Strecke ist (vgl. Broach et al., 2012). Ein Anstieg der Entfernung um 1 % verringert die Wahrscheinlichkeit, eine Route zu wählen, um etwa 9 % für Pendelfahrten zur Arbeit außerhalb des Berufsverkehrs und 5 % für alle weiteren Fahrten (vgl. ebd.). Die durchschnittliche Routendistanz in der Studie beträgt 6 km für Pendel-Fahrten zur Arbeit und 3,5 km für Fahrten außerhalb des Berufsverkehrs. González et al. (2016) definieren den Effekt in Metern: Eine Verlängerung der Fahrtstrecke um 100 Meter bei gleichbleibenden anderen Routen führt zu einem Rückgang der Wahrscheinlichkeit um 18 %, dass diese Route gewählt wird. Die mittlere Distanz der Routen in der Studie beträgt 1,8 km.

Ein weiterer räumlicher Einflussfaktor ist die *Topographie*. Menghini et al. (2010) geben beispielsweise an, ein Anstieg der maximalen Steigung um 1 m pro 100 m wird wie eine Verlängerung der Distanz um 115 m empfunden. In der Studie wurden im Mittel Routen mit einer Steigung von 0,9 m/100 m und einer Distanz von 999 m gewählt. Prato et al. (2018) behaupten, dass Bergabfahren oder Fahren in flachem Terrain zu keiner Veränderung der Distanzwahrnehmung führen würde, während Bergauffahren mit dem Gefühl verbunden wäre, dass Entfernungen mit zunehmender Steigung als länger wahrgenommen werden. Ihre Ergebnisse zeigen, dass ein durchschnittlicher Höhengewinn:

- von über 5,0 % bedeutet, dass die Wahrnehmung der Entfernung etwa 4,9-mal so hoch ist, als wenn das Terrain flach wäre oder bergab ginge.
- zwischen 3,5-5,0 % bedeutet, dass die Wahrnehmung der Entfernung etwa 2,1-mal so hoch ist, als wenn das Terrain flach wäre oder bergab ginge.

- von über 1,0-3,5 % bedeutet, dass die Wahrnehmung der Entfernung etwa 1,8-mal so hoch ist, als wenn das Terrain flach wäre oder bergab ginge.

Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang und hatten folgende Distanzen in Längenkategorien: Steigung 0-10 m/km: 0,004 km, Steigung 10-35 m/km: 0,009 km, Steigung 35-50 m/km: 0,002 km, Steigung >50 m/km: 0,003 km. Die oben genannten Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km, da dieser Wert im Modell fixiert wurde, um die Ergebnisse als Substitutionsraten interpretieren zu können. Broach et al. (2012) haben drei abweichende Kategorien mit durchschnittlicher Steigung von 2-4 % (10 % der Routen), 4-6 % (3 % der Routen) und 6 % (2 % der Routen) verwendet. Ihr Modell zeigt, dass Radfahrende bereit wären, im flachen Gelände:¹

- 2,8 km (2,2 km Pendeln) zu fahren, wenn die Alternative 1,6 km mit 2-4 % Steigung wäre.
- 6,3 km (3,5 km Pendeln) zu fahren, wenn die Alternative 1,6 km mit 4-6 % Steigung wäre.
- 19,4 km (6,8 km Pendeln) zu fahren, wenn die Alternative 1,6 km mit 6 % Steigung wäre.

Die mittlere Distanz der Routen in der Studie beträgt 7,2 km bei einer mittleren Steigung von 1,01 m pro 100 m. Hood et al. (2011) differenzieren keine Steigungsklassen, sondern berücksichtigen die absolute Steigung und geben an, dass der durchschnittliche Radfahrende es vermeiden würde, einen 10 m hohen Hügel zu befahren, solange der Umweg weniger als 0,59 km beträgt. Die durchschnittliche Distanz der Routen in der Studie beträgt 3,59 km bei einer durchschnittlichen Steigung von 8 m pro 100 m. Insbesondere bei der letzten aufgeführten Studie ist das Untersuchungsgebiet von San Francisco ausschlaggebend für die vergleichsweise hohen Steigungen.

Die *Infrastruktur* im Sinne der Führungsform des Radverkehrs beeinflusst ebenfalls die Wahl einer Route mit dem Fahrrad. Bovy & Bradley (1985) vergleichen die Verbesserung vom Zustand „keine Radinfrastruktur vorhanden“ zu „separater Radweg vorhanden“. Die durchschnittliche Fahrtdauer in der Studie beträgt neun Minuten. Die Infrastrukturverbesserung würde einen Fahrzeitverlust von etwa 3 Minuten ausgleichen. Die Untersuchungen werden in der Studie auf zeit- bzw. komfortsensitive Radfahrende ausgeweitet. Die Autor*innen untersuchen zudem Radfahrende unter 40 Jahre und über 40 Jahre. Broach et al. (2012) unterscheiden zwischen Pendelfahrten und Fahrten zu anderen Fahrtzwecken. Infrastrukturell unterscheiden sie zwischen Radwegen, die vom Mischverkehr getrennt sind, und sog. „Bike Boulevards“. Dabei handelt es sich um Wohnstraßen mit verkehrsberuhigenden Maßnahmen zur Verringerung der Geschwindigkeit und des Verkehrsaufkommens des Kfz-Verkehrs (z. B. durch Bodenschwellen, Einbahnstraßenregelung für Autos, Poller usw.), wobei Fahrrädern Vorrang an Kreuzungen gewährt wird und Querungshilfen an verkehrsreichen Kreuzungen vorhanden sind (vgl. ebd.). Die durchschnittliche Länge der Wege in der Studie beträgt 4,3 Meilen (entspricht 6,9 km). Die Ergebnisse werden als Gegenwert einer Fahrstreckenverringerung angegeben. Die empfundene Verringerung beträgt bei Benutzung eines:

- Bike Boulevards für Alltagsfahrten 17,9 %,
- Bike Boulevards für Pendelfahrten 10,8 %,
- Baulich getrennten Radwegs für Alltagsfahrten 26,0 %,
- Baulich getrennten Radwegs für Pendelfahrten 16,0 %.

¹ Anmerkung: Werte von Meilen in km umgerechnet.

Hood et al. (2011) berechnen in ihrer Studie distanzabhängige Substitutionsraten für baulich angelegte Radwege (gemeinsame Nutzung mit Zufußgehenden), Radfahrstreifen und Radfahren im Mischverkehr (mit Schildern und Fahrbahnmarkierung). Die durchschnittliche Länge der Routen in der Studie beträgt 3,59 km. Davon sind im Mittel 0,04 % baulich angelegte Radwege, 0,28 % Radfahrstreifen und 0,24 % eine Radverkehrsführung im Mischverkehr. Die Autor*innen geben an, Radfahrende empfinden im Vergleich zu einer Route ohne Radinfrastruktur 1 km...:

- ... auf einem Radfahrstreifen zu fahren wie die Reduktion der Distanz um 0,51 km.
- ... auf einem baulich angelegten Radweg mit geteilter Nutzung mit Zufußgehenden zu fahren wie die Reduktion der Distanz um 0,43 km.
- ... im Mischverkehr (mit Schildern und Fahrradpiktogrammen auf der Straße) zu fahren wie die Reduktion der Distanz um 0,08 km.

González et al. (2016) beschreiben den Effekt der Radinfrastruktur auf die Routenwahl als Elastizität: Eine Erhöhung des Radwege-Anteils einer Route um 1 % führt zu einem Anstieg der Wahrscheinlichkeit, dass die Nutzenden die Route wählen, um 3 %. In der Studie liegt die durchschnittliche Länge der Routen bei 1,8 km und der mittlere Anteil der Radwege an einer Route bei 31 %.

Prato et al. (2018) zeigen, dass die Benutzung eines Radwegs in der Hauptverkehrszeit wie eine Verringerung der Fahrtstrecke um 24,9 % empfunden wird, verglichen mit einem km ohne Radinfrastruktur. Die Verringerung in der Nebenverkehrszeit beträgt 19,5 % (vgl. ebd.). Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang. Die oben genannten Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km, da dieser Wert im Modell fixiert wurde, um die Ergebnisse als Substitutionsraten interpretieren zu können.

Neben der Art der Infrastruktur spielt auch die *Oberfläche* der Fahrbahn, die *Breite* der Fahrbahn und die *Kontinuität* der Radinfrastruktur eine Rolle. Hinsichtlich der Oberfläche geben Bovy & Bradley an, dass bei einer durchschnittlichen Fahrtdauer von 9 Minuten eine Verbesserung von einer rauen zu einer mittleren Oberflächenqualität einen Umweg von 3 Minuten ausgleichen könne. Eine Verbesserung von einer mittleren Qualität zu einer glatten Oberfläche würde einen Umweg von 2,4 Minuten kompensieren (vgl. ebd.). Prato et al. (2018) geben an, dass eine nicht asphaltierte Route als 21,2 % länger wahrgenommen wird als 1 km asphaltierte Route. Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang. Davon waren 3,7 km asphaltiert, 0,09 km nicht asphaltiert und 0,006 km Kopfsteinpflaster. Die oben genannten Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km, da dieser Wert im Modell fixiert wurde, um die Ergebnisse als Substitutionsraten interpretieren zu können. Keine der untersuchten Studien hat explizit aufgenommen, ob Straßenbahn- oder U-Bahn-*Schienen* einen Einfluss auf die Wahl der Route haben. Obgleich ist aus aktuellen Studien bekannt, dass Schienen das Risiko von Alleinunfällen mit dem Fahrrad statistisch signifikant erhöhen (vgl. Schüller et al., 2023). Sener et al. (2009) haben zusätzlich aufgenommen, wie breit die Radinfrastruktur ist. Die Autor*innen finden keine statistisch signifikante Vorliebe für den breiteren Radweg, sondern insgesamt eine Präferenz für die Fahrt im Mischverkehr (vgl. ebd.). Sie argumentieren dahingehend, die Befragten seien erfahrene Radfahrende mit einer entsprechenden Mentalität auf der Straße zu fahren, und dass die Präferenzen von unerfahrenen Radfahrenden sowie Nicht-Radfahrenden von den Ergebnissen abweichen könnten.

Die Kontinuität der Radinfrastruktur hat in derselben Studie einen statistisch signifikanten Einfluss: Pendelnde (mit durchschnittlichen Strecken < 5 Meilen (etwa 8 km) bzw. > 5 Meilen)

sind bereit, 12,63 bzw. 17,37 Minuten länger mit dem Fahrrad zu fahren, wenn eine ununterbrochene Radinfrastruktur vorhanden ist (vgl. ebd.). Stinson & Bhat (2003) belegen ebenfalls die Präferenz für eine kontinuierliche Infrastruktur, ohne eine Elastizität zu berechnen. Keine der vorliegenden Studien hat den Einfluss kontinuierlicher Radkorridore oder von Radschnellwegen einbezogen. *Brücken* wurden als Attribut bei Broach et al. (2012), Stinson & Bhat (2003) sowie Prato et al. (2018) untersucht. Für Alltagsfahrten entspricht eine Brücke mit Radfahrstreifen einer Entfernungsverringerung von 29,3 % bis zu 44,9 %, wenn die Radinfrastruktur getrennt vom motorisierten Verkehr ist (vgl. Broach et al., 2012). Der Vergleichsfall ist eine Brücke ohne Radverkehrsanlage. Die wahrgenommene Reduktion der Distanz für Pendelnde mit dem Fahrrad entspricht 18,2 % für die Brücke mit Radfahrstreifen bzw. 29,2 % für die Brücke mit getrennter Infrastruktur vom motorisierten Verkehr (vgl. ebd.). Die Autor*innen weisen allerdings darauf hin, dass nur sehr wenige Fahrten auf Brücken ohne Radverkehrsanlage in der Studie beobachtet werden konnten. Die Ergebnisse von Prato et al. (2018) vergleichen dezidierte Brücken für Radfahrende (durchschnittlich 0,002 km der gewählten Routen) mit Brücken, die im Mischverkehr von Radfahrenden gewählt werden können (durchschnittlich 0,015 km der gewählten Routen). Erstere führen dazu, dass Radfahrende die Distanz als 288 % kürzer wahrnehmen, während letztere die wahrgenommene Distanz um 128 % erhöhen (vgl. ebd.). Die Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km. Stinson & Bhat (2003) geben an, Radfahrende seien bereit, etwa 10 % zusätzliche Fahrzeit in Kauf zu nehmen (bei einer durchschnittlichen Fahrzeit von 21 Minuten), um Routen mit einer Radverkehrsanlage an Brücken zu nutzen, im Gegensatz zu Routen ohne Radverkehrsanlage an Brücken.

Einbahnstraßen sind ebenfalls ein Einflussfaktor auf die Routenwahl. Radfahrende in San Francisco fahren beispielsweise nur dann in die falsche Richtung einer Einbahnstraße, wenn sie dadurch im Durchschnitt mehr als die vierfache Strecke sparen (vgl. Hood et al., 2011). Die durchschnittliche Distanz der Routen in der Studie beträgt 3,6 km. Davon sind 2 % Einbahnstraßen. Prato et al (2018) geben für Radfahrende in Kopenhagen an, eine Strecke von 1 km würde als 241,2 % länger empfunden, wenn die Radfahrende sich dafür entscheiden würden, mit dem Fahrrad gegen den motorisierten Verkehr in einer Einbahnstraße zu fahren. Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang. Im Schnitt sind 0,070 km Einbahnstraße. Die Standardabweichung der Variable impliziert, dass 6,6 % der Radfahrenden Abkürzungen bevorzugen, bei denen sie in die falsche Richtung einer Einbahnstraße fahren (vgl. ebd.). Alrutz et al. (2002) haben die Anzahl an Radfahrenden in Einbahnstraßen deskriptiv ausgewertet. Die Autor*innen geben an, dass im Mittel 40–45 % der Radfahrenden in freigegebenen Einbahnstraßen in der Gegenrichtung fahren würden. Dieser Anteil sei in nicht geöffneten Einbahnstraßen nur unwesentlich geringer. Allerdings würden dann mehr Radfahrende in der Gegenrichtung die Gehwege nutzen (60 % gegenüber etwa 20 % in freigegebenen Einbahnstraßen). Dhakal et al. (2018) sowie Shah & Cherry (2021) argumentieren, dass erfahrene Radfahrende Einbahnstraßen häufiger in Gegenrichtung befahren als Radfahrende, die nur gelegentlich mit dem Fahrrad fahren. Segadilha & Sanches (2014) bewerten hingegen Einbahnstraßen als den am wenigsten wichtigen Faktor bei der Routenwahl.

Die Unterscheidung zwischen Hauptverkehrszeit und Nebenverkehrszeit impliziert ein unterschiedlich hohes *Verkehrsaufkommen*. Diese Einflussgröße wurde in den vorliegenden Studien bei motorisierten Verkehrsmitteln nicht weiter untergliedert. Eine Trennung nach *Kraftfahrzeug* und *Schwerverkehr* wird in der Modellierung allerdings zum Teil bereits

berücksichtigt (vgl. Teil I Kapitel 2). So geben beispielsweise Bovy & Bradley (1985) an, bei einer durchschnittlichen Fahrtdauer von 9 Minuten könne eine Verbesserung von starkem zu mittlerem Verkehr einen Umweg von 2,6 Minuten ausgleichen. Eine Verbesserung von durchschnittlichem zu leichtem Verkehr könne einen Umweg von 1,1 Minuten kompensieren (vgl. ebd.). Sener et al. (2009) bewerten den Effekt des Verkehrsaufkommens auf die Routenwahl mit dem Fahrrad ebenfalls mit Minutenangaben: Pendelnde (mit durchschnittlichen Strecken < 5 Meilen (etwa 8 km) bzw. > 5 Meilen) sind bereit, 10,68 bzw. 31,29 Minuten länger mit dem Fahrrad zu fahren, wenn das Verkehrsaufkommen gering im Vergleich zu einem mittleren oder hohen Verkehrsaufkommen ist. Allerdings beinhaltet die Studie keine Angabe zur durchschnittlichen Wegelänge und zur Höhe des Verkehrsaufkommens.

Prato et al. (2018) quantifizieren den Effekt über die Anzahl der Spuren für den motorisierten Verkehr. Den Vergleichsfall bildet eine Straße mit zwei Spuren. Wenn eine Route statt zwei Spuren für den motorisierten Verkehr:

- nur eine hat, wird sie um 139 % kürzer wahrgenommen,
- drei bis vier Spuren hat, wird sie um 23,4 % länger wahrgenommen,
- fünf oder mehr Spuren hat, wird sie 44,9 % länger wahrgenommen.

Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang. Die oben genannten Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km, da dieser Wert im Modell fixiert wurde, um die Ergebnisse als Substitutionsraten interpretieren zu können. Im Schnitt hatten die Routen 0,010 km einspurige, 2,937 km zweispurige, 0,045 km dreispurige, 0,262 km vierspurige, 0,047 km fünfspurige, 0,086 km sechsspurige und 0,007 km achtspurige Straßen.

Broach et al. (2012) nutzen mit der täglichen Anzahl der Fahrzeuge das tatsächliche Verkehrsaufkommen als Variable. Straßen ohne Radwege mit 10.000-20.000 Fahrzeugen pro Tag machen 8 % der Routen aus, Straßen ohne Radwege mit 20.000-30.000 Fahrzeugen pro Tag 4 % und Straßen ohne Radwege mit mehr als 30.000 Fahrzeugen pro Tag 2 %. Die durchschnittliche Länge der Wege in der Studie beträgt 4,3 Meilen (entspricht 6,9 km). Die Ergebnisse werden als prozentuale Umwege angegeben. Ihre Ergebnisse für Pendelfahrten lauten: Straßen ohne Radweg mit einem Verkehrsaufkommen...

- ... von 10.000-20.000 Fahrzeugen pro Tag, werden nur genutzt, wenn die verkehrsärmeren Alternativen einen Umweg von 36,8 % erfordern.
- ... von 20.000-30.000 Fahrzeugen pro Tag, werden nur genutzt, wenn die verkehrsärmeren Alternativen einen Umweg von 140,0 % erfordern.
- ... von > 30.000 Fahrzeugen pro Tag, werden nur genutzt, wenn die verkehrsärmeren Alternativen einen Umweg von 715,7 % erfordern.

Ihre Ergebnisse für alle anderen Alltagsfahrten lauten: Straßen ohne Radweg mit einem Verkehrsaufkommen...

- ... von 10.000-20.000 Fahrzeugen pro Tag, werden nur genutzt, wenn die verkehrsärmeren Alternativen einen Umweg von 22,3 % erfordern.
- ... von 20.000-30.000 Fahrzeugen pro Tag, werden nur genutzt, wenn die verkehrsärmeren Alternativen einen Umweg von 137,3 % erfordern.
- ... von > 30.000 Fahrzeugen pro Tag, werden nur genutzt, wenn die verkehrsärmeren Alternativen einen Umweg von 619,4 % erfordern.

Insbesondere für Straßen mit dem Verkehrsaufkommen von > 30.000 Fahrzeugen pro Tag stellen die Autor*innen ihre Ergebnisse in Frage. Sie vermuten, es sei unwahrscheinlich, dass Radfahrende tatsächlich eine siebenmal längere Route wählen würden, um eine Straße mit hohem Verkehrsaufkommen und ohne Radweg zu vermeiden. Es wäre wahrscheinlicher, dass überhaupt nicht mit dem Rad gefahren werden würde (vgl. ebd.).

Das *Verkehrsaufkommen* von anderen *Fahrradfahrenden* oder *Zufußgehenden* wurde nur von Vedel et al. (2017) untersucht. Der durchschnittliche Radfahrende in der Studie ist bereit, 1,03 km mehr zu fahren, um das Verkehrsaufkommen von anderen Radfahrenden zu reduzieren. Allerdings werden in der Studie keine Mittelwerte für die durchschnittlichen Distanzen angegeben, da es sich um Daten aus Entscheidungsexperimenten handelt. Die Entfernung im Entscheidungsexperiment (zwischen 3,5 und 7 km) basiert auf der Distanz, die die Befragten beim letzten Mal mit dem Fahrrad auf der Pendelstrecke zur Arbeit zurückgelegt haben (Stufen 1: < 5 km (12 %); 2: 5-10 km (29 %); 3: 10-15 km (24 %); 4: 15-20 km (18 %); 5: >20 km (17 %)). Die Befragten in der Studie bevorzugen von Radfahrenden und Zufußgehenden gemeinsam genutzte Infrastruktur und wären bereit, im Schnitt 0,67 km zusätzlich zu fahren, um diese zu benutzen (vgl. ebd.).

Neben dem Verkehrsaufkommen spielen auch die *Geschwindigkeit des angrenzenden Verkehrs* bzw. *Geschwindigkeitsbegrenzungen* eine Rolle bei der Routenwahl. So sind Pendelnde in der Studie von Sener et al. (2009) bereit, etwa 10,91/22,93 Minuten länger mit dem Fahrrad zu fahren, wenn die Geschwindigkeitsbegrenzung langsam wäre (<20 km/h) im Vergleich zu einer moderaten Geschwindigkeitsbegrenzung von 20-35 km/h oder einer hohen Geschwindigkeitsbegrenzung von mehr als 35 km/h.

Drei Studien haben die *Parksituation* in ihren Analysen berücksichtigt. Dabei werden *Fahrradabstellanlagen* am Zielort und *Kfz-Parkstände* entlang der Route unterschieden. Hunt & Abraham (2007) geben an, sichere Fahrradabstellanlagen am Zielort hätten die gleiche Auswirkung auf den Nutzen wie eine Verringerung der Zeit um 26,5 Minuten, die auf einer Straße im Mischverkehr verbracht wird. Allerdings sind keine Angaben zur durchschnittlichen Wegedauer oder Distanz vorhanden, sodass eine Einordnung der Ergebnisse nicht weiter erfolgen kann. Tilahun et al. (2007) finden in einem Entscheidungsexperiment heraus, dass im Vergleich zu einer 20-minütigen Route im Mischverkehr, eine Alternative ohne Parkstände entlang der Route wie 9,27 Minuten Reisezeit empfunden wird.

Die Ergebnisse von Torrance et al. (2007) basieren ebenfalls auf einem Entscheidungsexperiment. Von den 1.863 Befragten geben 46,3 % an, zur Arbeit zu pendeln und 53,7 % das Fahrrad im Alltag zu verwenden. Die Pendelnden legen durchschnittlich 6,88 Meilen (entspricht 11,1 km) bis zur Arbeit zurück. Die Autor*innen unterscheiden zusätzlich, ob die Pendelnden kurze Distanzen (<5 Meilen (etwa 8 km)) zurücklegen (52 % der Pendelnden) oder mehr als 5 Meilen (48 % der Pendelnden). In ihrem Bericht geben sie Elastizitäten von Maßnahmen an, die sich auf den Anteil der Alltags-Radfahrenden, Pendelnden und insgesamt auf den Anteil der Radfahrenden auswirken. Die im Paper veröffentlichten Ergebnisse (vgl. Sener et al., 2009) zeigen, dass Pendelnde mit kurzer Strecke zur Arbeit (< 5 Meilen (etwa 8 km))/mit langer Strecke zur Arbeit (> 5 Meilen) bereit wären, im Mittel mit dem Fahrrad

- 6,21/9,59 Minuten länger zu fahren, um parallelparkende Fahrzeuge zu vermeiden.
- 2,79/6,18 Minuten länger zu fahren, um schrägparkende Fahrzeuge zu vermeiden.
- 3,88 Minuten länger zu fahren, wenn die Länge der Parkstände auf der gewählten Route weniger als 2 Häuserblocks betragen würde.

Pendelnde wären bereit, etwa 3,88/13,10 Minuten mehr mit dem Fahrrad zu fahren, wenn die Länge der Parkstände auf der gewählten Route weniger als 2 Häuserblocks betragen würde, im Vergleich zu einer mittleren Länge von 2-4 Häuserblocks/einer langen Länge von 5-7 Häuserblocks. Pendelnde hingegen wären bereit, 4,26/14,10 Minuten länger mit dem Fahrrad zu fahren, wenn die Parkplatzauslastung auf der gewählten Strecke weniger als 26 % betragen würde, verglichen mit einer mittleren Auslastung von 26-75 %/einer hohen Auslastung von 76 %-100 %. Den Befragten wurden in Abhängigkeit ihrer angegebenen Distanz zur Arbeit unterschiedliche Wegedauern vorgeschlagen. Aggregiert gibt es allerdings keine Angabe zur durchschnittlichen Wegedauer.

Weitere Einflussfaktoren sind Wartezeiten durch *Halten* z. B. an *Knotenpunkten* oder durch *Abbiegungen*. Broach et al. (2012) beziffern den Gegenwert eines zusätzlichen Abbiegevorgangs pro Meile (0,6 Abbiegevorgänge/km) mit einer gefühlten Verlängerung der Strecke um 7,4 % für Alltags-Radfahrende und 4,2 % bei Pendelnden. Die durchschnittliche Länge der Wege in der Studie beträgt 4,3 Meilen (6,9 km) mit 3,64 Abbiegevorgängen pro Meile (2,26 pro km). Hood et al. (2011) geben an, der durchschnittliche Radfahrende würde ein Abbiegen vermeiden, wenn es nicht mehr als 0,17 km kostet. Die durchschnittliche Länge der Wege in der Studie beträgt 3,6 km mit 1,63 Abbiegevorgängen pro km. Prato et al. (2018) unterscheiden zusätzlich zwischen Linksabbiegen, Rechtsabbiegen und der Durchfahrt durch einen Kreisverkehr. Während das Linksabbiegen im Durchschnitt als ein Umweg von 423 m und ein Rechtsabbiegen als ein Umweg von 221 m wahrgenommen wird, verringert ein Kreisverkehr die Entfernung gefühlt um 12,9 %. Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang und haben 0,5 Kreisverkehre, 3,0 Linksabbiege- und 2,7 Rechtsabbiegevorgänge. Die oben genannten Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km, da dieser Wert im Modell fixiert wurde, um die Ergebnisse als Substitutionsraten interpretieren zu können. In der Studie von Vedel et al. (2017) sind Radfahrende bereit, etwa 1,33 km länger zu fahren, um von einer Route mit drei Halten auf eine Route ohne Halten zu wechseln (keine Angabe zur durchschnittlichen Routenlänge in der Studie enthalten). Für weitere Details zur Differenzierung zwischen signalisierten und nicht signalisierten Knoten siehe Broach et al. (2012).

Lichtsignalanlagen und *Schilder* stellen ebenfalls räumliche Faktoren dar, die das Radfahren beeinflussen. Eine Lichtsignalanlage pro Meile (mit Ausnahme von Rechtsabbiegen) (0,6 pro km) entspricht beispielsweise einem Umweg von 3,6 % für Alltags-Radfahrende und 2,1 % für Pendelnde. Durchschnittlich haben die Routen in dieser Studie 1,84 Lichtsignalanlagen pro Meile (1,14 pro km) und einer durchschnittlichen Distanz von 4,3 Meilen (entspricht 6,9 km) (vgl. Broach et al., 2012). Prato et al. (2018) geben an, dass ein Knoten mit Lichtsignalanlage, die wahrgenommene Länge der Route um 20,8 % verlängert. Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang und haben 7,9 Lichtsignalanlagen. Die oben genannten Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km, da dieser Wert im Modell fixiert wurde, um die Ergebnisse als Substitutionsraten interpretieren zu können.

Darüber hinaus wird die Routenwahl auch von der gebauten Umwelt beeinflusst. Dazu zählen insbesondere *POI*, *Flächennutzung*, *Natur* entlang der Route, *Beleuchtung* etc. So ist der durchschnittliche Radfahrende in der Studie von Skov-Petersen et al. (2018) bereit, pro prozentuale Zunahme der Route auf einer Einkaufsstraße 17,1 m weniger zurückzulegen. Dies widerspricht dem Ergebnis von Vedel et al. (2017), die angeben, der durchschnittliche Radfahrende sei bereit, 0,94 km mehr zu fahren, wenn eine Einkaufsstraße vorhanden ist. In einem zweiten Modell differenzieren Skov-Petersen et al. (2018), ob der Start- und Endpunkt in einer

Einkaufsstraße liegt und finden dort einen positive „willingness to cycle“, wenn eine Route in einer Einkaufsstraße beginnt. Da beide Studien das Routenwahlverhalten pendelnder Radfahrender in Kopenhagen untersuchen, können die Unterschiede in den Ergebnissen womöglich auf unterschiedlichen Datengrundlagen (GPS-Tracking vs. Stated-Preference-Befragung) zurückgeführt werden. Die Studien zeigen auch in Hinblick auf die Natur entlang der Route abweichende Ergebnisse. Vedel et al. (2017) geben an, der durchschnittliche Radfahrende sei bereit, 0,80 km mehr zu fahren, wenn eine grüne Umgebung vorhanden ist. Der durchschnittliche Radfahrende bei Skov-Petersen et al. (2018) hat im Gegensatz dazu eine negative „willingness to cycle“, wenn der Anteil grüner Umgebung zunimmt. Prato et al. (2018) vergleichen eine Route durch eine Wohngegend und durch Natur miteinander. Die Autor*innen differenzieren zusätzlich, ob die Umgebung nur auf der rechten Seite der Route oder auf beiden Seiten vorhanden ist sowie eine geringe bzw. moderate bis hohe Temperatur. Das Modell zeigt, dass die Radfahrenden in der Studie Natur entlang der Route vorziehen, wenn die Temperaturen moderat bis hoch sind, unabhängig davon, ob die Natur nur auf der rechten Seite oder auf beiden Seiten vorhanden ist. So ist die empfundene Distanz im Vergleich zu einem 1 km im Wohngebiet um...

- ...18,3 % länger, wenn das landschaftliche Gebiet auf der rechten Seite vorhanden ist und die Temperatur niedrig (< 5 Grad Celsius) ist.
- ...47,8 % länger, wenn das landschaftliche Gebiet auf beiden Seiten der Route vorhanden ist und die Temperatur niedrig (< 5 Grad Celsius) ist.
- ...33,0 % kürzer, wenn das landschaftliche Gebiet auf der rechten Seite vorhanden ist und die Temperatur moderat bis hoch (> 5 Grad Celsius) ist.
- ...38,3 % kürzer, wenn das landschaftliche Gebiet auf beiden Seiten der Route vorhanden ist und die Temperatur moderat bis hoch (> 5 Grad Celsius) ist.

Prato et al. (2018) haben die Routenwahl auch für Routen durch Industriegebiete untersucht. Die empfundene Distanz im Vergleich zu einem 1 km im Wohngebiet ist um...

- ...23,5 % länger, wenn das Industriegebiet auf der rechten Seite vorhanden ist.
- ...35,3 % länger, wenn das Industriegebiet auf beiden Seiten vorhanden ist.

Die gewählten Routen in der Studie sind durchschnittlich 3,8 km lang. Im Schnitt ist bei 0,185 km landschaftliches Gebiet auf der rechten Seite zu sehen und bei 0,095 km auf beiden Seiten. Ein Industriegebiet auf der rechten Seite ist bei 0,251 km und auf beiden Seiten bei 0,164 km zu sehen. Das Wohngebiet befindet sich bei durchschnittlich 0,509 km auf der rechten und bei 0,787 km auf beiden Seiten. Die oben genannten Ergebnisse beziehen sich auf eine durchschnittliche Streckenlänge von 1 km, da dieser Wert im Modell fixiert wurde, um die Ergebnisse als Substitutionsraten interpretieren zu können. Chen et al. (2018) haben die Dichte der Laternenbeleuchtung in ihre Untersuchungen aufgenommen und finden positive Effekte, wenn die Straßenbeleuchtungsichte um 1 % zunimmt. Da die Effekte allerdings sehr spezifische Szenarien beinhalten, werden sie an dieser Stelle nicht detaillierter diskutiert.

Das *Wetter* wurde als Einflussfaktor auf die Routenwahl nur bei Prato et al. (2018) einbezogen. Allerdings war die Temperatur nur als Interaktion mit der Natur als Umgebung der Route signifikant (vgl. ebd.). Darüber hinaus gilt zu beachten, dass die Routen je nach *Anlass* (z. B. Pendeln, Alltagswege, Freizeitwege) variieren und Service-Angebote entlang der Strecke (z. B. touristische Angebote oder Reparaturstationen) einen Einfluss nehmen können.

Subjektive Einflussfaktoren

Als subjektive Determinanten werden unter anderem die Erfahrung beim Radfahren und die wahrgenommene Sicherheit als statistisch signifikant angegeben (s.o.). Die Richtlinien für die einheitliche Bewertung von Radverkehrsanlagen (HEBRA) beziehen folgende Faktoren in die Bewertung der Fahrradinfrastruktur ein: Länge und Querschnittsneigung, durchschnittlicher täglicher MIV-Verkehr, zulässige Höchstgeschwindigkeit, Radverkehrsaufkommen und Stärke des Fußgängerverkehrs, Führungsform, Breite, Art und Zustand der Oberflächen, Mängel in der Streckenführung und an Knotenpunkten, Art des Knotenpunktes und Radverkehrsführung (FGSV, 2021). Darüber hinaus wird die Erlebnisqualität als "weicher" Faktor in die Bewertung von Radverkehrsanlagen einbezogen. Eine weitere Möglichkeit, weiche Faktoren einzubeziehen, wären beispielsweise Bikeability-Indizes (Hardinghaus, 2021) oder Rankings zur Fahrradfreundlichkeit (ADFC, 2020). So enthält beispielsweise die Fahrradklima-Befragung des ADFC auch Angaben zum Winterdienst in den deutschen Kommunen.

Tabelle 3: Zusammenfassung Einfluss der Determinanten der Routenwahl

Soziodemografische/-ökonomische Merkmale	
Einflussfaktor	Ergebnisse
Alter	<ul style="list-style-type: none"> • Zum Teil: Präferenz für eine Trennung vom motorisierten Verkehr für jüngere und ältere Menschen • Mit steigendem Alter höhere Bereitschaft, Umwege in Kauf zu nehmen
Geschlecht (weiblich = 1)	<ul style="list-style-type: none"> • Zum Teil: Frauen mit Präferenz für eine Trennung vom motorisierten Verkehr (verstärkt bei höherem Anteil Wenig- und Nicht-Radfahrende in Studien, weniger in Ländern mit hohem Radverkehrsaufkommen)
Weitere Merkmale (z. B. Vollzeit- vs. Teilzeitbeschäftigung, Einkommens sowie Bildungsstand)	<ul style="list-style-type: none"> • Wenige Arbeiten untersuchen den Einfluss der Arbeitszeit, des Einkommens sowie des Bildungsstands als Determinanten für die Routenwahl und kommen zu widersprüchlichen Ergebnissen
Fahrradart	
Einflussfaktor	Ergebnisse
Pedelec	<ul style="list-style-type: none"> • Pedelec-Fahrende wählen längere Strecken, direktere Strecken mit Steigungen und auch Strecken mit stärkerem Verkehr im Vergleich zu Radfahrenden mit konventionellen Fahrrädern
Zeitliche Merkmale	
Einflussfaktor	Ergebnisse
Reisezeit	<ul style="list-style-type: none"> • Neben Distanz wichtigster Einflussfaktor bei Routenwahl
Wetter	
Einflussfaktor	Ergebnisse
Temperatur	<ul style="list-style-type: none"> • Nur in einer Studie betrachtet (als Interaktion mit Naturumgebung) • Weitere Einflussfaktoren (z. B. Regen/Sonne/Windgeschwindigkeit) nicht in Studien untersucht
Räumliche Merkmale	
Einflussfaktor	Ergebnisse
Distanz	<ul style="list-style-type: none"> • Eine Verlängerung der Strecke um feste Entfernung, z. B. 1 km, wird als umso kostspieliger empfunden, je kürzer die Strecke ist • Die Sensitivität unterscheidet sich je nach Fahrtzweck
Topographie	<ul style="list-style-type: none"> • Je größer die Steigung, desto länger die empfundene Distanz oder desto größer Bereitschaft, Umweg zu fahren, um Steigung zu vermeiden
Führungsform Radverkehr	<ul style="list-style-type: none"> • Präferenzen unterscheiden sich nach Fahrtzweck, Alter und Erfahrung • Unterschiede auch je nach Verkehrsaufkommen • An Brücken Präferenz für Brücke mit Radverkehrsanlage
Infrastruktur Oberfläche	<ul style="list-style-type: none"> • Präferenz für glatte bzw. asphaltierte Oberflächen • Keine Untersuchungen für Straßenbahn- oder U-Bahn-Schienen
Infrastruktur Breite	<ul style="list-style-type: none"> • Nur eine Studie (nicht signifikante Ergebnisse)
Infrastruktur Kontinuität	<ul style="list-style-type: none"> • Präferenz für eine kontinuierliche Infrastruktur
Infrastruktur Einbahnstraße	<ul style="list-style-type: none"> • Empfundene Länge einer Einbahnstraße höher, wenn sie in Gegenrichtung befahren wird • Ausweichverhalten auf Gehwege insb. bei nicht freigegebenen Einbahnstraßen
Verkehrsaufkommen MIV	<ul style="list-style-type: none"> • Präferenz für geringes Verkehrsaufkommen • Unterschiedliche Sensitivität je nach Fahrtzweck
Verkehrsaufkommen Schwerverkehr	<ul style="list-style-type: none"> • Keine Trennung vom MIV in vorliegenden Studien
Verkehrsaufkommen Radverkehr	<ul style="list-style-type: none"> • Nur in einer Studie berücksichtigt
Verkehrsaufkommen Fußverkehr	<ul style="list-style-type: none"> • Nur in einer Studie berücksichtigt
Geschwindigkeit	<ul style="list-style-type: none"> • Nur in einer Studie berücksichtigt
Parksituation	<ul style="list-style-type: none"> • Präferenz für Routen ohne Parkstände entlang der Route • Wenige Studien berücksichtigen Fahrradabstellanlagen
Halten an Lichtsignalanlagen (LSA)	<ul style="list-style-type: none"> • Knotenpunkte mit LSA verlängern empfundene Distanz
Verzögerungen durch Abbiegen	<ul style="list-style-type: none"> • Rechts- und Linksabbiegen werden unterschiedlich bewertet • Rechtsabbiegen bevorzugt
Flächennutzung POI	<ul style="list-style-type: none"> • Widersprüchliche Ergebnisse
Flächennutzung Beleuchtung	<ul style="list-style-type: none"> • Eine Studie findet positive Effekte
Flächennutzung Naturumgebung	<ul style="list-style-type: none"> • Widersprüchliche Ergebnisse

3.4 Limitationen

Der Soll-Katalog für die Modus- und die Routenwahl ist mit folgenden Limitationen verbunden:

- 1) Der Vergleich der Studien geht mit einem Vergleich unterschiedlicher Untersuchungsgebiete einher. So ist es möglich, dass regionale Unterschiede zu Verhaltensabweichungen und als nicht beobachtbare Variablen zu verzerrten Ergebnissen führen können. Dementsprechend ist bei Nutzung der Ergebnisse ein Augenmerk darauf zu richten, welches Untersuchungsgebiet und welche verborgenen Einflussgrößen womöglich zugrunde liegen.
- 2) Außerdem unterscheiden sich die gegenübergestellten Studien im Hinblick auf die Stichprobengröße, die Auswertungsmethode sowie die Datenqualität. Dies wird unter anderem dadurch deutlich, dass Studien mit demselben Untersuchungsgebiet und einer scheinbar ähnlichen Gruppe von Befragten durch unterschiedliche Methoden zu abweichenden Ergebnissen kommen. Als Beispiel kann der Effekt von Ferien und Feiertagen auf die Moduswahl genannt werden. Die unterschiedlichen Vorzeichen bei den Effekten können auf die verwendete Datengrundlage zurückgeführt werden: Wessel (2020) berücksichtigt die Anzahl an Radfahrenden von Zählstellen, während Corcoran et al. (2014) Nutzendenzahlen von Bikesharing-Stationen verwenden. Dementsprechend ist es nicht sinnvoll, Ergebnisse einzelner Studien zu nutzen, sondern verschiedene Studien und ihre Ergebnisse zu vergleichen sowie zu hinterfragen.
- 3) Darüber hinaus hängt die Sensitivität für viele Einflussfaktoren vom Fahrtzweck ab. Beispielfhaft können an dieser Stelle unterschiedliche Präferenzen hinsichtlich der Distanz und des Verkehrsaufkommens sowie der Radinfrastruktur bei der Routenwahl für Freizeit-, Alltags- und Pendelfahrten zur Arbeit genannt werden.
- 4) Dieser Punkt führt zu einer weiteren Limitation des Soll-Katalogs: dem Verhältnis von Forschungsarbeiten zu Einflussfaktoren. Da im Rahmen der Recherche 62 objektive Einflussgrößen auf die Moduswahl und 44 Einflussfaktoren auf die Routenwahl identifiziert wurden, können 63 Studien zur Moduswahl und 47 Studien zur Routenwahl nicht jedes Detail der Einflüsse abdecken. So sind bei Detailuntersuchungen vertiefende Recherchen notwendig. Der Soll-Katalog soll entsprechend als ganzheitlicher Überblick und als Ausgangsbasis für weitere Analysen dienen.
- 5) Während bei der Moduswahl generalisierende Effektrichtungen abgeleitet werden können, ist ein Zusammenfassen der Einflussfaktoren auf die Routenwahl nicht möglich. Grund dafür sind unterschiedliche Methoden und Untersuchungsgebiete, fehlende Repräsentativität, unterschiedliche Stichproben sowie die zum Teil geringe Anzahl der Studien. Hauptgrund für die fehlende Vergleichbarkeit sind unterschiedliche Ergebnis-Typen: von „willingness to cycle“, Aufschlägen in Prozent oder Kilometern über Ersparnisse in Geldeinheiten oder Minuten hin zu Elastizitäten. Darüber hinaus fehlen insbesondere bei Stated-Preference-Auswertungen häufig Angaben zur durchschnittlichen Länge der Routen, um die Ergebnisse vergleichen zu können. Der vorangestellte Vorschlag, die präsentierten Ergebnisse als Testfälle für die Kalibrierung von Verkehrsmodellen zu nutzen, scheint ein Vorgehen zu sein, das über die Parameter aus den Verkehrsmodellen zur einer möglichen Vergleichbarkeit führt.
- 6) Insbesondere bei der beispielhaften Aufführung von Substitutionsraten bei der Routenwahl scheinen einige Angaben vergleichsweise hoch auszufallen und werden zum Teil bereits von den Autor*innen der entsprechenden Studien in Frage gestellt. Einige Studien enthalten keine durchschnittlichen Angaben zu Wegelängen oder zum Vorkommen/Anteil der betrachteten

Einflussgrößen. Dementsprechend können diese Ergebnisse schwer in einen Kontext gesetzt oder verglichen werden. Die entsprechenden Ergebnisse sind im Text gekennzeichnet.

- 7) Einige Einflussfaktoren lassen sich nicht trennscharf den übergeordneten Kategorien zuordnen: wie z. B. Stau oder Auslastung. Deshalb sei an dieser Stelle darauf hingewiesen, dass der Soll-Katalog eine ganzheitliche Übersicht bieten soll und die Kategorisierung nur eine untergeordnete Rolle spielt.

4. Priorisierung der Einflussfaktoren im Soll-Katalog

Die Forschungsarbeiten wurden im Hinblick auf Qualität und Limitationen bewertet und katalogisiert (vgl. Abbildung 5). Dazu wurden neben der Art der Datenerhebung, Studiendesign und Auswertungsmethode, das Untersuchungsgebiet und die Stichprobengröße zusammengetragen (Tabellen im Anhang). Sämtliche Erkenntnisse wurden in einem Online-Workshop mit Akteur*innen aus dem Projektkonsortium und den assoziierten Praxispartner*innen aus Sicht der Modellierung priorisiert. Parallel wurde zusätzlicher Forschungsbedarf identifiziert und festgehalten.

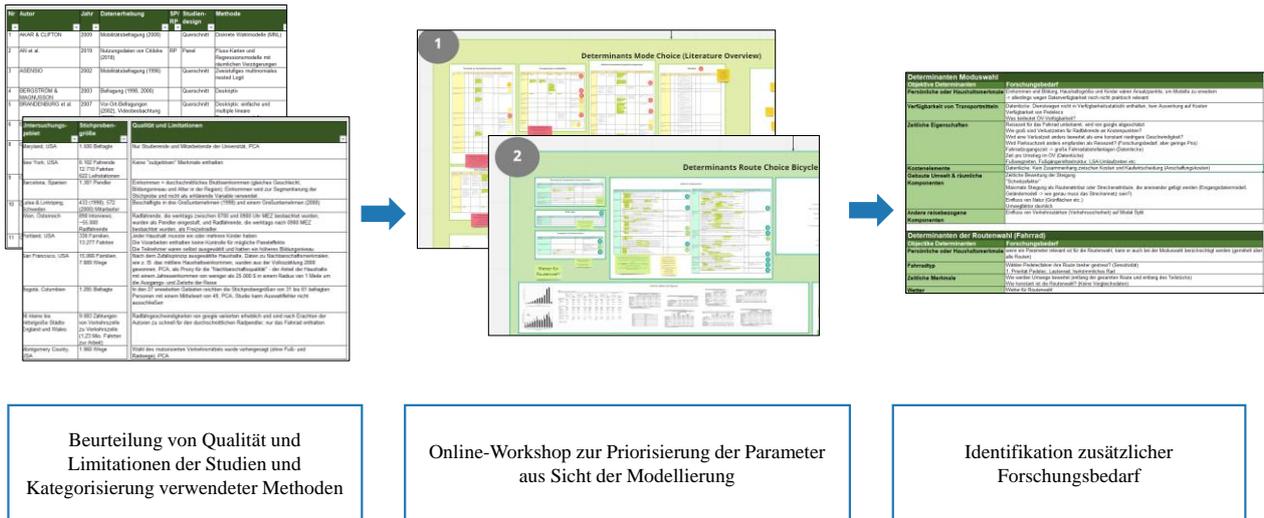


Abbildung 5: Vorgehen Priorisierung und Identifikation des Forschungsbedarfs

Die Priorisierung erfolgte außerdem unter dem Aspekt, inwiefern es inhaltlich und technisch sinnvoll ist, die jeweilige Einflussgröße in ein makroskopisches Verkehrsmodell zu integrieren, das in der Regel als ein strategisches Planungswerkzeug zur Bewertung von Prognosemaßnahmen genutzt wird. Es ist also nicht zwingend der Fall, dass Einflussgrößen mit niedriger Priorität nur einen geringen oder nicht nachgewiesenen Einfluss haben. Tabelle 4 und Tabelle 5 zeigen die Priorität der Einflussfaktoren auf. Anmerkungen und Erläuterungen zu der Festlegung finden sich jeweils nach den Kategorien der Einflussfaktoren.

Tabelle 4: Priorisierte Einflussfaktoren auf die Moduswahl

Persönliche oder Haushaltsmerkmale	
Einflussfaktor	Priorität
Alter	mittel
Geschlecht	gering
Migrationshintergrund	gering
Mobilitätseinschränkungen	gering
Haushaltsgröße	gering
Kinder im Haushalt	gering
Schüler*in oder Student*in	gering
Arbeitszeit	hoch
Einkommen	gering

In Verkehrsmodellen wird die Bevölkerung in verhaltenshomogene Gruppen eingeteilt. Auf dieser Grundlage erfolgt die Berechnung der Verkehrsnachfrage. In der Regel wird diese detaillierte Differenzierung auf Ebene der Ziel- und Moduswahl aufgegeben. Stattdessen wird die Modellierung der Ziel- und Moduswahl in Abhängigkeit des Zwecks durchgeführt. Eine mögliche Weiterentwicklung der Modellierungspraxis wäre es, bei der Modellierung der Moduswahl vor dem Hintergrund des wachsenden Pedelec-Anteils das Alter zu berücksichtigen. Die Arbeitszeit spielt dahingehend eine höhere Rolle bei der Moduswahl. Teilzeitarbeitende erledigen Wege/Aktivitäten häufig innerhalb einer Wege-Kette. Dabei werden Aktivitäten wie Einkaufen, Holen/Bringen und Arbeit innerhalb einer Wegekette miteinander kombiniert. Da die Individualverkehrsmittel Fahrrad und Pkw für die verschiedenen Wege und Aktivitäten mehr Flexibilität bieten sind sie für solche Wegeketten gut geeignet. Auf diese Weise wirkt sich die Arbeitszeit auf die Moduswahl aus.

Verkehrsmittelverfügbarkeit	
Einflussfaktor	Priorität
Anzahl Pkw	hoch
Dienstwagen	hoch
Führerschein	mittel
Anzahl Fahrräder	gering
Fähigkeit, Fahrrad zu fahren	gering
Fahrradabstellanlage	mittel
Entfernung Bike-Sharing-Station	gering
Zeitkarte ÖV	hoch
ÖV-Angebot	hoch
Entfernung Haltestelle	hoch

Der Fokus von Verkehrsmodellen lag bisher auf den ÖV und MIV. Daher wurden im Rahmen der

Berücksichtigung der Verfügbarkeit von Mobilitätswerkzeugen vor allem die Mobilitätswerkzeuge des ÖVs und des Pkws berücksichtigt und hoch priorisiert. Die Verfügbarkeit von Mobilitätswerkzeugen des Radverkehrs wird bisher noch nicht berücksichtigt. Es ist davon auszugehen, dass die Verfügbarkeit von Fahrrädern nahezu flächendeckend als hoch einzustufen ist. Daher sind sie als gering priorisiert.

Kostenmerkmale	
Einflussfaktor	Priorität
Kraftstoffkosten	hoch
Ticketpreis ÖV	hoch
Parkgebühren	hoch
Leihgebühren Sharing	gering
Straßennutzungsentgelte	hoch
Anreize Arbeitgeber	mittel

Generell spielen Sharing-Systeme eine untergeordnete Rolle, was den Anteil am Wegesvor allem aber am fahrleistungsbezogenen Modal-Split betrifft. Die Abbildung von Sharing-Systemen ist zudem sehr komplex, daher ist eine Integration in makroskopische Verkehrsmodelle niedrig priorisiert. Anreize durch Arbeitgeber lassen sich in Betriebskosten integrieren, was vor allem bei Dienstwagen und Jobtickets eine Rolle spielt. Indirekt erfolgt derart bereits eine teilweise Integration dieser Anreize.

Wetter	
Einflussfaktor	Priorität
Alle wetterbezogenen Faktoren	hoch

Die Fachliteratur zeigt, dass das Wetter einen direkten Einfluss auf die Moduswahl hat. Daher ist es als hoch zu priorisieren. Der Einfluss in die makroskopischen Modelle erfolgt i. d. R. indirekt über Anpassung der Zählwerte. Makroskopische Verkehrsmodelle beziehen sich i. d. R. auf einen mittleren Tag im Jahr, entsprechend auch auf den „mittleren“ Wetterzustand. Das muss bei der Erhebung von Verhaltensdaten und Zählwerten beachtet werden.

Tabelle 4: Priorisierte Einflussfaktoren auf die Moduswahl (Fortsetzung)

Zeitliche Merkmale	
Einflussfaktor	Priorität
Reisezeit	hoch
Wochentage	gering
Ferien	gering
Feiertag	gering
Jahreszeit	gering
Hauptverkehrszeit	hoch
Dunkelheit	gering
Parkplatzsuche	hoch
Wartezeit ÖV	hoch
Zusätzlicher Fußweg	hoch
Anzahl der Umstiege	hoch
Umstiegszeiten	hoch
Takt des ÖV	hoch

Die Merkmale mit der Priorität hoch werden in Verkehrsmodellen als Aufwände der entsprechenden Modi berücksichtigt. Da im Verkehrsmodell ein gesamter mittlerer Werktag (Montag bis Freitag außerhalb der Ferien und außerhalb von Feiertagen) des gesamten Jahres abgebildet wird, sind die als gering eingestuften Merkmale nicht relevant.

Räumliche Merkmale	
Einflussfaktor	Priorität
Distanz	hoch
Topographie	hoch
Infrastruktur (Fahrrad)	hoch
Infrastruktur (Gehweg)	gering
Flächennutzung (Dichte)	gering
Flächennutzung (Vielfalt)	gering
Flächennutzung (Design)	gering
Natur	mittel

Die Distanz, die Topographie und die Infrastruktur für den Radverkehr werden bereits in Verkehrsmodellen berücksichtigt. Sie fließen in die Berechnung der Widerstände des Radverkehrs ein. Daher sind sie als hoch

priorisiert. Die Attraktivität der Streckenumgebung wird vereinzelt berücksichtigt und daher als mittel priorisiert. Die Infrastruktur des Fußverkehrs und die Flächennutzung wurden in keinem bekannten Modell berücksichtigt. Die Integration eines Fußwegenetzes inklusive vorhandener Querungsmöglichkeiten würde eine grundlegend andere Netzabbildung mit entsprechender räumlicher Auflösung erfordern, für die die Abbildungsgenauigkeit von makroskopischen Verkehrsmodellen nicht ausreichend ist.

Andere wegebezogenen Merkmale	
Einflussfaktor	Priorität
Mitreisende	gering
Gepäck	gering
Wege Zweck: Freizeit	hoch
Wege Zweck: Arbeit	hoch
Wege Zweck: Schule	hoch
Wege Zweck: Einkaufen	hoch
Auslastung	hoch
Sicherheit (objektiv)	mittel

Die Modellierung der Verkehrsnachfrage erfolgt differenziert nach dem Wege Zweck. Folglich sind diese hoch priorisiert. Die Auslastung der Radverkehrsanlagen wird in den kommenden Jahren zunehmen und ist daher für die Prognose relevant und sollte entsprechend in der Analyse während der Modell-Kalibrierung mitberücksichtigt werden. Mitreisende und Gepäck werden bisher nicht berücksichtigt und lassen sich indirekt über den Wege Zweck mit abbilden. Daher wurden diese Merkmale gering priorisiert.

Tabelle 5: Priorisierte Einflussfaktoren auf die Routenwahl

Persönliche oder Haushaltsmerkmale	
Einflussfaktor	Priorität
Alle persönlichen oder Haushaltsmerkmale	gering

Bei der Modellierung der Routenwahl wird die gesamte Nachfragematrix umgelegt. Eine Differenzierung nach Wegezweck oder Personengruppe findet aus rechentechnischen Gründen nicht statt. Daher wurden die genannten Merkmale als gering bewertet.

Fahrradtyp	
Einflussfaktor	Priorität
Pedelec vs. herkömmliches Fahrrad	hoch

Die Nutzung von Pedelecs und damit die mittlere Geschwindigkeit der Fahrradflotte wird in den kommenden Jahren zunehmen. In den meisten Modellprognosen sind daher Geschwindigkeitserhöhungen für den Radverkehr gefordert. Folglich kommt den Pedelecs höchste Priorität zu.

Zeitliche Merkmale	
Einflussfaktor	Priorität
Reisezeit	hoch
Umwege	hoch

Die Reisezeit ist der zentrale Widerstand bei der Modellierung der Routenwahl. In den entsprechenden Algorithmen sind Parameter zur zulässigen Abweichung anzugeben. Daher sind beide Merkmale von hoher Priorität.

Wetter	
Einflussfaktor	Priorität
Alle wetterbezogenen Faktoren	gering

Das Wetter wirkt in erster Linie auf die Moduswahl. Wenn Quelle und Ziel feststehen, kann davon ausgegangen werden, dass sich das Wetter auf den verschiedenen Routen nicht oder nur unwesentlich unterscheidet. Vorstellbar wäre, dass aufgrund der Wettersituation bestimmte Routenabschnitte eher gemieden werden, wie starke Steigungen bei Schnee und Eis, Straßenbahnschienenquerungen bei Regen bzw. lange schattenfreie Abschnitte im Hochsommer. Im Jahresmittel, was der Fokus der Modellierung ist, sollte das jedoch eine untergeordnete Rolle spielen. Folglich hat es eine geringe Bedeutung für die Routenwahl.

Räumliche Merkmale	
Einflussfaktor	Priorität
Distanz	hoch
Topographie	hoch
Radinfrastruktur	hoch
Oberfläche der Fahrbahn	hoch
Bahngleise	hoch
Breite der Fahrbahn	hoch
Kontinuität der Infrastruktur	hoch
Festgelegte Fahrradkorridore	hoch
Brücken	gering
Einbahnstraße	hoch
Verkehrsaufkommen Kraftfahrzeuge	hoch
Verkehrsaufkommen Schwerverkehr	hoch
Verkehrsaufkommen Fahrradfahrende	hoch
Verkehrsaufkommen Zufußgehende	hoch
Geschwindigkeit angrenzender Verkehr	hoch
Parkende Fahrzeuge	mittel
Fahrradabstellanlagen	hoch
Knotenpunkte, Abbiegungen, Halten	hoch
Verkehrssignalanlagen und Schilder	hoch
POI	gering
Natur	mittel
Flächennutzung	mittel
Dichte Laternenbeleuchtung	mittel

Den als hoch priorisierten räumlichen Merkmalen lassen sich Strecken, Knoten, Abbieger und Bezirke als deren Eigenschaften zuordnen. Die dafür erforderlichen Datenquellen sind für die meisten Eigenschaften vorhanden. Aus der Literatur lässt sich eine Wirkung auf die Routenwahl ableiten. Diese kann in Widerstandsparameter übersetzt werden und in die Modellierung der Routenwahl eingehen.

Teil II: Gegenüberstellung des Soll-Katalogs mit dem Status quo – ein Soll-Ist-Katalog aus den Perspektiven der Datenverfügbarkeit und Modellierung

1. Einleitung

In diesem Kapitel werden die in den letzten Jahren von der PTV Group erstellten Modelle im Hinblick auf die Integration des Radverkehrs analysiert. Der Fokus liegt zum einen auf der Modellierung der Routenwahl der Radfahrenden. Zum anderen wird die Integration von radverkehrsspezifischen Faktoren wie der Verfügbarkeit von Radverkehrsanlagen oder die Topographie in die Moduswahl betrachtet. Die analysierten Modelle sind die Folgenden:

- Verkehrsmodell Augsburg (A)
- Verkehrsmodell Bocholt (BO)
- Verkehrsmodelle für den Regionalverband Großraum Braunschweig, die Stadt Braunschweig und die Stadt Wolfsburg (BW)
- Integriertes Verkehrsmodell Dresden (DD)
- Multimodales Verkehrsmodell München (M)
- Verkehrsmodell Regensburg (R)
- Nationales Personenverkehrsmodell der Schweiz (CH)
- Verkehrsmodell Münster (für den Mobilitätsplan 2035+) (MS)

Zudem werden ein Forschungsprojekt und eine Masterarbeit betrachtet. In dem Forschungsprojekt wurde die Modellierung des Radverkehrs im Raum Ludwigsburg im Verkehrsmodell der Region Stuttgart vertieft (LU). In der Masterarbeit wurden Ansätze zur verbesserten Modellierung des Radverkehrs in Landesverkehrsmodellen am Beispiel des Landesverkehrsmodells Bayern entwickelt (BY).

2. Darstellung des Ist-Zustandes aus Perspektive der Modellierung

In den analysierten Modellen wurden folgende Einflussfaktoren mindestens einmal berücksichtigt:

- Längsneigung [%]
- Höhendifferenz zwischen höchstem und niedrigstem Punkt der Route
- Art der Radverkehrsanlage
- Art / Kategorie des Verkehrsweges
- Definierte Radkorridore
- Material der Oberfläche
- Umgebung der Strecke
- Einbahnstraßen
- Verkehrsstärke des MIVs
- Schwerverkehr
- Geschwindigkeit des MIVs
- Verlustzeit an Knoten
- Zahl der beim Abbiegen gekreuzten Kraftfahrzeuge
- Dichte von Knoten im Verlauf der Route
- erhöhter Widerstand beim Linksabbiegen
- Streckenhierarchie beim Abbiegen
- Trennwirkung von Flüssen und Bahndämmen

- Radaffinität
- Radabstellanlagen

Welche Einflussfaktoren in welchem Modell berücksichtigt wurden, ist in Tabelle 6 dargelegt.

Tabelle 6: In den Verkehrsmodellen berücksichtigte Einflussfaktoren

	A	BO	BW	DD	LB	M	MS	R	BY	CH
Längsneigung [%]	x		x	x	x	x		x	x	x
Höhendifferenz im Verlauf der Route										x
Radverkehrsanlage/Wegeart		x	x	x			x	x	x	
Art der Radverkehrsanlage	x	x	x		x	x	x	x		x
Definierte Radkorridore					x		x			
Verkehrsstärke des MIVs	x	x	x		x	x				x
Schwerverkehr	x		x		x					
Geschwindigkeit des MIVs										x
Oberfläche	x		x	x						
Umgebung der Strecke						x	x	x	x	
Breite	x									
Straßenbahnschienen	x									
Trennwirkung von Flüssen und Bahndämmen	x			x						
Einbahnstraßen			x				x	x		
Verlustzeit an Knoten	x	x	x	x	x	x	x	x		
Zahl der beim Abbiegen gekreuzten Kraftfahrzeuge					x					
Dichte von Knoten im Verlauf der Route										x
schwieriges Linksabbiegen	x									x
Streckenhierarchie beim Abbiegen										x
Radaffinität				x						
Radabstellanlagen	x									

Für die Integration der Einflussfaktoren haben sich zwei Ansätze entwickelt. Der eine ist die Berechnung eines subjektiven, empfundenen Widerstandes. Der andere Ansatz ist die Berechnung einer objektiven Streckengeschwindigkeit und -fahrzeit. In den folgenden Abschnitten wird beschrieben, wie die Einflussfaktoren in den Verkehrsmodellen berücksichtigt wurden.

Ein Einflussfaktor ist die Längsneigung [%] der Strecken. Die Voraussetzung ihrer Berücksichtigung ist die Attribuierung der Knoten mit ihrer Z-Koordinate, aus welchen wiederum die Längsneigung berechnet werden kann. Als Quelle der Höhendaten haben sich die in Kommunen und Ländern gepflegten digitalen Geländemodelle bewährt. Ihr Vorteil ist ihre hohe Genauigkeit. Eine Alternative bietet die Nutzung frei verfügbarer Daten, wie z. B. das digitale Geländemodell des Copernicus-Landüberwachungsdiensts der EU. Die Längsneigung fließt im Verkehrsmodell Augsburg in die Berechnung des empfundenen Widerstands ein. Es wurden Klassen der Längsneigung (z. B. 0 % bis 2 %, 2 % bis 5 % ...) definiert. Diesen sind Widerstandsfaktoren mit einem Wertebereich von 1,0 (Längsneigung < 2,5 %) bis 1,6

(Längsneigung $\geq 5,0\%$) zugeordnet. Die Widerstandsfaktoren werden mit der Fahrzeit der Strecken und den Widerstandsfaktoren der anderen Einflussfaktoren zum empfundenen Widerstand multipliziert. In den Verkehrsmodellen für den Regionalverband Großraum Braunschweig, die Stadt Braunschweig und die Stadt Wolfsburg sowie der Stadt Dresden wird aus der Längsneigung und einer Grundgeschwindigkeit eine längsneigungsabhängige Geschwindigkeit berechnet. Sie wurde auf der Grundlage der Fachliteratur entwickelt und soll die objektive Streckengeschwindigkeit darstellen. Die Formel zur Berechnung der längsneigungsabhängigen Geschwindigkeit unterscheidet sich zwischen den Streckenarten. So können die Spezifika der Streckenarten berücksichtigt werden. Einige beispielhafte Längsneigung-Geschwindigkeit-Funktionen sind in Abbildung 6 dargestellt.

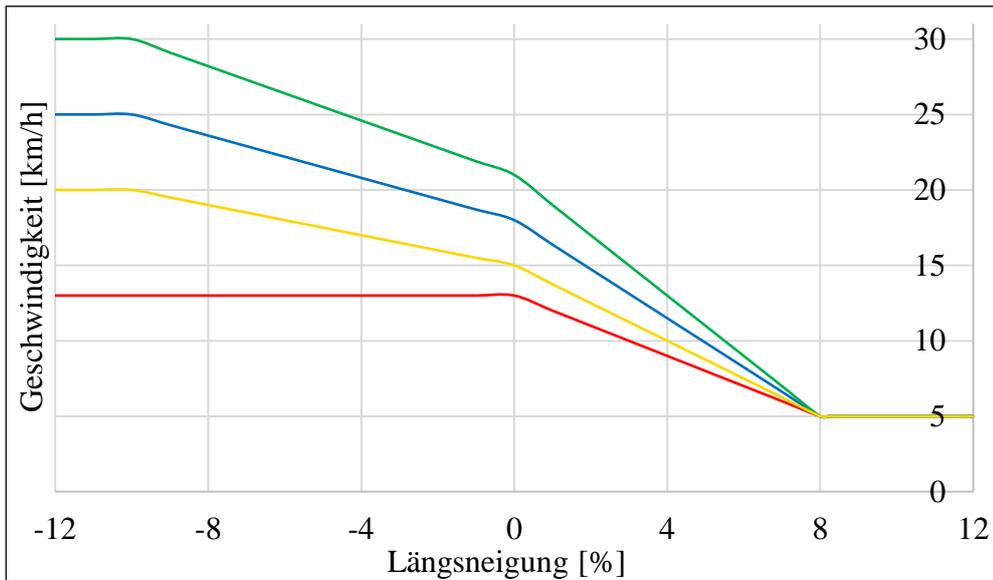


Abbildung 6: Objektive Längsneigung-Geschwindigkeit-Funktionen

In der Masterarbeit im Landesverkehrsmodell Bayern wurde auch dieser Ansatz umgesetzt.

Im nationalen Personenverkehrsmodell der Schweiz, den Verkehrsmodellen der Städte München und Regensburg und dem Forschungsprojekt zur Modellierung des Radverkehrs im Raum Ludwigsburg wird ebenfalls eine Geschwindigkeit aus der Längsneigung und der Grundgeschwindigkeit berechnet. Diese bildet die objektive und real messbare Geschwindigkeitsveränderung sowie den subjektiven Diskomfort von Steigungsstrecken und die daraus folgende negative Bewertung durch die Radfahrenden ab. Die in den Modellen hinterlegte Längsneigung-Geschwindigkeit-Funktion ist in Abbildung 7 dargestellt.

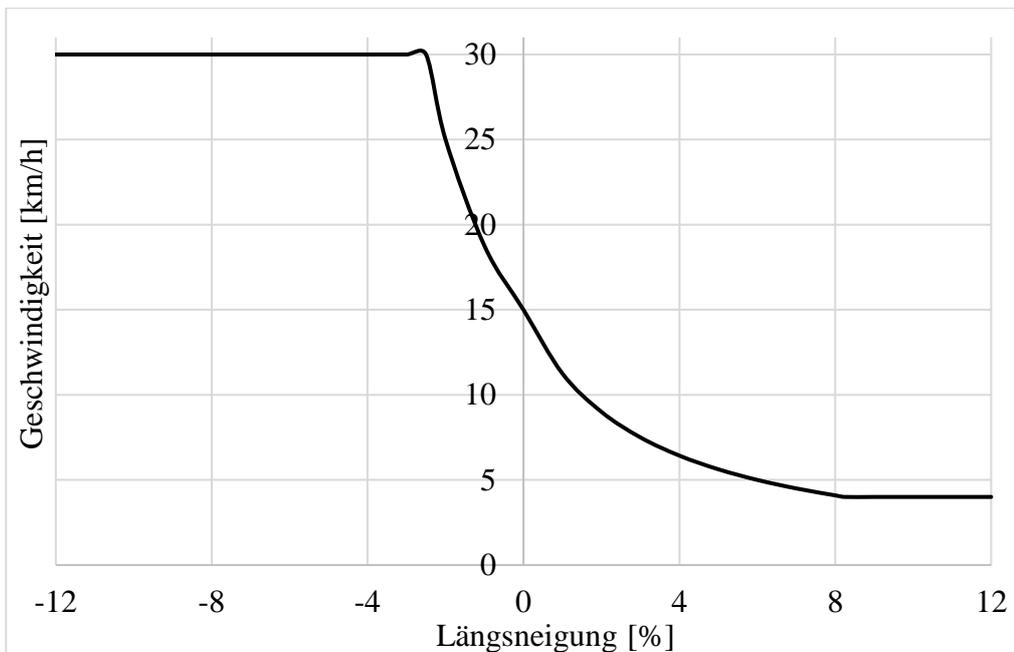


Abbildung 7: Subjektive Längsneigung-Geschwindigkeit-Funktion

Im nationalen Personenverkehrsmodell der Schweiz wird die Höhendifferenz im Verlauf der Route berücksichtigt. Dazu wird die Höhendifferenz zwischen dem höchsten und dem niedrigsten Knoten einer Route berechnet. Daraus wird ein Zuschlag für den Widerstand der Route berechnet. Ausgewiesene Radrouten- bzw. Korridore wurden im Forschungsprojekt zur Modellierung des Radverkehrs im Raum Ludwigsburg berücksichtigt. Die Quelle dieser Daten sind die für die Radverkehrsplanung verantwortlichen Gemeinden. Im Rahmen der Aufteilung der Verkehrsströme auf die Routen wird für diese die Wegstrecke abseits der Radkorridore berechnet. Aus dieser Wegstrecke wird ein Zusatzwiderstand für die Routen berechnet. Die Strecken abseits der Radkorridore gehen somit mit einem erhöhten Widerstand in die Routenwahl ein. Im Verkehrsmodell der Stadt Münster wird die Attraktivität ausgewählter, für den Radverkehr attraktiver Korridore berücksichtigt. Diese Korridore zeichnen sich durch eine grüne Umgebung und das Fehlen von Interaktion mit dem MIV aus. Die Fahrzeit der Strecken dieser Korridore wird um ca. 22 % reduziert. So wird abgebildet, dass die Radfahrenden aufgrund der hohen Attraktivität dieser Strecken bereit sind Umwege zu fahren. Die Promenade ist für Radfahrende besonders attraktiv. Auf ihr beträgt die Reduzierung der Fahrzeit 35 %.

Eine Streckeneigenschaft mit einem Einfluss auf die Routenwahl der Radfahrenden ist die Führungsform des Radverkehrs (z. B. Radfahrstreifen, gemeinsamer Geh- und Radweg etc.). Bei der Beschaffung dieser Datensätze sollten die amtlichen Daten der städtischen oder der regionalen Planungsämter die erste Wahl sein. Geeignete Quellen können auch öffentlich zugänglichen Daten wie z. B. OpenStreetMap oder Luftbilder sein. Zur Integration der Führungsform des Radverkehrs in die Modellierung des Radverkehrs liegen verschiedenen Ansätze vor. Einer ist die Vergabe von diskreten Widerstandsfaktoren. Dieser Ansatz ist im Verkehrsmodell Augsburg implementiert. Den Führungsformen ist ein diskreter Widerstandsfaktor zugeordnet. Je unattraktiver eine Führungsform ist, desto höher ist ihr Widerstandsfaktor. Die Werte der Widerstandsfaktoren reichen von 1,0 (Radweg) bis 1,6 (Mischverkehr auf der Fahrbahn). Der Widerstandsfaktor wird mit der Fahrzeit der Strecken und den Widerstandsfaktoren der anderen Einflussfaktoren zum empfundenen Widerstand multipliziert. Der gleiche Ansatz ist im Verkehrsmodell München und im Verkehrsmodell Regensburg implementiert.

In den Verkehrsmodellen für den Regionalverband Großraum Braunschweig, die Stadt Braunschweig und die Stadt Wolfsburg wird die Wirkung der Führungsform auf die Geschwindigkeit berücksichtigt. Den Strecken wurde in Abhängigkeit ihrer Führungsform eine Grundgeschwindigkeit des Radverkehrs zugewiesen. Diese soll die reale Geschwindigkeit in der Ebene im Modell abbilden. Die den Führungsformen zugeordneten Geschwindigkeiten sind in Tabelle 7 aufgeführt.

Tabelle 7: Grundgeschwindigkeit des Radverkehrs in Abhängigkeit der Führungsform in den Verkehrsmodellen für den Regionalverband Großraum Braunschweig, die Stadt Braunschweig und die Stadt Wolfsburg

Führungsform	Grundgeschwindigkeit [km/h]
Entgegen Einbahnstraße	4,0
Fahrradstraße	18,0
Feld-, Forst-, Treidel- und ländliche Wege	10,0
Fußgängerzone	4,0
Gemeinsamer Geh- und Radweg außerorts	15,0
Gemeinsamer Geh- und Radweg innerorts	10,0
Gesperrt	0,0
keine Angabe	15,0
Mischverkehr	15,0
Radfahrstreifen	15,0
Radschnellweg	22,5
Radweg	15,0
Schutzstreifen	15,0

Im Verkehrsmodell Dresden wurde ein ähnlicher Ansatz implementiert. Die Grundgeschwindigkeit wurde in Abhängigkeit der Art des Verkehrsweges bzw. der Netzhierarchie vergeben. Es wurden vier Geschwindigkeitsklassen definiert: Schnelle Strecken (21 km/h, z. B. der Elberadweg), normale Strecken (18 km/h, die Mehrzahl der Haupt- und Nebenstraßen), langsame Strecken (13 km/h, z. B. von Fußgängern hochfrequentierte Bereiche im Stadtzentrum) sowie Strecken durch Parks und Trampelpfade (15 km/h). Die Attribuierung des Netzmodells mit diesen Geschwindigkeiten ist in Abbildung 8 dargestellt.

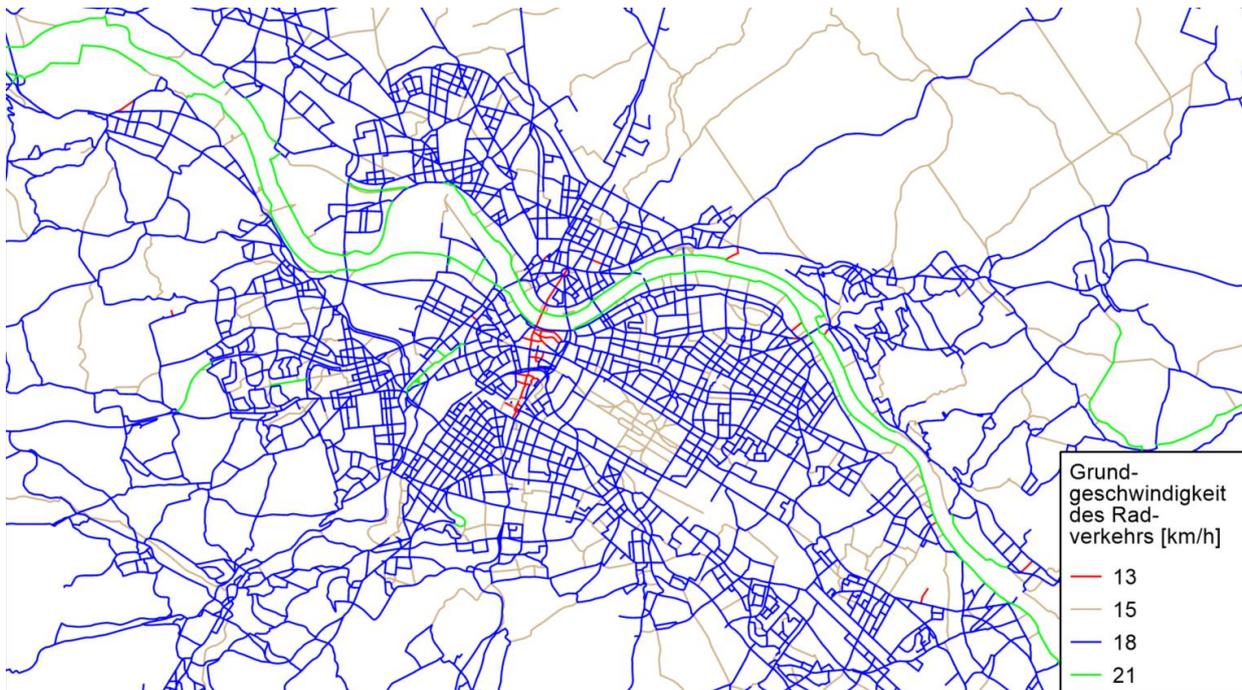


Abbildung 8: Grundgeschwindigkeit des Radverkehrs im Verkehrsmodell Dresden

Im Verkehrsmodell Bocholt wurde die Grundgeschwindigkeit nach der Qualität der Verkehrsanlage differenziert. Für Standardstrecken beträgt die Geschwindigkeit 15 km/h und für Radwege mit höherer Qualität 20 km/h.

Im Verkehrsmodell Regensburg wird die Geschwindigkeit des Radverkehrs nach der Art des Verkehrsweges und der Radverkehrsanlage differenziert. Im Gegensatz zu anderen Modellen verfügen einige der Verkehrswegearten bzw. Radverkehrsanlagen über einen eigenen Streckentyp. Ihre Geschwindigkeiten sind in Tabelle 8 aufgeführt.

Tabelle 8: Grundgeschwindigkeit des Radverkehrs im Verkehrsmodell Regensburg

Führungsform	Grundgeschwindigkeit [km/h]
Fuß-/Rad Treppe mit Schiebehilfe	3,0
Fähre	5,0
Fußgängerzone (Bus möglich)	5,0
Verkehrsberuhigter Bereich	5,0
Fuß-/Radweg (Lieferverkehr frei)	10,0
Anliegerverkehr	10,0
Fuß-/Radweg	12,0
Feld-/Wald-/Landwirtschaftlicher Weg	12,0
Alle anderen Verkehrswege und Führungsformen	15,0

Erfahrungen für eine differenzierte Setzung der Geschwindigkeit des Radverkehrs liegen auch für Landesverkehrsmodelle vor. Im Rahmen der genannten Masterarbeit wurde den Strecken des Landesverkehrsmodell Bayern eine Grundgeschwindigkeit zugewiesen. Die Strecken des Bayernnetz für Radler wurden mit 20 km/h und Radwanderwege mit 19 km/h parametrisiert. Den restlichen Strecken wurde eine Geschwindigkeit von 18 km/h zugeschrieben.

Der Pkw-Verkehr besitzt mehrere Eigenschaften, für die ein Einfluss auf den Radverkehr nachgewiesen ist. Im Verkehrsmodell Augsburg werden die Verkehrsstärke des gesamten Pkw-Verkehrs sowie des Schwerverkehrs bei der Berechnung des empfundenen Widerstands berücksichtigt. Dabei wird auf die Verkehrsstärken, die sich als das Ergebnis der Umlegung ergeben, zurückgegriffen. Es wurden Klassen der Pkw-Verkehrsstärke (z. B. $\text{Pkw}/24\text{h} < 500$, $5.000 < \text{Pkw}/24\text{h} < 10.000$...) definiert. Diesen sind Widerstandsfaktoren mit einem Wertebereich von 0,8 ($\text{Pkw}/24\text{h} < 250$) bis 1,6 ($\text{Pkw}/24\text{h} > 7.500$ und $\text{Schwerverkehr}/24\text{h} > 1.250$) zugeordnet. Die Widerstandsfaktoren werden mit der Fahrzeit der Strecken und den Widerstandsfaktoren der anderen Einflussfaktoren zum empfundenen Widerstand multipliziert. Im Verkehrsmodell München wird ein ähnlicher Widerstandsfaktor der Verkehrsstärke des Pkw-Verkehrs berücksichtigt. Im Gegensatz zum Verkehrsmodell Augsburg wird dieser Faktor aus der Tageskapazität (Stundenkapazität mal c-Faktor der CR-Funktion) der Strecken als Stellvertreter für die Tagesbelastung abgeleitet. Dies wirkt sich positiv auf die Stabilität des Modells und das Konvergenzverhalten aus. Im nationalen Personenverkehrsmodell der Schweiz werden die Verkehrsstärke und die zulässige Höchstgeschwindigkeit des Pkw-Verkehrs berücksichtigt. Es wurden vier Klassen gebildet. Ihnen sind diskrete Widerstandsfaktoren zugeordnet. Die Widerstandsfaktoren reichen von 1,0 (Velorouten, Radwege sowie Tempo-30-Zone mit max. 1.000 Pkw/24h) bis 1,6 (Außerhalb Tempo-30-Zone mit Belastung über 7.500 Pkw/24h). Die Widerstandsfaktoren werden mit der Fahrzeit der Strecken zum empfundenen Widerstand multipliziert.

Im Verkehrsmodell Bocholt ist ein Widerstandsfaktor implementiert, der die Führungsform des Radverkehrs und die Verkehrsstärke des Pkw-Verkehrs berücksichtigt. Der Widerstandsfaktor wird mit der Fahrzeit der Strecken zum empfundenen Widerstand multipliziert. Ist die Strecke ein eigenständig-geführter Radweg beträgt der Faktor 0,8. Verfügt sie über einen Radfahrstreifen, einen Radfahrstreifen oder einen straßenbegleitenden Radweg beträgt der Faktor 0,9. Ist keine Radverkehrsanlage vorhanden hängt der Faktor von der Verkehrsstärke des Pkw-Verkehrs ab. Wie im Verkehrsmodell Augsburg wurde die Verkehrsstärke in Klassen eingeteilt. Diesen sind diskrete Werte des Widerstandsfaktors zugeordnet. Der Faktor der Verkehrsstärke reicht von 1,0 ($\text{Pkw}/24\text{h} < 1.000$) bis 1,6 ($\text{Pkw}/24\text{h} \geq 10.000$).

Im Forschungsprojekt zur Modellierung des Radverkehrs im Raum Ludwigsburg wurde ebenfalls ein Widerstandsfaktor entwickelt, der die Führungsform des Radverkehrs und die Verkehrsstärke des Pkw-Verkehrs berücksichtigt. Fährt der Radverkehr außerhalb der Fahrbahn wird dem Widerstandsfaktor in Abhängigkeit der Führungsform ein diskreter Wert zwischen 0,8 und 1,2 zugeordnet. Fährt der Radverkehr auf der Fahrbahn wird der Widerstandsfaktor aus der Verkehrsstärke (aus der Umlegung des Pkw-Verkehrs) berechnet. Dabei sind unterschiedliche Funktionen für Radfahrstreifen- und Radschutzstreifen sowie den Mischverkehr implementiert. Je stärker die Interaktion mit dem MIV ist, desto steiler verläuft die Funktion. Die Verkehrsstärke fließt in der Einheit Pkw-Einheiten ein. Das Flussdiagramm zur Berechnung des Widerstandsfaktors ist in Abbildung 9 dargestellt.

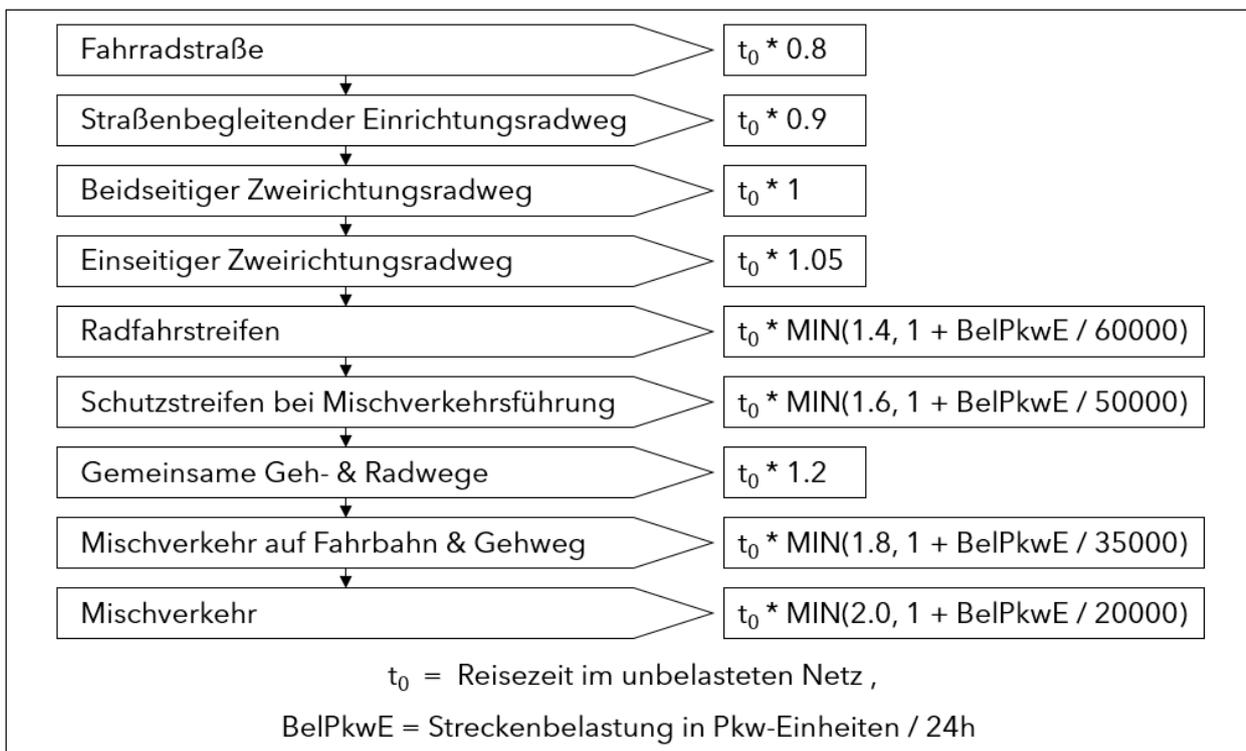


Abbildung 9: Berechnung des Widerstandsfaktors bei der Erweiterung des Verkehrsmodells der Region Stuttgart um den Radverkehr

Eine weitere Streckeneigenschaft mit einem Einfluss auf die Routenwahl der Radfahrenden ist die Oberfläche. Bei der Beschaffung dieser Datensätze sollten die amtlichen Daten der städtischen oder der regionalen Planungsämter die erste Wahl sein. Geeignete Quellen können auch öffentlich zugänglichen Daten wie z. B. OpenStreetMap oder Luftbilder sein. Zur Integration der Oberfläche in die Modellierung des Radverkehrs liegen zwei Ansätze vor. Einer ist die Vergabe von diskreten Widerstandsfaktoren. Dieser Ansatz ist im Verkehrsmodell Augsburg implementiert. Den Oberflächen ist ein diskreter Widerstandsfaktor zugeordnet. Je unattraktiver eine Oberfläche ist, desto höher ist ihr Widerstandsfaktor. Die Werte des Widerstandsfaktors reichen von 1,0 (Asphalt) bis 1,4 (Kopfsteinpflaster). Der Widerstandsfaktor wird mit der Fahrzeit der Strecken und den Widerstandsfaktoren der anderen Einflussfaktoren zum empfundenen Widerstand multipliziert. Der zweite Ansatz ist die Berücksichtigung der Oberfläche bei der Berechnung der Streckengeschwindigkeit. Dieser Ansatz ist im Verkehrsmodell Dresden implementiert. Die aus der Grundgeschwindigkeit und der Längsneigung resultierende Geschwindigkeit wird mit einem Faktor der Oberfläche multipliziert. So wird im Modell abgebildet, dass bestimmte Oberflächenarten (z. B. Kopfsteinpflaster) eine verlangsamende Wirkung aufweisen. Im Verkehrsmodell Dresden beträgt der Faktor von Asphalt und Beton 1,0. Diese Oberflächen weisen keine verlangsamende Wirkung auf. Bei ungebundenen Decken und Pflaster ist dies anders. Daher beträgt der Faktor von ungebundenen Decken und Kleinpflaster 0,93. Der Faktor von Groß- und Wildpflaster beträgt 0,75. Dieser Ansatz ist auch in den Verkehrsmodellen für den Regionalverband Großraum Braunschweig, die Stadt Braunschweig und die Stadt Wolfsburg implementiert.

Eine weitere Eigenschaft von Strecken, für die ein Einfluss auf die Routenwahl der Radfahrenden nachgewiesen wurde, ist ihre Umgebung. Zu ihrer Integration in die Modellierung des Radverkehrs liegen mehrere Ansätze vor. Einer ist die Vergabe von diskreten Widerstandsfaktoren. Dieser Ansatz ist in den Verkehrsmodellen der Städte München und

Regensburg implementiert. Den Umgebungen ist ein diskreter Widerstandsfaktor zugeordnet. Je unattraktiver eine Umgebung ist, desto höher ist ihr Widerstandsfaktor. Die Werte des Widerstandsfaktors reichen im Verkehrsmodell München von 0,8 (verkehrsberuhigter Bereich / Tempo-30-Zone, landwirtschaftlich geprägt und grüne Umgebung) bis 1,2 (Hauptstraßen). Im Verkehrsmodell Regensburg reichen sie von 0,9 (ruhige Nebenstraßen/Tempo-30-Zone/verkehrsberuhigt) bis 1,2 (starke Pkw-Belastung). Der Widerstandsfaktor wird mit der Fahrzeit der Strecken und den Widerstandsfaktoren der anderen Einflussfaktoren zum empfundenen Widerstand multipliziert. Im Verkehrsmodell Münster wurde die Umgebung bei der Auswahl der Radkorridore berücksichtigt. In der Masterarbeit zur Modellierung des Radverkehrs im Landesverkehrsmodell Bayern wurde den Strecken eine Landnutzungsart zugeordnet. Den Landnutzungsarten ist ein Faktor größer als eins zugeordnet. Er wird mit der Fahrzeit der Strecken multipliziert. So sollen verlangsamende Störfaktoren wie Knotenpunkte, Konflikte mit anderen Verkehrsteilnehmenden und Konflikte mit dem ruhenden Verkehr im Modell abgebildet werden. Der Faktor ist umso höher, je höher die Dichte solcher Konflikte und die durch sie bewirkten Zeitverluste in dieser Umgebung sind. Die Landnutzungen und ihre Faktoren sind in Tabelle 9 aufgeführt.

Tabelle 9: Faktoren zur Verlängerung der Reisezeit in Abhängigkeit der Landnutzung

Landnutzung	Faktor [-]
durchgängig städtischer Prägung	1,20
Verkehrsflächen	1,20
nicht durchgängig städtischer Prägung	1,10
Industrie und Gewerbegebiete	1,10
alle anderen Landnutzungsarten (Grünflächen, Wälder, Ackerland ...)	1,05

Im Verkehrsmodell Augsburg wird ein Widerstandsfaktor der Breite berücksichtigt. Je enger eine Strecke ist, desto höher ist ihr Widerstandsfaktor. Seine Werte reichen von 1,00 (keine Einschränkung) bis 1,25 (sehr eng). Zudem ist ein Widerstandsfaktor für das Fahren neben Straßenbahnschienen definiert. Dieser beträgt 1,4. Der Widerstandsfaktor wird mit der Fahrzeit der Strecken und den Widerstandsfaktoren der anderen Einflussfaktoren zum empfundenen Widerstand multipliziert.

Flüsse und Bahndämme besitzen eine Trennwirkung. Diese wird in einigen Modellen bei der Modellierung des Radverkehrs berücksichtigt. Im Verkehrsmodell Augsburg wird sie auf der Ebene der Strecken berücksichtigt. Zur Fahrzeit ausgewählter Strecken (Brücken und Unterführungen) wird ein Zeitzuschlag zwischen 90 s und 300 s addiert. Diese Zeitzuschläge sind ein Ergebnis der Kalibrierung und in Abbildung 10 dargestellt.

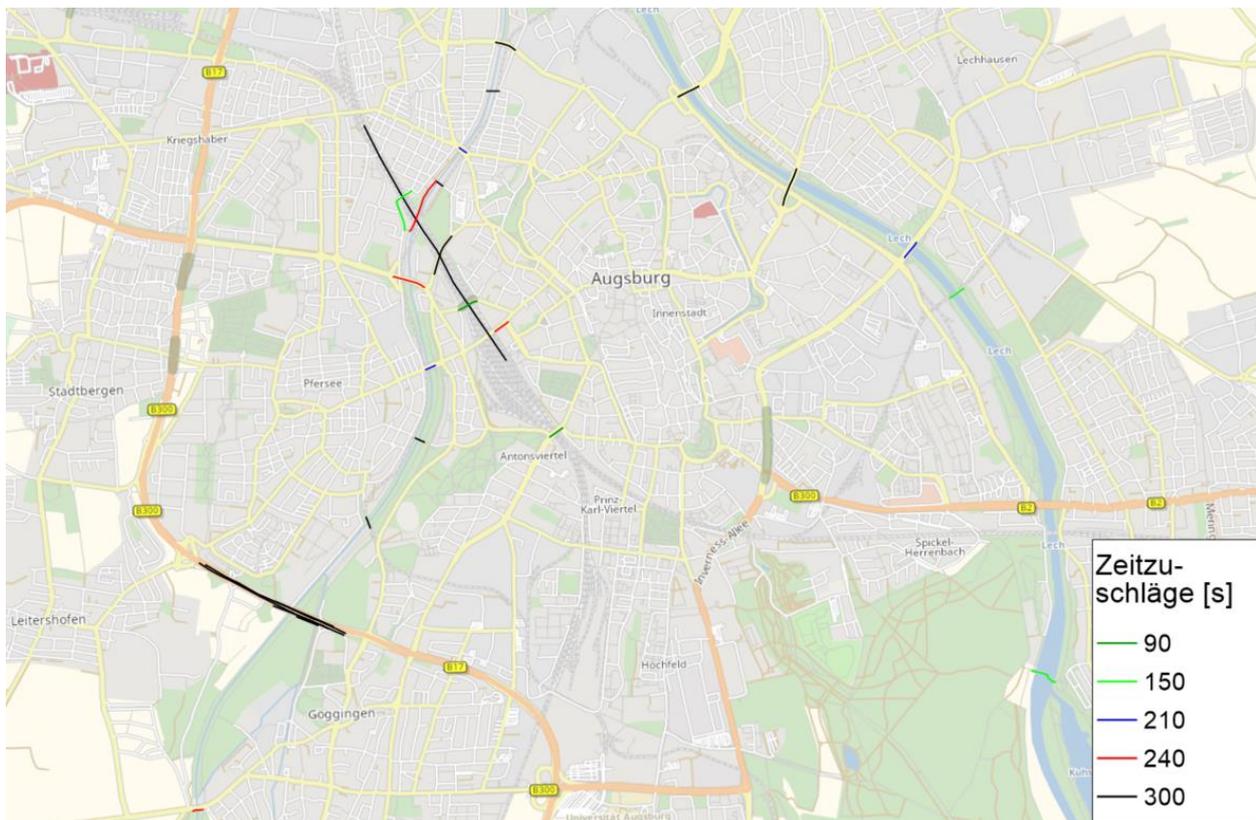


Abbildung 10: Zeitzuschläge für Brücken und Unterführungen im Verkehrsmodell Augsburg

Die Trennwirkung wird zudem bei der Modellierung der Ziel- und Moduswahl berücksichtigt. Dazu wurde auf der Grundlage der erläuterten Streckenwiderstände (vgl. Abbildung 10) eine Matrix erstellt. Sie ist in die Nutzenfunktion des Radverkehrs in der Moduswahl integriert. Diese Matrix enthält eine 0 für Bezirksbeziehungen, die keiner Trennwirkung eines Bahndamms oder eines Flusses unterworfen sind. Führt die Relation über einen Fluss bzw. einen Bahndamm liegt der Wert je nach kalibrierter Trennwirkung zwischen 0 und 1. Der Wert wird in der Nutzenfunktion mit einem negativen Parameter multipliziert, so dass die Trennwirkung zu einer geringeren Auswahl dieser Relationen im Rahmen der Zielwahl führt. Eine ähnliche Matrix ist im Verkehrsmodell Dresden in die Modellierung der Ziel- und Moduswahl integriert. Sie bildet die Trennwirkung durch die Elbe im Modell ab. Liegen Quelle und Ziel auf der gleichen Elbseite beträgt der Matrixwert 1,0 (keine Verschlechterung der Bewertung des Radverkehrs auf der Relation). Liegen Quelle und Ziel unterschiedlichen Elbseiten ist der Matrixwert kleiner als 1,0 (Verschlechterung der Bewertung des Radverkehrs auf der Relation).

Gesperrte Gegenrichtungen (z. B. entgegen einer Einbahnstraße) sind in einigen Modellen mit einer eigenen Geschwindigkeit parametrisiert. Im Verkehrsmodell Regensburg und den Verkehrsmodellen für den Regionalverband Großraum Braunschweig, die Stadt Braunschweig und die Stadt Wolfsburg beträgt die Geschwindigkeit entgegen Einbahnstraßen 10 km/h (vgl. Tabelle 7). Im Verkehrsmodell Münster beträgt sie 12 km/h. In den anderen Modellen sind sie entweder für den Radverkehr gesperrt oder ohne Abweichung zum Standardansatz parametrisiert.

Die Wirkung von Knotenpunkten auf die Wahlentscheidungen der Verkehrsteilnehmenden und der Radfahrenden wird ebenfalls berücksichtigt. Am häufigsten geschieht dies durch die Berücksichtigung der Zeitverluste beim Abbiegen. Diese werden in der Regel aus den Abbiegezeiten des Pkw-Verkehrs abgeleitet und ggf. angepasst. Die Begründung dafür ist, dass die Radfahrenden an den meisten Knoten ein Teil des Verkehrsstromes des Pkw-Verkehrs sind

und somit die gleichen Zeitverluste wie dieser erfahren. Durch die Anpassungen der Abbiegezeiten können radverkehrsspezifische Besonderheiten im Modell abgebildet werden. In den meisten der analysierten Modelle wurden die Abbiegezeiten des Pkw-Verkehrs ohne Anpassungen auf den Radverkehr übertragen. Eine Ausnahme bildet das Verkehrsmodell München. Dort wurden die Abbiegewiderstände des Radverkehrs nach der Abbiegerichtung und der Steuerungsart des Knotens differenziert. Die Abbiegezeiten sind in Tabelle 10 dargestellt.

Tabelle 10: Abbiegezeiten des Radverkehrs im Verkehrsmodell München

Knotentyp	Abbiegerichtung	Abbiegezeit
Lichtsignalanlage & Verkehrszeichengeregelte	Rechts	3 s
	Geradeaus, U-Turn	0,75 * Abbiegezeit des MIVs [s]
	Links	1,25 * Abbiegezeit des MIVs [s]
Kreisverkehr & Rechts vor Links	Alle	3 s
Alle anderen Knotenpunkte	Rechts, Geradeaus, U-Turn	2 s
	Links	5 s

Die Abbiegezeit des Rechtsabbiegens beträgt höchstens drei Sekunden. Damit wird im Modell abgebildet, dass die Radfahrenden beim Rechtsabbiegen über den Bordstein bzw. im Seitenraum abbiegen können. An Knoten mit einer Lichtsignalanlage und an verkehrszeichengeregelten Knoten ist die Abbiegezeit für Linksabbiegen höher als die Abbiegezeit für Geradeausfahren. So wird im Modell berücksichtigt, dass Radfahrende häufig indirekt Linksabbiegen und dabei zwei Straßen queren müssen. Im Verkehrsmodell Augsburg wurde zusätzlich zu den Zeitverlusten beim Abbiegen der hohe Schwierigkeitsgrad einiger bestimmter Abbiegevorgänge berücksichtigt. Diese Abbiegevorgänge wurden vom Auftraggeber auf der Grundlage seines lokalen Wissens ausgewählt. Sie umfassen vor allem Linksabbiegevorgänge. Ihre Abbiegezeit wird um 30 s erhöht. Im Forschungsprojekt zur Modellierung des Radverkehrs im Raum Ludwigsburg wurden die Abbiegezeiten des Radverkehrs aus der Zahl der beim Abbiegen gekreuzten Kraftfahrzeuge [Pkw-Einheiten] berechnet. Die Zahl der beim Abbiegen gekreuzten Kraftfahrzeuge wird mit der folgenden Formel in den Abbiegewiderstand umgerechnet.

$$\text{RadWid [min]} = \text{Min} ((\text{MIV-Abbieger [PkwE]}) / 50.000, 4) * 60$$

Im nationalen Personenverkehrsmodell der Schweiz wird die Dichte der Abbiegevorgänge entlang einer Route in der Modellierung der Routenwahl berücksichtigt. Dieser Widerstand repräsentiert die Kontinuität der Routen. Zur Berechnung des Widerstands wurde jedem Abbieger an einem Knoten mit mindestens drei Armen ein Gewicht zugeordnet. Das Gewicht repräsentiert das Risikopotential des Abbiegers. Je höher das Gewicht, desto gefährlicher schätzen die Radfahrenden den Abbiegevorgang ein. Die Gewichte sind in Tabelle 11 dargestellt.

Tabelle 11: Widerstand der Kontinuität aus dem nationalen Personenverkehrsmodell der Schweiz

Abbiegerichtung	Auf höherrangige Strecke	Gewicht
Rechts	Ja	2
	Nein	1
Geradeaus	Ja	1
	Nein	0
Links	Ja	4
	Nein	3

Widerstand der Kontinuität wird berechnet, in dem das Gewicht der Abbieger der betrachteten Route aufsummiert wird. Diese Summe wird durch die Länge der Route geteilt. Das Ergebnis repräsentiert die Anzahl potenzieller Konfliktsituationen entlang der Route je Kilometer. Dieser Wert wird mit 5 s multipliziert und zum Widerstand der Route addiert.

Im Verkehrsmodell Dresden ist ein Vektor der Radaffinität in die Modellierung der Ziel- und Moduswahl integriert. Jedem Bezirk ist ein Affinitätswert zugeschrieben. So kann eine niedrige oder hohe Affinität der Bevölkerung fürs Fahrrad im Modell abgebildet werden.

Im Verkehrsmodell Augsburg existieren eigenständige Rad-Anbindungen. Diese sind für die Verkehrssysteme Rad und Fuß geöffnet und wurden an Radabstellanlagen gesetzt. So wird der Radverkehr dort ins Netz eingespeist, wo die Fahrten der Radfahrenden beginnen.

Die folgenden Einflussfaktoren wurden in keinem der analysierten Verkehrsmodelle berücksichtigt:

- Breite der Verkehrsanlage
- Möglichkeit zum Überholen
- Anteil Pedelecs
- Präsenz von Fußgängern
- Maximale Steigung im Verlauf der Route
- Kontinuität der Radverkehrsanlage im Verlauf der Route
- Ruhender Kraftfahrzeugverkehr
- Beleuchtung
- Soziale Sicherheit/Angsträume
- Infrastruktur für bzw. Führung des Radverkehrs an Knotenpunkten
- Einfluss des Wetters

3. Soll-Ist-Vergleich

In diesem Kapitel werden die zusammengestellten Einflussfaktoren im Soll-Katalog (Teil 1 Kapitel 3) dem Ist-Zustand aus Perspektive der Modellierung (Teil 2 Kapitel 2) gegenübergestellt und um die Verfügbarkeit in bestehenden Datenquellen ergänzt. Basierend auf den „Empfehlungen für Verkehrserhebungen“ (vgl. FGSV, 2012) können Datenquellen für die Verkehrsplanung und -modellierung in 1. Zähl- und Messdaten, 2. Messungen, 3. Beobachtungen, 4. Mobilitätsbefragungen,

5. Erhebungen zu hypothetischen Situationen, 6. qualitative Methoden und 7. sekundäre Datenquellen zur Erweiterung der Datenbasis unterteilt werden.

Zählraten

Zählraten messen Standortveränderungen von z. B. nicht-motorisiertem Verkehr wie Radfahrenden (vgl. FGSV, 2012). Da manuelle Zählungen fehleranfällig sind (vgl. Turner & Lasley, 2013), bieten Dienstleistende (wie u. a. „Mio-Vision“) Kameras und auf künstlicher Intelligenz basierende Algorithmen an, um Zählraten aus Videomaterial automatisch zu ermitteln (vgl. Yan et al., 2016). Stationäre Zählstationen wie „Eco-Counter“ nutzen Induktionsschleifensysteme, um Radfahrende mit einer Genauigkeit zwischen 73 und 93 Prozent zu zählen (vgl. Nytepchuk, 2019). Obwohl die Daten räumlich begrenzt sind, da sie nicht flächendeckend zur Verfügung stehen (vgl. Roy et al., 2019), können sie als Grundlage für die Bewertung weiterer Datenquellen wie Fahrrad-GPS-Trajektorien und Messungen genutzt werden.

Messungen

Messungen erfassen metrische Attribute wie Geschwindigkeit, Fahrzeiten, Warte- oder Parkdauern (vgl. FGSV, 2012) unter anderem durch die Erfassung von GPS-Trajektorien mithilfe digitaler Tools. Beispielsweise sammeln Routing-Apps wie „Strava“ oder „Komoot“ Trajektorien von GPS-Punkten durch Crowdsourcing (siehe z. B. Francke et al., 2018). Die von Strava zur Verfügung gestellten Daten werden bereits in Publikationen für die Schätzung der Verkehrsnachfrage, die Analyse der Fahrradroutenwahl und die Bewertung der Infrastruktur ausgewertet, wie Lee und Sener (2021) zeigen. Vorteile der Erfassung von GPS-Daten sind neben der Kosteneffizienz, eine hohe Qualität der Informationen über den Standort des Fahrzeugs (bis auf wenige Meter genau) sowie eine hohe Aufzeichnungsfrequenz (vgl. Duncan et al., 2009). Dies bedeutet, dass GPS-Daten die Beobachtung ganzer Trajektorien und damit Routenwahlen mit zusätzlichen Informationen über Geschwindigkeit und Beschleunigung sowie Wartezeiten an Kreuzungen oder Ampeln ermöglichen. Allerdings sind die erhobenen Stichproben mit sogenannten „GPS-Fehlern“ (vgl. Saki & Hagen, 2022) behaftet und in der Regel nicht repräsentativ (vgl. Plaudis et al., 2021). Dies erfordert, dass Fahrrad-GPS-Trajektorien aufbereitet (anhand eines Algorithmus an ein Straßennetz angepasst) und gewichtet werden müssen, um Rückschlüsse auf die zugrundeliegende Bevölkerung ziehen zu können.

Viele Studien erwähnen das Problem der geschlechts- und altersbezogenen Verzerrung in GPS-Fahrraddaten (vgl. u. a. Boss et al., 2018; Griffin & Jiao, 2015; Heesch & Langdon, 2016; Huber et al., 2019), wobei Frauen, Kinder und ältere Menschen unterrepräsentiert sind. Kwigizile et al. (2019) stellen eine Überrepräsentation von Radfahrenden fest, die mit dem Wegezweck Freizeit unterwegs sind, im Vergleich zu Pendelnden oder Radfahrenden im Alltag. Darüber hinaus weisen Studien auf eine Verzerrung von städtischen (vgl. Leao et al., 2017) und einkommensschwachen Bevölkerungsgruppen (vgl. Blanc et al., 2016) hin. Im Allgemeinen machen die Aufzeichnungen von „Power-Usern“ einen großen Anteil der aufgezeichneten Trajektorien aus (vgl. bspw. Francke et al., 2018; Heesch & Langdon, 2016; Romanillos et al., 2016).

Beobachtungen

Beobachtungen messen äußere Merkmale und das Verhalten von Nutzenden (vgl. FGSV, 2012). Meist beschränken sie sich auf visuelle Beobachtungen. Manuelle Beobachtungen erfordern eine intrinsische Motivation des Erhebungspersonals und können zu Ungenauigkeiten führen. Um Fehler zu minimieren, ist es wichtig, die Mitarbeitenden zu schulen und die Ergebnisse zwischen verschiedenen Personen zu wiederholen und zu vergleichen, um die Qualität der Daten

sicherzustellen (vgl. Hagen et al., 2023). Um die Geschwindigkeit bei der Beobachtung zu verringern, können Video- oder Bilddaten und Annotations-Tools zur Kennzeichnung bestimmter Merkmale verwendet werden. Als Beispiel untersuchen Wu et al. (2012) das Verhalten von Radfahrenden mithilfe von Videokameras. Sakshaug et al. (2010) konzentrieren sich auf Konflikte bei Videoaufzeichnungen an zwei Kreisverkehren. Neuartige Ansätze werten Beobachtungsdaten aus Videoaufzeichnungen aus, um Machine-Learning-Algorithmen zu trainieren, die Muster automatisch erkennen.

Mobilitätsbefragungen

Mit Mobilitätsbefragungen kann das persönliche Verhalten evaluiert werden (vgl. FGSV, 2012). Die wichtigsten deutschlandweiten repräsentativen Mobilitätsbefragungen sind „Mobilität in Deutschland“ (MiD) und „Mobilität in Städten“ (SrV). Mobilitätsbefragungen kombinieren Fragen zur Verkehrsmittelwahl und Demografie mit Wegetagebüchern. Befragungsdaten können im Allgemeinen durch Faktoren wie soziale Erwünschtheit (z. B. Lajunen & Summala, 2003), Selbstselektion (vgl. Heesch & Langdon, 2016), Nonresponse oder Gedächtnislücken (z. B. Roeser & Vohs, 2012) verzerrt werden. Ein weiterer Nachteil von Mobilitätsbefragungen ist, dass sie aufgrund ihrer geringen Wiederholungshäufigkeit schnell veralten (vgl. Willumsen, 2021). Sie können jedoch verwendet werden, um neue Datenquellen wie GPS-Trajektorien zu gewichten, um Repräsentativität (für die Population der Radfahrenden) zu erreichen. Im Hinblick auf Wegetagebücher in Deutschland werden im Status quo Fragebögen (manuell oder online) zur Datenerhebung eingesetzt. Zhao et al. (2015) weisen auf Probleme hin, wie z. B. die Untererfassung von kurzen Fahrten, ungenaue Ort- und Zeitangaben sowie die Berichterstattung über einen „typischen“ Tag anstatt des tatsächlichen Tages.

Erhebungen auf der Grundlage hypothetischer Situationen

Als Erweiterung können Erhebungen auf der Grundlage hypothetischer Situationen durchgeführt werden (vgl. FGSV, 2012). Tabelle 12 vergleicht die Erhebungsmethoden der Revealed Preferences (RP) und Stated Preferences (SP) im Zusammenhang mit verschiedenen Methoden zur Erhebung von Mobilitätsdaten. RP-Erhebungsmethoden erfassen Entscheidungen, die Personen tatsächlich getroffen haben (vgl. dell'Olio et al., 2018). Beispielsweise geben Wegetagebücher als Teil von Mobilitätsbefragungen Aufschluss über die Wahl des Verkehrsmittels.

Tabelle 12: Revealed und stated Preferences im Kontext verschiedener Methoden zur Erhebung von Mobilitätsdaten in Anlehnung an Hagen & Reinfeld (2021)

	Revealed Preferences	Stated Preferences
Befragungen	Erhebungsform: Wegetagebuch	Erhebungsform: Hypothetischer Vergleich zwischen Alternativen
	Nachteil: Verzerrte Aussagen (vgl. Zhao et al., 2015)	Nachteil: Unaufmerksamkeit, fehlende Attribute, Inkongruenz mit der RP (vgl. Danaf et al., 2019)
Messungen	Erhebungsform: GPS-Tracking mit Fragen z. B. zum Zweck der Reise	Erhebungsform: Referenzszenario vs. hypothetische Alternativen (RP-basiert)
	Nachteil: Technische Probleme, Genauigkeit der GPS-Ortung (vgl. Bierlaire et al., 2010)	Nachteil: Repräsentativität (vgl. Weber & Bauder, 2013), Wahl Referenzszenario (vgl. Danaf et al., 2019)

Neben den oben erwähnten Nachteilen von Wegetagebüchern besteht ein weiterer Nachteil von RP-Studien darin, dass sie nur Mobilitätsangebote widerspiegeln, die bereits existieren (vgl.

Matyas & Kamargianni, 2017). SP-Experimente können dies lösen, indem sie hypothetische Situationen bezüglich der Verkehrsmittel- oder Routenwahl präsentieren (vgl. dell'Olio et al., 2018). Die Teilnehmenden bewerten aufeinanderfolgende Situationen mit unterschiedlichen Merkmalen und können entscheiden, welche Situation sie wählen würden. Hypothetische Situationen werden durch eine Reihe von Merkmalen charakterisiert und können so Mobilitätsangebote beinhalten, die noch nicht auf dem Markt existieren (vgl. Matyas & Kamargianni, 2017; Willumsen, 2021). Stated Preferences und Wahlmöglichkeiten werden häufig zur Beantwortung von Forschungsfragen zur Routenwahl (vgl. z. B. Hardinghaus & Nieland, 2021; Sener et al., 2009; Stinson & Bhat, 2003; Vedel et al., 2017) oder zu Fahrradanlagen (vgl. z. B. Caulfield et al., 2012; Hunt & Abraham, 2007; Tilahun et al., 2007) verwendet.

Qualitative Methoden

Qualitative Methoden werden eingesetzt, um subjektive Faktoren wie Motivationen, Gefühle und Einstellungen der Teilnehmenden zu messen (vgl. FGSV, 2012). Subjektive Faktoren beeinflussen das Mobilitätsverhalten und sollten zusätzlich zu den objektiven Faktoren in Verkehrsmodellen berücksichtigt werden (vgl. Heinrichs & Jarass, 2020). Zu den qualitativen Methoden gehören z. B. Tiefeninterviews und Fokusgruppen.

Sekundäre Datenquellen

Zu den sekundären Datenquellen gehören Verwaltungsdaten, Geodaten, Handydaten, Unfalldaten usw. (vgl. FGSV, 2012). In den letzten Jahren hat sich OpenStreetMap (OSM) zu einer sehr wichtigen Quelle entwickelt. Orellana und Guerrero (2019) verwenden beispielsweise OSM-Daten neben GPS-Trajektorien mit dem Fahrrad, um den Einfluss der Straßennetzstruktur auf das räumliche Verhalten von Radfahrenden zu untersuchen. Die OSM-Community beteiligt sich durch Kartierung, d. h. durch das Sammeln von Kartendaten mit einem GPS-Gerät. Daher sind die OSM-Daten kostenlos verfügbar. Aufgrund des Community-Ansatzes sollten Zuverlässigkeitsprobleme hinsichtlich der Qualität (vgl. Kaur et al., 2017) berücksichtigt werden (vgl. Seybold, 2017).

Tabelle 13 zeigt die Datenverfügbarkeit und bisherige Berücksichtigung der Einflussfaktoren bei der Moduswahl auf. Ausgewählte Einflussfaktoren werden in den folgenden Abschnitten detaillierter beleuchtet. Die meisten soziodemografischen und -ökonomischen Merkmalen sind implizit über die verhaltenshomogenen Gruppen oder Wegezwecke in den Modellen enthalten. Je nach Modellierungsansatz können auch Altersgruppen in der Modellierung berücksichtigt werden. Für die Prognose spielen sog. „Kohorten-Effekte“ eine Rolle. Sie basieren auf der Annahme, dass die Mobilität des Einzelnen von aktuellen gesellschaftlichen Entwicklungen, der individuellen Lebensphase und -situation sowie den Trends innerhalb der eigenen Generation (sog. „Kohorte“) abhängt. Angaben wie das Geschlecht, der Migrationshintergrund, Mobilitätseinschränkungen und Haushaltsgrößen sind aufgrund der praktischen Relevanz zur Prognose nicht enthalten (vgl. Kapitel 4). Ein weiterer Grund ist, dass die Datenverfügbarkeit ist aufgrund des Datenschutzes nicht flächendeckend gegeben ist. Auf dem Detaillierungsgrad von Gitterzellen existieren allerdings für einzelne Einflussfaktoren aggregierte abgeschätzte Daten (z. B. Scientific Use Files RWI).

Die Datenlage zur Verfügbarkeit von Verkehrsmitteln ist für gängige Verkehrsmittel aus Befragungen und Daten des statistischen Bundesamts (bspw. Anzahl Pkw) flächendeckend bekannt und zugänglich. Allerdings ist eine Differenzierung zwischen der Art des Pkw (u. a. zur Berücksichtigung eines Dienstwagens) aufgrund der Datenlage nicht möglich. Der Führerschein kann als Indikator für die Fortschreibung der Verkehrsmittelverfügbarkeit in der Prognose

verwendet werden. Allerdings sind auch dort Kohorten-Effekte zu berücksichtigen, die im Hinblick auf die Frage analysiert werden müssen, ob es sich bei der veränderten Führerscheinquote junger Menschen um ein Resultat sich verändernder Lebensumstände (häufiger Studium anstatt betrieblicher Ausbildung und danach Erwerbstätigkeit) oder aber um eine dauerhafte Verhaltensänderung bei gegebenen Lebensumständen handelt. Mit Blick auf den Radverkehr, wird die Verfügbarkeit eines Fahrrads aufgrund der weiten Verbreitung in der Bevölkerung nicht in Modellen berücksichtigt. Eine Abschätzung der Mengengerüste für neuere Fahrräder wie Pedelecs und Lastenräder ist aus Datenverfügbarkeitsperspektive nicht möglich. Dies gilt auch für neuere Mobilitätsangebote wie Sharing (insb. für Free Floating Angebote). Darüber hinaus werden Fahrradabstellanlagen zum Teil bereits in Modellen berücksichtigt (vgl. Tabelle 6), allerdings sind keine flächendeckenden Daten zu Abstellanlagen verfügbar.

Daten zu Kostenkomponenten sind insgesamt ausreichend gut verfügbar und bereits in Modellen enthalten. Allein Anreize des Arbeitgebers (wie Kompensationen für nachhaltige Mobilität, Mobilitätsbudget oder Ähnliches) sind aufgrund vertraglicher Verschwiegenheitsvereinbarungen nicht verfügbar und bislang wegen der fehlenden Durchdringung in der Bevölkerung auch (noch) nicht in Modellen enthalten. Aktuell beschäftigen sich allerdings bereits einige Forschungsprojekte mit dem Einfluss von Mobilitätsbudgets (siehe u. a. MoBudget, 2023, InnaMo Ruhr, 2023).

Eines der wichtigsten der zeitlichen Merkmale – die Reisezeit – wird in Modellen häufig mit Routing Engines (automatisierte Verteilung) dargestellt. Allerdings unterschätzen Routing Engines die tatsächliche Reisezeit. McBain & Caulfield (2018) quantifizieren die durchschnittliche Differenz auf 1,3 Minuten mit einer Standardabweichung von 4,1 Minuten. Reisezeiten aus GPS-Trackings werden hingegen häufig durch rad-affine „Power-User“ (Vielfahrende) verfälscht. Weitere zeitliche Einflussfaktoren insb. mit Freizeitbezug sind das Verhalten an Wochenenden, in Ferien und an Feiertagen. Diese sind relevant für Tourismus-Modelle und stehen nicht im Fokus des Berichts. Zur Einschätzung der Hauptverkehrszeiten wächst die Datenverfügbarkeit aktuell aufgrund zunehmender Zählstellen für den Radverkehr und die Zurverfügungstellung in Open Data-Portalen. Wetterdaten sind als historische Wetterdaten für Wetterstationen des DWD verfügbar (Luftdruck, Temperatur, Bewölkung, Dampfdruck und relative Feuchte, Erdbodenzustand, Sichtweite, Wind, Niederschlag, Wetterphänomene). Sie werden für die Bereinigung von Erhebungsdaten verwendet. In Prognosen wird allerdings gleichbleibendes Wetter angenommen. Bei räumlichen Merkmalen stellt insbesondere die Radinfrastruktur einen Einflussfaktor dar, der aufgrund der fehlenden digitalen Verfügbarkeit ein Problem als Eingangsgröße darstellt. Dies trifft auch auf das Netz an Gehwegen zu. Da diese allerdings nicht in Modellen abgebildet werden, weist diese Lücke eine entsprechend geringe Priorität auf.

Tabelle 13: Soll-Ist-Katalog Moduswahl

Soziodemografische und -ökonomische Merkmale			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Alter	mittel	Daten für 100x100m Gitterzelle oder auf Straßenabschnittsebene von kommerziellen Anbietern (abgeschätzt verfügbar) z. B. als Scientific Use Files (RWI)	Z. T., je nach Modellierungsansatz Integration möglich
Geschlecht	gering	Daten für 100x100m Gitterzelle oder auf Straßenabschnittsebene von kommerziellen Anbietern (abgeschätzt verfügbar) z. B. als Scientific Use Files (RWI)	Nein → Annahme: Keine Veränderung des Geschlechterverhältnisses in Zukunft
Migrationshintergrund	gering	Daten für 100x100m Gitterzelle oder auf Straßenabschnittsebene von kommerziellen Anbietern (abgeschätzt verfügbar) z. B. als Scientific Use Files (RWI)	Nein → Keine praktische Bedeutung
Mobilitätseinschränkungen	gering	Über Mobilitätsbefragungen (MiD, SrV) verfügbar; allerdings nicht nach Verkehrszellen	Nein
Haushaltsgröße	gering	Haushaltsgeneratoren (wird in Kommunen/Städten geschätzt)	Nein
Kinder im Haushalt	gering	Über Mobilitätsbefragungen (MiD, SrV) verfügbar; allerdings nicht nach Verkehrszellen	Indirekt, Kinder über Wegezwecke enthalten
Schüler*in oder Student*in	gering	Für verhaltenshomogene Gruppen bevölkerungsrepräsentativ über Mobilitätsbefragungen (MiD, SrV) verfügbar Zum Teil über Schuleinzugsgebiete, Studentenwohnheime Aus MiD auf Gemeindeverbandebene	Indirekt, über Wegezweck Hochschule und verhaltenshomogene Gruppen enthalten → Qualifikationsniveau zum Teil bereits enthalten → Korrelation mit Einkommen
Arbeitszeit	hoch	Daten für 100x100m Gitterzelle oder auf Straßenabschnittsebene von kommerziellen Anbietern (abgeschätzt verfügbar) z. B. als Scientific Use Files (RWI) Für verhaltenshomogene Gruppen bevölkerungsrepräsentativ über Mobilitätsbefragungen (MiD, SrV) verfügbar	Indirekt, Beschäftigung über Wegezweck und verhaltenshomogene Gruppen enthalten
Einkommen	gering	Daten für 100x100m Gitterzelle oder auf Straßenabschnittsebene von kommerziellen Anbietern (abgeschätzt verfügbar) z. B. als Scientific Use Files (RWI) → ggf. über Mietspiegel ableitbar	Nein

Tabelle 13: Soll-Ist-Katalog Moduswahl (Fortsetzung)

Verfügbarkeit von Verkehrsmitteln			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Anzahl Pkw	hoch	Pkw pro Einwohner (Verfügbarkeit in %) -> öffentliche Statistik für private Pkw In MiD Lokaldatensatz enthalten (500x500m)	Ja, über Attribut Pkw-Verfügbarkeit oder direkt als Anzahl „Pkw je Einwohner“
Dienstwagen	hoch	Keine Daten verfügbar	Nein
Führerschein	mittel	In MiD Lokaldatensatz enthalten (500x500m)	Z. T., kann ein Indikator für Fortschreibung der Verkehrsmittelverfügbarkeit in Prognose sein, Hilfsgröße
Anzahl Fahrräder	gering	In MiD Lokaldatensatz enthalten (500x500m)	Nein, da nahezu flächendeckende Verfügbarkeit gegeben
Fähigkeit, Fahrrad zu fahren	gering	Keine Daten verfügbar	Nein
Fahrradabstellanlage	mittel	Keine flächendeckenden Daten verfügbar MiD Modul zur Fahrradnutzung (Standarddatensatz)	Ja punktuell, wenn Daten verfügbar
Entfernung Bikesharing-Station	gering	Keine flächendeckenden Daten verfügbar, insb. Free Floating Angebote nicht abbildbar	Nein
Zeitkarte ÖV	hoch	Den Verkehrsverbänden bekannt In MiD Lokaldatensatz enthalten (500x500m)	Ja
ÖV-Angebot	hoch	Aus MiD auf Gemeindeverbandebene, OSM, Routing-Apps von Verkehrsverbänden	Ja, komplett enthalten mit allen Kenngrößen
Entfernung Haltestelle	hoch	Aus MiD auf Gemeindeverbandebene, OSM, Routing-Apps von Verkehrsverbänden	Ja
Kostenkomponenten			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Kraftstoffkosten	hoch	Öffentlich zugängliche Datenbanken	Ja
Ticketpreis ÖV	hoch	Verkehrsverbänden bekannt, öffentlich zugänglich	Ja
Parkgebühren	hoch	Kommunen bekannt, öffentlich zugänglich	Ja
Leihgebühren Sharing	gering	Heterogene Datenlage aufgrund verschiedener Anbietender	Nein
Straßennutzungsentgelte	hoch	Kommunen bekannt, öffentlich zugänglich	Ja
Anreize Arbeitsgeber	mittel	Schlechte Datenverfügbarkeit → Vertragliche Verschwiegenheitsvereinbarungen	Nein

Tabelle 13: Soll-Ist-Katalog Moduswahl (Fortsetzung)

Zeitliche Merkmale			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Reisezeit	hoch	wird geschätzt z.B. über Google Reisezeit → ggf. etwas zu schnell und hoch korreliert mit Länge Reisezeiten über GPS-Tracking nicht flächendeckend	Ja
Wochentage	gering	Gute Datenverfügbarkeit (MiD, SrV)	Z. T., relevant für touristisch geprägte Modelle → Korrelation zu Wegezweck
Ferien	gering	Gute Datenverfügbarkeit (MiD, SrV)	Z. T., relevant für touristisch geprägte Modelle → Korrelation zu Wegezweck
Feiertag	gering	Gute Datenverfügbarkeit (MiD, SrV)	Z. T., relevant für touristisch geprägte Modelle → Korrelation zu Wegezweck
Jahreszeit	gering	Gute Datenverfügbarkeit (MiD, SrV), Zählstellen, Open-Data-Portale	Indirekt, wichtig für die Hochrechnung und Datenaufbereitung z. B. von Zählungen → für Modell an sich keine große Rolle
Hauptverkehrszeit	hoch	Wachsende Datenverfügbarkeit über Zählstellen, Open-Data-Portale	Ja, Kenngrößen wie Reisezeit oder Bedienungshäufigkeit werden repräsentativ für Morgen- und Abendspitze bestimmt.
Dunkelheit	gering	Wachsende Datenverfügbarkeit über Zählstellen, Open-Data-Portale, Befragungen wie Fahrradmonitor	Nein, Mittelwerte werden gleichbleiben
Parkplatzsuche	hoch	Aktuell noch keine gute Datenbasis → Projekt Start2Park möchte Parksuchdauer quantifizieren	Ja, Parksuchzeit abgeschätzt
Wartezeit	hoch	Wartezeiten an Knotenpunkten für Pkw gut zu berechnen nach Abbiegerelationen Für den Radverkehr Datenverfügbarkeit noch gering	Ja, (siehe Routenwahl)
Zusätzlicher Fußweg	hoch	Für Pkw korreliert mit Parkdruck Für ÖV Haltestellendichte, Abschätzung wie lange man zur nächsten Haltestelle läuft	Ja, wird über Parkdruck abgeschätzt
Anzahl der Umstiege	hoch	Gut bekannt wegen aktuellen Fahrplänen Für Zukunft keine anschlussoptimierten Fahrpläne	Ja
Umstiegszeiten	hoch	Kann häufig aufgrund der Datenlage nicht geschätzt werden (90% der Verbindungen sind direkt → bei Befragungen keine Ergebnisse)	Ja, muss für Prognose abgeschätzt werden
Takt des ÖV	hoch	Kann häufig aufgrund der Datenlage nicht geschätzt werden (90% der Verbindungen sind direkt → bei Befragungen keine Ergebnisse)	Ja

Tabelle 13: Soll-Ist-Katalog Moduswahl (Fortsetzung)

Wetter			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Alle wetterbezogenen Faktoren	hoch	Historische Wetterdaten für Wetterstationen des DWD verfügbar (Luftdruck, Temperatur, Bewölkung, Dampfdruck und relative Feuchte, Erdbodenzustand, Sichtweite, Wind, Niederschlag, Wetterphänomene)	Indirekt, für die Bereinigung von Erhebungsdaten → in Prognosen gleichbleibendes Wetter → Einfluss auf Modus-, Routen- und Zielwahl → Korrelation mit Ferien, Arbeitsmodell
Räumliche Merkmale			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Distanz	hoch	In MiD und SrV gute Datenverfügbarkeit	Ja → wichtig von der Reisezeit zu separieren
Topographie	hoch	In MiD und SrV Datenverfügbarkeit auf Gemeindeverbandsebene, Einfluss auf Moduswahl in Stated Choice Experimenten	Ja sowohl als Einflussfaktor auf die Reisezeit als auch als Einflussfaktor auf den empfundenen Widerstand
Infrastruktur (Fahrrad)	hoch	Noch nicht digitalisiert	Z. T., Problem als Eingangsgröße
Infrastruktur (Gehweg)	gering	Noch nicht digitalisiert	Nein, wird in Modellen nicht abgebildet
Flächennutzung (Dichte)	gering	Über öffentliche Statistiken, OSM	Ja, als Eingangsgrößen: Verkehrszellen, Bevölkerung, POI
Flächennutzung (Vielfalt)	gering	Über öffentliche Statistiken, Flächennutzungspläne	Ja, als Eingangsgrößen: Verkehrszellen, Bevölkerung, POI
Flächennutzung (Design)	gering	Einfluss auf Moduswahl in Stated Choice Experimenten	Ja, im Prinzip über Zeit- und Kostenkomponenten abgebildet
Straßennetzgestaltung	gering	Einfluss auf Moduswahl in Stated Choice Experimenten	Ja, über Zeit- und Kostenkomponenten abgebildet
Natur	mittel	Grünflächen etc. gut in Flächennutzungsplänen bekannt	Z. T., schwierig zu ermitteln, welches Element die Wahl beeinflusst
Andere reisebezogene Komponenten			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Mitreisende	gering	gute Datengrundlage in MiD und SrV	Indirekt enthalten, Korrelation mit Zweck, z. B. Bahnhof als Ziel mit Zweck Holen & Bringen
Gepäck	gering	gute Datengrundlage in MiD und SrV	Indirekt enthalten, Korrelation mit Zweck, z. B. Bahnhof als Ziel mit Zweck Holen & Bringen
Reisezweck: Freizeit	hoch	gute Datengrundlage in MiD und SrV	Ja, wegezweckfeiner Modal Split
Reisezweck: Arbeit	hoch	gute Datengrundlage in MiD und SrV	Ja, wegezweckfeiner Modal Split
Reisezweck: Schule	hoch	gute Datengrundlage in MiD und SrV	Ja, wegezweckfeiner Modal Split
Reisezweck: Einkaufen	hoch	gute Datengrundlage in MiD und SrV	Ja, wegezweckfeiner Modal Split
Auslastung	hoch	Keine weiteren Daten notwendig	Ja
Sicherheit (objektiv)	mittel	Unfallatlas enthält Daten zu Unfällen mit Koordinaten, keine Daten zu Beinahe-Unfällen	Nein, nur subjektiv über Verkehrsstärke Pkw und Kfz

Tabelle 14 zeigt die Datenverfügbarkeit und bisherige Berücksichtigung der Einflussfaktoren bei der Routenwahl. Ausgewählte Einflussfaktoren werden in den folgenden Abschnitten detaillierter beleuchtet. *Soziodemografische und -ökonomische Merkmale* spielen aufgrund rechentechnischer Gründe eine untergeordnete Rolle bei der Modellierung der Routenwahl. Hinsichtlich des *Fahrradtyps* ist eine Abschätzung der Mengengerüste für Fahrräder wie Pedelecs und Lastenräder aus Datenverfügbarkeitsperspektive (noch) nicht möglich. Arning et al. (2023) weisen allerdings darauf hin, dass mit Neuaufgabe der Mobilitätsbefragungen, aktuell noch bestehende Datenlücken geschlossen werden können. Eine repräsentative flächendeckende Datenbasis von GPS-Trajektorien ist nicht verfügbar. Lißner (2022) weist darauf hin, wie GPS-Trajektorien gewichtet werden können, um ein repräsentatives Sample zu erreichen und betont, dass die Datensätze im besten Fall bereits bevölkerungsrepräsentativ erhoben werden sollten.

Bei den für die Routenwahl besonders relevanten *räumlichen Merkmalen* sind noch Datenlücken vorhanden. Während die Distanz der Wege gut aus Wegetagebüchern und GPS-Trackings abgeleitet werden kann, bestehen Probleme bei der Topographie und Infrastruktur. Die topographischen Modelle unterscheiden zwischen der Netzebene und dem Geländeprofil. Während das Geländeprofil vorhanden ist, fehlen häufig Angaben über die Topographie des Netzes. Als Beispiel kann eine Flussüberquerung genannt werden. Im Modell ist das Höhenprofil des Flusses enthalten. Der Radweg verläuft allerdings über eine Brücke und muss mit diesem Höhenprofil attribuiert werden. Die Radverkehrsinfrastruktur ist in den Kommunen häufig vorhanden, allerdings nicht in digitalisierter Form. Zum Teil kann dies durch OSM und Routing Apps wie Komoot ausgeglichen werden, allerdings ist dies mit Attribuiierungsaufwand verbunden und zum Teil nicht flächendeckend verfügbar. Aktuell versuchen Projekte die Oberflächenbeschaffenheit oder Breite von Infrastruktur basierend auf Sensordaten oder LiDAR-Scans und Kameras zu ermitteln (vgl. bspw. Projekt INFRASense, AKhoch2, aZuR). Das Verkehrsaufkommen von Radfahrenden und Zufußgehenden ist aufgrund (noch) nicht verfügbarer Zählstellen ebenfalls erst lückenhaft vorhanden.

Tabelle 14: Soll-Ist-Katalog Routenwahl

Soziodemografische und -ökonomische Merkmale			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Alle persönlichen oder Haushaltsmerkmale	gering	Persönliche Informationen für Routenwahl <ul style="list-style-type: none"> • nicht flächendeckend • nicht repräsentativ • nicht enthalten (Datenschutzgründe) → Projekt FLOBIDAS versucht eine Datenraum für Floating Bike Data aufzubauen → Movebis stellt Kommunen aggregierte GPS-Daten in einem Dashboard zur Verfügung	Nein, auf der Umlegungsebene keine Personengruppen → rechentechnische Gründe Radaffinität als Einflussfaktor auf den empfundenen Widerstand enthalten
Fahrradtyp			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Pedelec / herkömmliches Fahrrad	hoch	Keine aktuellen flächendeckenden Angaben, in MiD auf Lokalebene enthalten (500x500m)	(Noch) nicht modellierter Einflussfaktor auf die Reisezeit -> Untersuchungen der Uni Wuppertal
Zeitliche Merkmale			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Reisezeit	hoch	Identisch zu Moduswahl	Ja, identisch zu Moduswahl
Umstiegsmöglichkeiten	mittlere	In MiD und SrV keine Etappen enthalten → 2017 MiD Feldversuch zur Etappenerfassung	Z. T., für den Radverkehr sehr rudimentär, verlängerte Zugangsmöglichkeiten zum ÖV (Bahnhöfe mit höherem Einzugsbereich), Routensuche über Modi hinweg, Kopplung mit Park & Ride schwierig (um Stadt herum), Fahrradmitnahme nicht enthalten, keine Möglichkeit
Umwege	hoch	Studien zu Umwegen im Vergleich zur kürzesten Route, Vergleich von GPS-Routen mit Routingalgorithmen	Mit Sensitivität, Zusammenhang mit Fahrzeit und Länge
Wetter			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Alle wetterbezogenen Faktoren	gering	Wetterdatenverfügbarkeit siehe Moduswahl → Einfluss des Wetters auf Routenwahl zum Teil in Stated Choice/ Stated Preference Experimenten enthalten	(Noch) nicht modellierter Einflussfaktor auf empfundenen Widerstand

Tabelle 14: Soll-Ist-Katalog Routenwahl (Fortsetzung)

Räumliche Merkmale			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Distanz	hoch	Gut, z.B. über GPS-Tracking, Wegetagebücher (MiD, SrV)	Ja
Topographie	hoch	Höhenprofile vorhanden → Allerdings Unterschiede zwischen Netzebene und Höhenprofil	Ja, Längsneigung sowohl als Einflussfaktor auf Reisezeit als auch auf den empfundenen Widerstand enthalten Höhendifferenz im Verlauf der Route als Einflussfaktor auf den empfundenen Widerstand enthalten Maximale Steigung im Verlauf der Route (noch) nicht modellierter Einflussfaktor auf empfundenen Widerstand
Radinfrastruktur	hoch	Häufig in Kommunen vorhanden, zum Teil in OSM öffentlich zugänglich, in Komoot enthalten	Ja, sowohl als Einflussfaktor auf Reisezeit als auch auf den empfundenen Widerstand enthalten Radabstellanlagen als Einflussfaktor auf den empfundenen Widerstand enthalten
Oberfläche der Fahrbahn	hoch	Relativ häufig vorhanden, Informationen in Radroutenplanern enthalten	Ja, sowohl als Einflussfaktor auf Reisezeit als auch auf den empfundenen Widerstand enthalten
Bahngleise	hoch	Den Kommunen bekannt, zum Teil in OSM öffentlich zugänglich	(Noch) nicht modellierter Einflussfaktor auf empfundenen Widerstand
Breite der Fahrbahn	hoch	Anzahl der Spuren zum Teil in OSM enthalten	(Noch) nicht modellierter Einflussfaktor auf die Reisezeit
Kontinuität der Infrastruktur	hoch	Einfluss der (Nicht-)Kontinuität auf Routenwahl in Studien enthalten	(Noch) nicht modellierter Einflussfaktor auf empfundenen Widerstand
Festgelegte Fahrradkorridore	hoch	Den Kommunen bekannt, zum Teil in OSM öffentlich zugänglich	Ja, als Einflussfaktor auf den empfundenen Widerstand enthalten
Brücken	gering	Den Kommunen bekannt	Ja, bei der Ziel- und Moduswahl enthalten (Flusswiderstandsmatrix) Trennwirkung durch Flüsse, Brücken oder Bahndämme als Einflussfaktoren auf den empfundenen Widerstand enthalten
Einbahnstraße	hoch	Den Kommunen bekannt, zum Teil in OSM öffentlich zugänglich	Ja, als Einflussfaktor auf Reisezeit enthalten
Verkehrsaufkommen Kraftfahrzeuge	hoch	Keine weiteren Daten notwendig	Ja, als Einflussfaktor auf den empfundenen Widerstand enthalten
Verkehrsaufkommen Schwerverkehr	hoch	Keine weiteren Daten notwendig	Ja, als Einflussfaktor auf den empfundenen Widerstand enthalten
Verkehrsaufkommen Fahrradfahrende	hoch	Zählstellen noch nicht flächendeckend verfügbar → zukünftig wichtige Datenquelle Projekte arbeiten an der Unterscheidung zwischen Fußgängern und Radfahrenden	(Noch) nicht modellierte Einflussfaktoren auf die Reisezeit und auf empfundenen Widerstand → für zukünftige Modelle wichtige Rolle
Verkehrsaufkommen Zu Fußgehende	hoch	Zählstellen noch nicht flächendeckend verfügbar → zukünftig wichtige Datenquelle Projekte arbeiten an Unterscheidung zw. Fußgängern und Radfahrenden	(Noch) nicht modellierte Einflussfaktoren auf die Reisezeit und auf empfundenen Widerstand → für zukünftige Modelle wichtige Rolle

Tabelle 14: Soll-Ist-Katalog Routenwahl (Fortsetzung)

Räumliche Merkmale			
Einflussfaktor	Priorität	Datenverfügbarkeit	In Modellen enthalten?
Geschwindigkeit angrenzender Verkehr	hoch	Daten liegen nicht immer vor, zum Teil in OSM enthalten oder Kommunen bekannt	Ja, als Einflussfaktor auf den empfundenen Widerstand enthalten bekannt in Modellen (unterschied zwischen gefahrener & erlaubter Geschwindigkeit) → in Kombination mit Radverkehrsanlagen
Parkende Fahrzeuge	mittel	Keine flächendeckenden Daten → aus dem Luftbild theoretisch bekannt	(Noch) nicht modellierter Einflussfaktor auf empfundenen Widerstand
Fahrradabstellanlagen	hoch	Keine flächendeckenden Daten	Ja, punktuell enthalten über Anbindungen
Kreuzungen, Abbiegungen oder Halten, Verkehrssignalanlagen und Schilder	hoch	Art der Knotenpunkte bekannt, zum Einfluss auf Routenwahl nur Stated Choice Experimente	Ja, Verlustzeit an Knoten und Zahl der beim Abbiegen gekreuzten Kraftfahrzeuge als Einflussfaktoren auf die Reisezeit enthalten, Dichte von Knoten im Verlauf der Route, Linksabbiegen, Streckenhierarchie beim Abbiegen und Zahl der beim Abbiegen gekreuzten Kraftfahrzeuge als Einflussfaktoren auf den empfundenen Widerstand enthalten, Regelungsart des Knotens und Radverkehrsführung am Knoten (noch) nicht modellierte Einflussfaktoren auf empfundenen Widerstand
POI	gering	Über OSM öffentlich zugänglich	Nein, keine Zweckabhängige Umlegung: Jeder Zwischenstopp → neuer Wegezweck
Flächennutzung, Natur	mittlere	Landnutzungsdaten verfügbar	Ja, sowohl als Einflussfaktor auf Reisezeit als auch auf den empfundenen Widerstand enthalten
Dichte Laternenbeleuchtung	mittlere	Keine Daten verfügbar	(Noch) nicht modellierter Einflussfaktor auf empfundenen Widerstand

4. Weiterer Forschungsbedarf

Zusätzlicher Forschungsbedarf wurde hinsichtlich des Einflusses *persönlicher Merkmale und Haushaltmerkmale* insbesondere für die Größen Einkommen und Bildung identifiziert. Auch die Haushaltsgröße und die Anzahl der Kinder im Haushalt sind Ansatzpunkte, um bestehende Modelle zu erweitern. Wenn ein solcher Parameter für die Routenwahl relevant ist, kann er auch bei der Moduswahl gemittelt über alle Routen berücksichtigt werden. Die praktische Relevanz ist aufgrund der Datenverfügbarkeit allerdings noch nicht gegeben. Da sich die Altersstruktur aufgrund der demographischen Entwicklung in Zukunft verändern wird, ist zukünftig Forschung zu „Kohorten-Effekten“ notwendig. So können Effekte auf die Mobilität des Einzelnen getrennt nach aktuellen gesellschaftlichen Entwicklungen, der individuellen Lebensphase sowie den Trends innerhalb der eigenen Generation betrachtet werden. So sollte im Hinblick auf die gesunkene Führerscheinquote junger Menschen untersucht werden, ob es sich um ein Resultat sich verändernder Lebensumstände (häufiger Studium anstatt betrieblicher Ausbildung und danach Erwerbstätigkeit) oder aber um eine dauerhafte Verhaltensänderung bei gegebenen Lebensumständen handelt.

Mit Blick auf die *Verfügbarkeit der Verkehrsmittel* ist die Datengrundlage noch nicht ausreichend, um Mengengerüste von Pedelecs und Lastenrädern zu modellieren. Darüber hinaus ist noch nicht hinreichend geklärt, ob Pedelec-Fahrende ihre Routen breiter streuen und gegenüber bestimmten Parametern wie beispielsweise der Topographie weniger sensitiv reagieren, als die Nutzenden von herkömmlichen Fahrrädern. Für den ÖV muss darüber hinaus evidenzbasiert definiert werden, was ÖV-Verfügbarkeit überhaupt bedeutet (bspw. Distanz zur nächsten Bushaltestelle). Außerdem sind Dienstwagen nicht in der Verfügbarkeitsstatistik enthalten und haben dementsprechend noch keine Auswirkung auf *Kosten* im Modell. Eine weitere Datenlücke ist hinsichtlich des Zusammenhangs zwischen *Kosten* und Kaufentscheidung (also Anschaffungskosten) vorhanden. Der größte Forschungsbedarf besteht für *zeitliche Einflussgrößen*:

- Die Reisezeit für das Fahrrad wird mithilfe von Routing-Engines abgeleitet.
- Wie groß sind Verlustzeiten für Radfahrende an Knotenpunkten?
- Wird eine Verlustzeit anders bewertet als eine konstant niedrigere Geschwindigkeit?
- Wird Parksuchzeit anders empfunden als Reisezeit?
- Wie hoch sind Fahrradzugangszeiten insbesondere bei großen Fahrradabstellanlagen? (Datenlücke)
- Wie hoch ist die durchschnittliche Zeit pro Umstieg im ÖV? (Datenlücke)
- Die tatsächliche Reisezeit für Wege zu Fuß ist unbekannt.
- Fußgängerinfrastruktur ist nicht in allen Kommunen (digitalisiert) vorhanden.
- Wie hoch sind LSA-Umlaufzeiten?
- Wie werden Umwege entlang der gesamten Route und entlang von Teilstücken bewertet?
- Wie konstant ist die Routenwahl? (Keine Vergleichsdaten vorhanden)

Für *räumliche Einflussgrößen* und die *gebaute Umwelt* ist ebenfalls Forschungsbedarf vorhanden:

- Wie werden Steigungen zeitlich bewertet?
- Gibt es einen sog. „Schwitzefaktor“ bei körperlich anstrengenden Fahrten?
- Ist die maximale Steigung ein Routenattribut oder Streckenattribut für Strecken, die aneinandergesetzt werden?
- Wie können Unterschiede im Eingangsdatenmodell und Geländemodell erkannt werden? Wie genau muss das Streckennetz sein?

- Wie kann der Einfluss von Natur (Grünflächen etc.) quantifiziert werden?
- Wie können Umwegfaktoren räumlich bewertet werden?

Als weitere Lücken wurden außerdem der Einfluss von Verkehrsstärken (und damit zusammenhängend der Verkehrssicherheit) auf den Modal Split und der Einfluss des Wetters auf die Routenwahl identifiziert.

Im weiteren Verlauf des Berichts wird ein Use Case präsentiert, um nicht vorhandene, aber ermittelbare Parameter basierend auf existierender Forschung herzuleiten. Darüber hinaus wird ein Erhebungskonzept dargestellt, um aktuell noch fehlende Daten zu erheben.

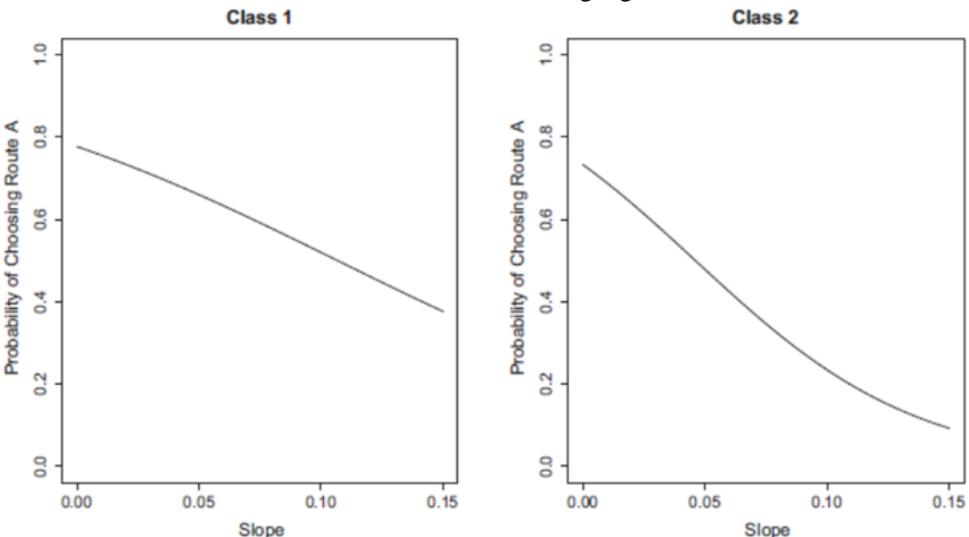
Teil III: Ermittlung/Aktualisierung ausgewählter Parameter basierend auf existierender Datenbasis & Erhebungskonzept für fehlende Daten/Parameter

1. Integration der beispielhaft ermittelten Parameter im Rahmen eines Use Cases

Im Rahmen eines Workshops wurden die verschiedenen Parameter vorgestellt und diskutiert. Darauf aufbauend wurde mit den Teilnehmenden diskutiert, welche Parameter im Rahmen eines Use Case vertieft untersucht werden sollten, um ihre Abbildung in Verkehrsmodellen weiterzuentwickeln. Der Austausch ergab, dass eine tiefere Betrachtung des Einflussfaktors Topographie für die Projektpartner von höchstem Interesse ist. Daher konzentrierte sich der Use Case auf die Betrachtung der Parameter des Einflussfaktors Topographie/Höhenunterschiede/Längsneigung.

Im Rahmen der Literaturrecherche wurde die Qualität und Quantität dieses Einflussfaktors in mehrere Publikationen nachgewiesen. Daher wurden für den Use Case zuerst die Publikationen zusammengetragen, die ein empirisches Ergebnis enthalten, aus welchem sich Parameter für das Verkehrsmodell ableiten lassen. Es wurden sechs Publikationen identifiziert. Diese sind in Tabelle 15 mit den wesentlichen Erkenntnissen dargestellt.

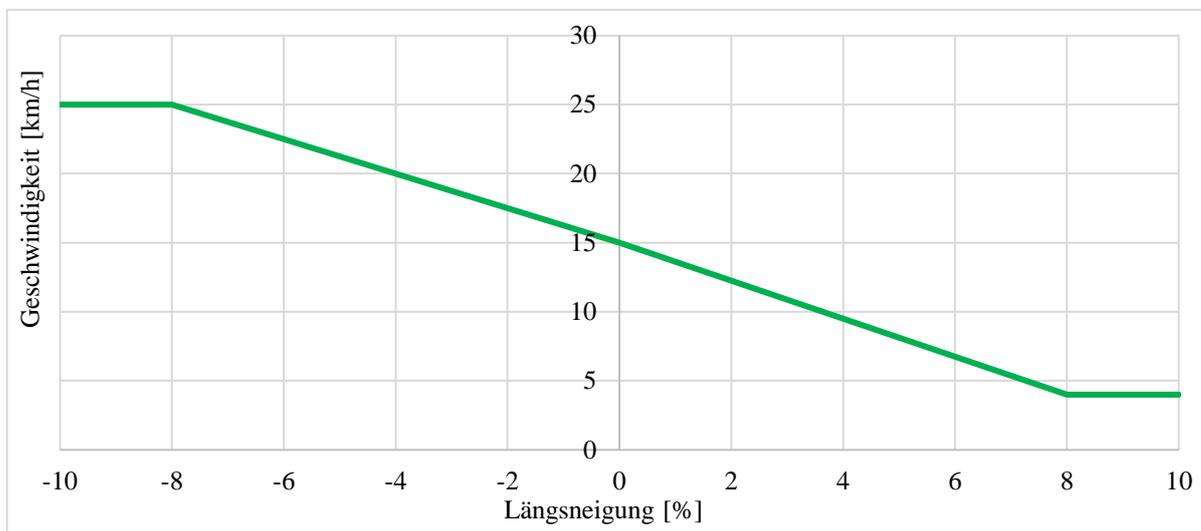
Tabelle 15: Literaturquellen für den Use Case

Quelle	Erkenntnis
Menghini et al. (2010)	Ein Anstieg der maximalen Steigung um 1 % wird wie eine Verlängerung der Distanz um 115 m empfunden
Prato et al. (2018)	Faktoren zur Berechnung der empfundenen Länge aus der Längsneigung
Broach et al. (2012)	Faktoren zur Berechnung der empfundenen Länge aus der Längsneigung
Motoaki et al. (2015)	<p>Wahlwahrscheinlichkeit einer Route in Abhängigkeit ihrer Steigung differenziert nach zwei Klassen der Radfahrenden.</p> <p>Route A: 20 min, niedriges Verkehrsaufkommen und Steigung von X % Route A: 10 min, hohes Verkehrsaufkommen und Steigung von 10 %</p> <div style="text-align: center;">  <p>Fig. 5. Choice probability of choosing route A as a function of slope.</p> </div>
Hood et al. (2011)	Der durchschnittliche Radfahrer vermeidet es, einen 10 m hohen Hügel zu befahren, solange der Umweg weniger als 0,59 km beträgt.
Huber (2022)	Bei zwei gleichen Routen mit Wahlwahrscheinlichkeit je 50 % bewirkt der Anstieg des Anteils von Streckenabschnitten mit einer Längsneigung > 2 % um 10 % eine Verringerung der Wahlwahrscheinlichkeit um 2,7 %.

Das Routenwahlverhalten, welches durch diese Parameter beschrieben wird, soll in den Verkehrsmodellen abgebildet bzw. reproduziert werden. Dafür sind die dargelegten Parameter in die

Widerstandsparameter, die in Verkehrsmodellen verwendet werden, zu übersetzen. Für die Abbildung der Topographie und deren Einfluss auf den Radverkehr wurden drei Ansätze verfolgt:

1. Berechnung der Streckengeschwindigkeit aus der Längsneigung mit einer stetigen Funktion: Die Streckengeschwindigkeit des Radverkehrs wird aus einer Grundgeschwindigkeit in der Ebene und der Längsneigung der Strecke berechnet. Dabei wird eine stetige Funktion angewandt. Ihre Formel und der Verlauf für eine Standardparametrisierung sind im Folgenden dargestellt.



Wenn $(LN < LN_{Min}; V_{Max};$

Wenn $(LN > LN_{Max}; V_{Min};$

Wenn $(LN < 0; V_E + LN \cdot ((V_{Max} - V_E) / LN_{Min});$

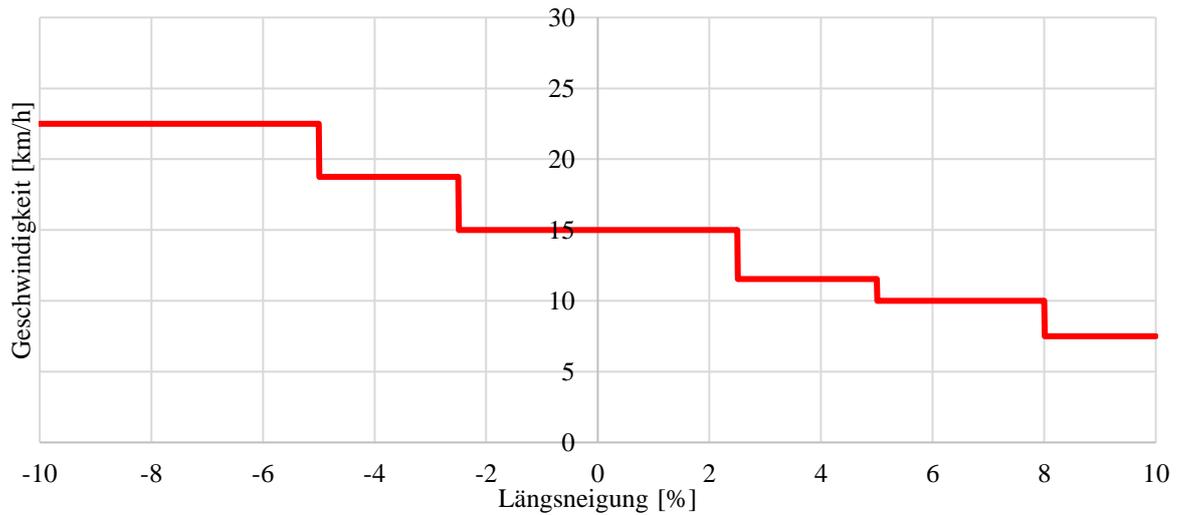
$V_E - LN \cdot ((V_E - V_{Min}) / LN_{Max}))))$

Parameter	Erklärung	Standardwert
LN	Längsneigung [%]	
V_E	Grundgeschwindigkeit in der Ebene	15 km/h
V_{Min}	Minimale Geschwindigkeit	4 km/h
V_{Max}	Maximale Geschwindigkeit	25 km/h
LN_{Min}	Längsneigung bei der die maximale Geschwindigkeit erreicht wird	- 8 %
LN_{Max}	Längsneigung bei der die minimale Geschwindigkeit erreicht wird	+ 8 %

Mit dieser Formel wird für jede Strecke eine Geschwindigkeit berechnet. Aus dieser wird die Fahrzeit des Radverkehrs auf der Strecke abgeleitet. Die Summe der Fahrzeiten aller Strecken einer Route bildet gemeinsam mit den Abbiegezeiten die Reisezeit bzw. den Widerstand der Route.

2. Berechnung einer Streckengeschwindigkeit aus der Längsneigung mit einer stufigen Funktion: Die Streckengeschwindigkeit des Radverkehrs wird aus einer Grundgeschwindigkeit in der Ebene und der Längsneigung der Strecke berechnet. Dabei wird eine stufige Funktion angewandt. Die Längsneigung wird dazu in Klassen (z. B. -2,5 % bis +2,5 %, +2,5 % bis 5,0 % ...) eingeteilt. Innerhalb einer Klasse ist die Geschwindigkeit konstant. Zwischen den Klassen

unterscheidet sie sich. Die Formel und der Verlauf der Funktion sind eine Standardparametrisierung und im Folgenden dargestellt.



Wenn ($LN < LN_1$; $f_1 \cdot V_E$;

Wenn ($LN < LN_2$; $f_2 \cdot V_E$;

Wenn ($LN < LN_3$; $f_3 \cdot V_E$;

Wenn ($LN < LN_4$; $f_4 \cdot V_E$;

Wenn ($LN < LN_5$; $f_5 \cdot V_E$;

$f_6 \cdot V_E$))))

Parameter	Erklärung	Standardwert
LN	Längsneigung [%]	
V_E	Grundgeschwindigkeit in der Ebene	15 km/h
f_1	Anpassungsfaktor der Stufe 1	1,25
f_2	Anpassungsfaktor der Stufe 2	1,25
f_3	Anpassungsfaktor der Stufe 3	1,00
f_4	Anpassungsfaktor der Stufe 4	0,77
f_5	Anpassungsfaktor der Stufe 5	0,67
f_6	Anpassungsfaktor der Stufe 6	0,50
LN_1	Grenze zwischen Stufe 1 und Stufe 2	- 5,0 %
LN_2	Grenze zwischen Stufe 2 und Stufe 3	- 2,5 %
LN_3	Grenze zwischen Stufe 3 und Stufe 4	+ 2,5 %
LN_4	Grenze zwischen Stufe 4 und Stufe 5	+ 5,0 %
LN_5	Grenze zwischen Stufe 5 und Stufe 6	+ 8,0 %

Es können beliebig viele Stufen definiert werden. So kann die Funktion an die verschiedensten Anforderungen angepasst werden. Sie ist dementsprechend zu erweitern. Die Zahl der zu definierenden Parameter hängt von der Anzahl der Klassen ab. Im Rahmen der betrachteten Anwendungsfälle dieser Funktion wurden sechs Stufen definiert. Daraus ergeben sich zwölf Parameter. Mit der vorgestellten Formel wird für jede Strecke eine Geschwindigkeit berechnet.

Aus dieser wird die Fahrzeit des Radverkehrs auf der Strecke abgeleitet. Die Summe der Fahrzeiten aller Strecken einer Route bildet gemeinsam mit den Abbiegezeiten die Reisezeit bzw. den Widerstand der Route.

- Integration der maximalen Steigung in den Routenwiderstand: Bei diesem Verfahren wird die Längsneigung nicht in den Widerstand der Strecken integriert. Dafür wird bei der Modellierung der Routenwahl für jede Route die maximale Steigung aller ihrer Strecken bestimmt. Daraus wird ein Zusatzwiderstand berechnet und zum Widerstand der Route, welcher sich aus den Strecken und den Abbiegern zusammensetzt, addiert. Die Formel ist im Folgenden dargestellt

$$\text{Routenwiderstand} = \sum \text{Widerstand Strecken} + \sum \text{Widerstand Abbieger} + \beta \cdot \text{LN}_{\text{Max}}$$

Parameter	Erklärung	Standardwert
LN_{Max}	Maximale Längsneigung/Steigung [%] aller Strecken der Route	
β	Parameter zur Steuerung des Einflusses der maximalen Steigung	0,5

Dieses Verfahren verfügt über einen Parameter β .

Die Parameter der in Tabelle 15 dargelegten Erkenntnisse sind in die Parameter der drei Ansätze zu übersetzen. Dies wurde im Rahmen des Use Case für jede Kombination aus Literaturerkenntnis und Ansatz zur Abbildung im Modell durchgeführt. Dazu wurde ein Excel-Tool entwickelt. In diesem sind die Ansätze zur Berechnung des Widerstands der Strecken und Routen sowie die darauf aufbauende Verkehrsstromaufteilung für eine Menge von Routenpaaren implementiert. Als Routenwahlmodell wurde jeweils ein Logitmodell mit einem Wahlparameter von -0.25 für die Methode 1 und 2 sowie einem Wahlparameter von -0.1 für die Methode 3 verwendet. In Tabelle 16 sind die Ergebnisse dargelegt. Im Rahmen des Excel-Tools wurde für die Übersetzung der Parameter eine Menge von Routenpaaren definiert. Diese sind eine Grundlage der Übersetzung und haben einen Einfluss auf das Ergebnis. Die Qualität der Setzung der Eigenschaften der Routenpaare bzw. der Routenpaare selbst ist somit ein Einflussfaktor auf die Ergebnisse des Use Case. Die resultierenden Parameter sind unter Berücksichtigung dieser Tatsache anzuwenden.

Die Übersetzung der Parameter gestaltete sich für den dritten Ansatz „maximale Steigung“ am einfachsten. Dies ist darauf zurückzuführen, dass er nur über einen Parameter verfügt. Die Möglichkeit eines unterbestimmten Gleichungssystems bei der Bestimmung der Parameter besteht somit nicht. Diese Widerstandsfunktion ist daher vergleichsweise einfach zu parametrisieren. Der Nachteil der einfachen Parametrisierung liegt in den begrenzten Möglichkeiten zur Anpassung im Rahmen der Kalibrierung. Zudem ist die Repräsentativität der maximalen Steigung, die unabhängig von ihrem Anteil an der Route betrachtet wird, für die gesamte Route beschränkt. Für die beiden Längsneigung-Geschwindigkeit-Funktionen ist das Gegenteil der Fall. Da sie über eine höhere Zahl von Parametern verfügen, gestaltet sich ihre Parametrisierung herausfordernder und es wird die Längsneigung jeder Strecke berücksichtigt. Diese Funktionen bieten mehr Spielraum für Feinanpassungen. Für die Kalibrierung von Verkehrsmodellen ist dies ein Vorteil. Die stufige Funktion bietet mehr Möglichkeiten als die Stetige, da die Zahl der Stufen frei gewählt werden kann. So kann auf verschiedene Besonderheiten eingegangen werden und die Funktion kann nach den jeweiligen Bedürfnissen angepasst werden. Bei der stetigen Funktion können die Geschwindigkeiten zwischen der minimalen und der maximalen Steigung sowie der Ebene nur über die vier genannten Parameter gesteuert werden. Zudem führt die Klasse um 0 % Längsneigung mit einem Faktor von 1 zu symmetrischen Widerständen im Bereich um 0 % Längsneigung. Die stetige Funktion berechnet

asymmetrische Widerstände. So werden Asymmetrien in den Modellergebnissen reduziert und Wahrnehmungsschwellen der am Verkehr Teilnehmenden im Modell abgebildet.

Tabelle 16: Ergebnisse des Use Case

Quelle / Ansatz	Stetige Funktion	Stufige Funktion	Maximale Steigung
Menghini et al. (2010)	<p>Es konnten konkrete Werte für die 4 Parameter bestimmt werden. Die Funktion ist demnach flacher einzustellen als in den Ausgangseinstellungen. Die geschätzten Parameter sind die Folgenden.</p> <p>$V_{\text{Min}} = 6,0 \text{ km/h}$ $V_{\text{Max}} = 18,0 \text{ km/h}$ $LN_{\text{Min}} = - 20, \%$ $LN_{\text{Max}} = + 8,5 \%$</p>	<p>Die hohe Zahl an Parameter erschwerte deren Schätzung. Die abgeschätzten Parameter legen eine flachere Einstellung der Funktion und eine breite Klasse von 8 % um 0 % Längsneigung nahe. Die geschätzten Parameter sind die Folgenden.</p> <p>$f_1 = 1,20$ $f_2 = 1,20$ $f_3 = 1,00$ $f_4 = 0,85$ $f_5 = 0,70$ $f_6 = 0,50$ $LN_1 = - 6,0 \%$ $LN_2 = - 4,0 \%$ $LN_3 = + 4,0 \%$ $LN_4 = + 5,0 \%$ $LN_5 = + 8,0 \%$</p>	Es konnte ein konkreter Wert von 0,52 für β bestimmt werden.
Prato et al. (2018)	<p>Die Schätzung ergab, dass im Bereich negativer Längsneigungen keine Erhöhung der Geschwindigkeit stattfinden sollte. Im Bereich positiver Längsneigungen ergab sich ein steilerer Verlauf als in den Ausgangseinstellungen. Die geschätzten Parameter für Steigungen sind die Folgenden.</p> <p>$V_{\text{Min}} = 2,9 \text{ km/h}$ $LN_{\text{Max}} = + 5,7 \%$</p>	<p>Durch die Übereinstimmung der Struktur der Widerstandsfunktion mit der Struktur der Ergebnisse der Studie konnten die Parameter für den Bereich positiver Längsneigungen einfach geschätzt werden. Da die Studie keine Aussagen zu negativen Längsneigungen enthält, war für diesen Bereich keine Schätzung möglich. Für den Bereich positiver Längsneigungen legen die Ergebnisse eine Reduzierung der Faktoren f gegenüber den Standardwerten und somit eine Erhöhung der Widerstände nahe. Die geschätzten Parameter für Steigungen sind die Folgenden.</p> <p>$f_3 = 1,00$ $f_4 = 0,54$ $f_5 = 0,48$ $f_6 = 0,20$ $LN_3 = + 1,0 \%$ $LN_4 = + 3,5 \%$ $LN_5 = + 5,0 \%$</p>	Es konnte ein konkreter Wert von 1,32 für β bestimmt werden
Broach et al. (2012)	<p>Die Schätzung ergab, dass im Bereich negativer Längsneigungen keine Erhöhung der Geschwindigkeit stattfinden sollte. Im Bereich positiver Längsneigungen ergab sich ein steilerer</p>	<p>Durch die Übereinstimmung der Struktur der Widerstandsfunktion mit der Struktur der Ergebnisse der Studie konnten die Parameter für den Bereich positiver Längsneigungen einfach</p>	Es konnte ein konkreter Wert von 1,09 für β bestimmt werden

	<p>Verlauf als in den Ausgangseinstellungen. Die geschätzten Parameter für Steigungen sind die Folgenden.</p> <p>$V_{\text{Min}} = 1,6 \text{ km/h}$ $LN_{\text{Max}} = + 7,2 \%$</p>	<p>geschätzt werden. Da die Studie keine Aussagen zu negativen Längsneigungen enthält, war für diesen Bereich keine Schätzung möglich. Für den Bereich positiver Längsneigungen legen die Ergebnisse eine Reduzierung der Faktoren f gegenüber den Standardwerten und somit eine Erhöhung der Widerstände nahe. Die geschätzten Parameter für Steigungen sind die Folgenden.</p> <p>$f_3 = 1,00$ $f_4 = 0,65$ $f_5 = 0,33$ $f_6 = 0,12$ $LN_3 = + 2,0 \%$ $LN_4 = + 4,0 \%$ $LN_5 = + 6,0 \%$</p>	
Hood et al. (2011)	<p>Es konnten konkrete Werte für die 4 Parameter bestimmt werden. Im Gefälle sollte keine Beschleunigung erfolgen. Bei Steigungen erreicht die Funktion eine minimale Geschwindigkeit im Bereich der Gehgeschwindigkeit. Diese wird allerdings bei einer niedrigeren Steigung erreicht, so dass die Funktion nun steiler verläuft. Die geschätzten Parameter für Steigungen sind die Folgenden.</p> <p>$V_{\text{Min}} = 5,2 \text{ km/h}$ $LN_{\text{Max}} = + 2,0 \%$</p>	<p>Die hohe Zahl von Parameter erschwerte deren Schätzung. Die abgeschätzten Parameter legen eine geringe Beschleunigung im Gefälle nahe, die mit zunehmendem Gefälle nicht weiter zunimmt, und eine schmale Klasse von 4 % um 0 % Längsneigung nahe. Die geschätzten Parameter sind die Folgenden.</p> <p>$f_1 = 1,20$ $f_2 = 1,20$ $f_3 = 1,00$ $f_4 = 0,80$ $f_5 = 0,60$ $f_6 = 0,50$ $LN_1 = - 6,0 \%$ $LN_2 = - 2,0 \%$ $LN_3 = + 2,0 \%$ $LN_4 = + 3,0 \%$ $LN_5 = + 5,0 \%$</p>	Es konnte ein konkreter Wert von 1,03 für β bestimmt werden
Huber (2022)	<p>Es konnten konkrete Werte für die 4 Parameter bestimmt werden. Im Gefälle sollte keine Beschleunigung erfolgen. Die geschätzten Parameter für Steigungen sind die Folgenden.</p> <p>$V_{\text{Min}} = 7,1 \text{ km/h}$ $LN_{\text{Max}} = + 18,3 \%$</p>	<p>Die hohe Zahl von Parameter erschwerte deren Schätzung. Die abgeschätzten Parameter legen eine geringe Beschleunigung im Gefälle nahe, die mit zunehmendem Gefälle nicht weiter zunimmt, und eine Klasse von 5 % um 0 % Längsneigung nahe. Die geschätzten Parameter sind die Folgenden.</p> <p>$f_1 = 1,25$ $f_2 = 1,25$ $f_3 = 1,00$</p>	Es konnte ein konkreter Wert von 0,52 für β bestimmt werden

		$f_4 = 0,77$ $f_5 = 0,67$ $f_6 = 0,52$ $LN_1 = - 5,0 \%$ $LN_2 = - 2,5 \%$ $LN_3 = + 2,5 \%$ $LN_4 = + 5,0 \%$ $LN_5 = + 8,0 \%$	
Motoaki et al. (2015)	<p>Das in der Studie dargelegte Routenwahlverhalten wurde versucht mit den Ansätzen der stetigen und der stufigen Geschwindigkeitsfunktion nachzubilden. Da die Belastung des Kfz-Verkehrs zu berücksichtigen ist, wurde zu ihrer Integration in die Berechnung des Widerstands des Radverkehrs auf Erfahrungswerte zurückgegriffen. Es zeigt sich, dass es mit der Stufen-Widerstandsfunktion besser nachgebildet werden kann. Die Optimierung ergab, dass beide Funktionen für eine Minimierung der Abweichung steiler einzustellen sind als die Ausgangseinstellungen. Die Literaturquelle enthält keine Aussagen zu negativen Längsneigungen. Daher wurden nur positive Längsneigungen betrachtet. Die geschätzten Parameter sind die Folgenden.</p> $V_{Min} = 3,8 \text{ km/h}$ $LN_{Max} = + 15,0 \%$	$f_2 = 1,00$ $f_3 = 1,37$ $f_4 = 1,83$ $f_5 = 2,40$ $f_6 = 2,81$ $LN_2 = + 1,3 \%$ $LN_3 = + 4,3 \%$ $LN_4 = + 7,9 \%$ $LN_5 = + 13,6 \%$	

2. Erhebungskonzept für fehlende Daten und Parameter

Vorgehen und Methodik

Um das Konzept zur Erhebung fehlender Daten/Parameter zu entwickeln, wurde ein zweigeteiltes methodisches Vorgehen gewählt: Zunächst wurden aktuelle Methoden der Datenerhebung im Mobilitätskontext mithilfe einer Literaturrecherche zusammengetragen. Dazu wurden neben Quellen zu Erhebungskonzepten großer deutscher Mobilitätsbefragungen auch Regelwerke der FGSV und internationale Publikationen berücksichtigt. Anschließend wurden Experteninterviews geführt, um Meinungen von Expert*innen zur Erweiterung bestehender Erhebungen sowie zu Möglichkeiten, fehlende Daten zu erheben, einzubeziehen. Dazu wurden 30 Unternehmen und Projekte im Kontext der Mobilitätsdatenerhebung kontaktiert. Sieben Interviews wurden mithilfe eines standardisierten Leitfadens (im Anhang enthalten) geführt. Dabei nutzen fünf Unternehmen/Projekte Apps zur Datenerhebung, ein Unternehmen/Projekt stationär verbaute bildgebende Sensoren, ein Unternehmen/Projekt verbaute Sensoren in Fahrrädern, ein Unternehmen/Projekt mitzuführende Sensoren beim Radfahren, ein Unternehmen/Projekt Simulationen und vier Unternehmen/Projekte Befragungselemente (Mehrfachnennungen der Unternehmen/Projekte enthalten). Der Leitfaden beinhaltet neben Fragen zur Datenerhebung innerhalb der Unternehmen und Projekte Fragen zur möglichen Erhebung fehlender Daten. Die Interviews dauerten zwischen 30 und 45 Minuten. Anschließend wurden die Interviews transkribiert, zusammengefasst und mithilfe der Software MAXQDA codiert und ausgewertet.

Die folgenden Abschnitte des Erhebungskonzepts basieren auf den anonymisierten Empfehlungen der geführten Interviews, um keine Rückschlüsse auf die Personen und Unternehmen/Projekte zu ermöglichen. Wenn mehrere Expert*innen eine Aussage getroffen haben, ist die Anzahl der Aussagen in Klammern am Ende des Satzes/Abschnitts angegeben. Da die Expert*innen aufgrund der unterschiedlichen Produkte und Projekte verschiedene Aspekte in das Erhebungskonzept eingebracht haben, wurden viele Aussagen nur von einzelnen Personen getroffen.

Erhebungsgegenstand

Basierend auf dem Soll-Ist-Vergleich (vgl. Teil II Kapitel 3 und 4) wurden Daten und Parameter mit einer hohen Priorität identifiziert, die sowohl bei der Datenverfügbarkeit Lücken aufweisen als auch nur abgeschätzt oder noch nicht in Modellen integriert sind. Die Datenlücken wurden nach den folgenden Datentypen zusammengefasst:

1. Soziodemografische und -ökonomische Daten
2. Daten zur Moduswahl
3. Daten zur Routenwahl
4. Räumliche und/oder zeitliche Daten
5. Subjektive Eindrücke

Soziodemografische und -ökonomische Daten

Dieser Datentyp umfasst als Datenlücken die Verkehrsmittelausstattung mit einem Dienstwagen, Pedelec und Lastenrad sowie neuen Mobilitätsangeboten. Da die Daten repräsentativ für eine bestimmte Grundgesamtheit erhoben werden sollten, sind bei Erhebungen weitere soziodemografische und -ökonomische Angaben wie Geschlecht, Alter, Haushaltsgröße etc. relevant.

Daten zur Moduswahl

Zu diesem Datentyp zählen die Häufigkeit der Wahl des Dienstwagens, Pedelecs und Lastenrads sowie von neuen Mobilitätsangeboten bei der Wahl eines Verkehrsmittels.

Daten zur Routenwahl

Fehlende Daten zur Routenwahl umfassen neben einer verbesserten Einschätzung der Reisezeit für Wege mit dem Fahrrad und Wege zu Fuß weitere Untersuchungen zur Routenwahl mit dem Pedelec und insgesamt zur Sensitivität der Routenwahl.

Räumliche und/oder zeitliche Daten

Zu diesem Datentyp zählen Angaben zur Infrastruktur (u. a. Bodenbeschaffenheit, Radverkehrsführung, Kontinuität, Vorhandensein von Schienen, Breite der Infrastruktur und Radverkehrsführung am Knoten) sowie Angaben zum Verkehrsaufkommen und weitere Durchschnittsangaben wie Zugangszeiten zu Radabstellanlagen, ÖV-Umstiegszeiten, Umlaufzeiten an Knoten etc.

Subjektive Eindrücke

Subjektive Eindrücke umfassen beispielsweise Sicherheitsempfinden, Präferenzen, Gewohnheiten etc. Zu diesem Datentyp zählen auch quantifizierbare Angaben zum Einfluss von Naturumgebung.

Erhebungsformen

Wie in Teil II Kapitel 3 dargestellt, weisen klassische Erhebungsformen wie (manuelle) Zählzeiten, Messungen, Beobachtungen und Mobilitätsbefragungen eine Vielzahl von Nachteilen auf. Dementsprechend berücksichtigt das Erhebungskonzept hauptsächlich innovativere Erhebungsmethoden wie Apps und Sensoren. Telekommunikationsdaten wurden ebenfalls von den Expert*innen als mögliche Erhebungsform genannt. Aufgrund der hohen Kosten bei der Datenbeschaffung wurde diese Erhebungsform im weiteren Erhebungskonzept jedoch nicht berücksichtigt.

Soziodemografische und -ökonomische Daten

Soziodemografische und -ökonomische Angaben können mittels Befragungselementen erhoben werden (5 Expert*innen). Dazu kann bei der Nutzung einer App zur Datenerhebung eine Umfrage im Profil der nutzenden Person nach der Installation der App verwendet werden. Fehlende Daten zur Verkehrsmittelverfügbarkeit (z. B. Dienstwagen, Pedelec, Lastenrad) oder Anschaffungskosten können dort ergänzt werden. Außerdem ist es denkbar, dass im Bereich der Umfrage die Fahrzeugverfügbarkeit im Haushalt abgefragt und diese dann in die Verkehrsmittelauswahl integriert wird (2 Expert*innen).

Daten zur Moduswahl

Daten zur Moduswahl zu erheben ist grundsätzlich beispielsweise durch Interviews und Befragungen (3 Expert*innen) oder Methoden wie die Nutzung von Mobilfunkdaten (2 Expert*innen) oder Apps zur Erfassung des Mobilitätsverhaltens (2 Expert*innen) möglich. Es gibt Apps, die die Moduswahl während einer Fahrt automatisiert erkennen. Dabei werden Beschleunigungssensoren und weitere Sensoren im Hintergrund aufgezeichnet, um festzustellen, welche Bewegungen stattfinden und welche Verkehrsmittel genutzt werden. Die Genauigkeit dieser Methoden wird als relativ zuverlässig angesehen, obwohl es Raum für Verbesserungen gibt (2 Expert*innen). Außerdem ist es denkbar, dass die Auswahl der Verkehrsmittel entsprechend der Angaben zur Verkehrsmittelausstattung im Profil der Nutzer*innen integriert wird (2 Expert*innen).

Daten zur Routenwahl

Daten zur Routenwahl mit dem Fahrrad, die auf Plattformen wie Strava oder Komoot erhoben werden, sind häufig nicht repräsentativ, da sie von spezifischen Nutzendengruppen verwendet werden (1 Expert*in). Zwei weitere potenzielle Datenquellen für die Routenwahl sind Daten von E-Bikes (1 Expert*in) oder E-Scooter- bzw. Bike-Sharing (1 Expert*in). Grundsätzlich hat sich die Erhebung über Apps am Markt bereits etabliert (2 Expert*innen). Eine Anpassung bestehender Apps zur Erhebung weiterer Daten wäre rein theoretisch möglich (3 Expert*innen). Es wäre ebenso möglich, am Ende einer Route zu erfragen, warum keine Alternativroute gewählt wurde (4 Expert*innen). Allerdings sollte darauf geachtet werden, dass neue Elemente nicht zu aufwendig für die Nutzenden sind (2 Expert*innen). Es wäre auch ein Bewertungssystem denkbar, in dem Routen mit Sternen bewertet werden können (1 Expert*in). Aus den bisherigen Daten wäre es mit neuen Abfragen möglich, zu analysieren, wie die Streuung bei der Routenwahl ist (2 Expert*innen).

Räumliche Daten

Infrastrukturdaten sind (zumindest für straßengebundene Verkehre) bereits gut verfügbar (2 Expert*innen) und in Zukunft durch Technologien wie „Mobileye“ und anderen Anbietenden, die Sensorik in Fahrzeugen verwenden, problemlos zugänglich (2 Expert*innen). Dies ermöglicht, perspektivisch ein detailliertes Netzniveau zu betrachten, um beispielsweise die Sichtbarkeit von Fahrbahnmarkierungen und Schildern zu überprüfen (1 Expert*in). Die aktuelle Datenqualität räumlicher Daten wie Infrastrukturdaten kann beispielsweise durch die Nutzung von OpenStreetMap in Kombination mit verschiedenen Anbietenden von Netz- und Infrastrukturdaten verbessert werden (2 Expert*innen). Die Nutzung von OSM-Features hängt letztendlich davon ab, wie gut die OSM-Datenqualität ist und wie vollständig die Daten sind (1 Expert*in). Ein Risiko für unvollständige und auch fehlerhafte Daten bleibt jedoch immer.

Zur Erhebung räumlicher Daten in Hinblick auf den Radverkehr gibt es bislang keine optimale Lösung, die nicht viel manuelle Arbeit für die Nutzenden bedeutet (2 Expert*innen). So müssen in einem klassischen Crowdsourcing-Ansatz, Nutzende aktiv aufgefordert werden, Informationen über die Infrastruktur in ihrer Umgebung zu erfassen und in Fragebögen anzugeben (1 Expert*in). Um Nutzende zu entlasten, können beispielsweise Techniken wie Bilderkennung genutzt werden. So können automatisch Informationen über die Beschaffenheit von Straßen und den Zustand von Straßenbelägen erfasst werden (2 Expert*innen). Diese Art der Datenerhebung erfordert in der Regel den Einsatz von Kameras und Sensoren, entweder durch Kooperationen mit Verkehrsbetrieben oder Müllabfuhrern, die bestimmte Gebiete durchfahren und dabei Daten sammeln können (1 Expert*in). Kameraauswertungen können außerdem Störungen wie Wurzelaufbrüche oder Schlaglöcher automatisiert erkennen (1 Expert*in). Dieses Vorgehen erfordert technische Lösungen, um andere Personen in den Aufnahmen unkenntlich zu machen oder herauszufiltern (1 Expert*in). Auch Erschütterungsdaten spiegeln die Oberflächenbeschaffenheit der Straßen wider wie Pflasterungen und Unebenheiten stärkere Erschütterungen (1 Expert*in).

Zeitliche Daten

Tatsächliche Reisezeiten können aus bereits erhobenen Daten herausgefiltert werden (3 Expert*innen). Das Auswerten von Wartezeiten an Knotenpunkten, Lichtsignalanlagen und ähnlichen Verkehrssituationen ist verhältnismäßig einfach. Dies kann durch die Erfassung von Standortdaten und Bewegungsinformationen erfolgen (3 Expert*innen). Wenn beispielsweise Nutzende an einem Knoten oder einer Lichtsignalanlage stehen, lässt sich dies durch das Erfassen von Stillstand und Bewegung leicht unterscheiden. Die Wartezeiten können somit relativ genau ermittelt werden, indem die Zeit

zwischen dem Stillstand an der Kreuzung und der Fortbewegung registriert wird (1 Expert*in). Diese Daten werden ebenfalls automatisch bei der Aufzeichnung einer Route miterhoben (2 Expert*innen). Ein weiterer Ansatz bei der Berechnung wäre, Geschwindigkeitsdaten zu normieren und sie mit der individuellen Wunschgeschwindigkeit der Radfahrenden zu vergleichen, um Zeitverluste an Knotenpunkten zu ermitteln (1 Expert*in). Insgesamt ist es allerdings schwierig die Repräsentativität der Umlaufzeiten einzuschätzen, wenn Radfahrende an einer Ampel halten, da der Zeitpunkt des Umlaufs, zu dem die Radfahrenden ankommen, nicht bekannt ist (1 Expert*in).

Durchschnittsangaben wie Zugangszeiten an (großen) Fahrradabstellanlagen oder durchschnittliche Umstiegszeiten im öffentlichen Verkehr können durch KI-Systeme an Knotenpunkten und anderen Orten ermittelt werden, indem entsprechende Sensoren in die Infrastruktur integriert werden (1 Expert*in). Bei der Nutzung einer App zur Berechnung von Durchschnittsangaben wie Fahrradzugangszeiten an Fahrradabstellanlagen müssten Start- und Endpunkt der Aufzeichnungen einheitlich sein. Da nicht bekannt ist, an welchem Zeitpunkt die Aufzeichnungen gestartet werden (z. B. vor Betreten der Abstellanlage oder beim Losfahren), können Zugangszeiten nicht berechnet werden (1 Expert*in). Weitere Durchschnittsangaben wie Umstiegszeiten können mithilfe einer App ermittelt werden, wenn die Verkehrsmittelerkennung mit einer hohen Genauigkeit funktioniert. Die Verkehrsmittelerkennung ermöglicht es, die Wechsel von einem Verkehrsmittel zum anderen zu identifizieren und die Zeiten zwischen den Umstiegen zu erfassen (1 Expert*in). Für die Auswertung ist es wichtig zu klären, ab welchem Punkt es sich tatsächlich um einen Umstieg handelt und wann der Weg als separate Wegstrecke betrachtet wird (1 Expert*in).

Subjektive Eindrücke

Es wäre grundsätzlich möglich, am Ende einer Route den Fahrenden zu befragen, welche subjektiven Eindrücke (bspw. zur Naturumgebung) während der Fahrt vorhanden waren (4 Expert*innen). Allerdings sollte darauf geachtet werden, dass neue Elemente nicht zu aufwendig für die Nutzenden sind (2 Expert*innen). Hardinghaus (2021) empfiehlt „Bike-along-Interviews“ mit Radfahrenden als Ergänzung zu quantitativen Analysen, um Motive und Emotionen bei der Routenwahl zu bewerten.

Wegezweck

Wegezwecke können entweder mithilfe von Wegetagebüchern in Befragungen (2 Expert*innen) oder mithilfe von Apps (3 Expert*innen) erhoben werden. Beispielsweise kann nach jeder Fahrt gefragt werden, welchen Zweck die Fahrt hatte (1 Expert*in). Eine Routinen-Erkennung als Alternative kann bei Wegen zum selben Ziel auch den vorher gewählten Wegezweck vorschlagen (1 Expert*in). Darüberhinausgehend kann unter der Nutzung von Machine Learning der Wegezweck erkannt werden. Dies erfolgt durch eine Mischung aus Routinen-Analyse und Analysen umliegender Geo-Merkmale (1 Expert*in). Für den Nutzenden müssen dennoch Möglichkeiten für Validierungen bestehen (2 Expert*innen).

Die untersuchten Erhebungsformen weisen Vor- und Nachteile auf (vgl. Tabelle 17), die je nach Erhebungsgegenstand abgewogen werden müssen. Die Erörterung der Vor- und Nachteile erfolgt am Ende der folgenden Abschnitte bezugnehmend auf die identifizierten Datenlücken.

Tabelle 17: Vor- und Nachteile der Erhebungsformen
(Anzahl der Expert*innen, die das Argument genannt haben, in Klammern)

Erhebungsform	Vorteile	Nachteile
<i>App</i>	<ul style="list-style-type: none"> • Schnell einsatzbereit (1) • Gut skalierbar (1) • Vergleichsweise günstig (2) • Erhebungszeitraum flexibel (2) • Bring-your-own-device-Konzept wirkmächtig (2) • Globale Erhebungen möglich (2) • Smartphone-Sensorik ermöglicht granulare Datenaufzeichnung (1) • Bequem für Teilnehmende (1) • Bessere Erfassung von Fußwegen im Vergleich zu Wegetagebüchern (1) • Einfache Auswertungen (2) 	<ul style="list-style-type: none"> • Map Matching notwendig (2) • Entsprechende Netze notwendig (2) • Meist Anreizsysteme notwendig (1) • Hohe Kosten für Vermarktung (2) • Unterschiedliche Datenschutzgesetze je nach Land (1) • Datenschutzvereinbarungen zeitintensiv zu verfassen (2) • Unterbrechungen beim Tracking durch Wartezeiten (2) • Smartphone-Verführbarkeit von Minderjährigen und älteren Erwachsenen (1) • Fehlende Repräsentativität (1)
<i>Bildgebende Sensoren</i>	<ul style="list-style-type: none"> • Einfache Installation (1) • Automatisierte Auswertungen (1) • Vermeidet Fehler manueller Erhebungen (vgl. Yan et al., 2016) • Hohe Repräsentativität möglich (1) 	<ul style="list-style-type: none"> • Stationär verbaut (1) • Keine Verfolgung über Untersuchungsraum hinaus (1)
<i>Verbaute Sensoren</i>	<ul style="list-style-type: none"> • Diebstahlsicher (1) • Einfaches Auslesen (1) 	<ul style="list-style-type: none"> • Benötigen Stromquelle (1) • Verhältnismäßig hohe Kosten (1) • Lücken im Empfang möglich (1) • Unterbrechungen beim Tracking durch Wartezeiten (1)
<i>Mitgeführte Sensoren</i>	<ul style="list-style-type: none"> • Schnell einsatzbereit (1) • Sensorik ermöglicht granulare Datenaufzeichnung (1) 	<ul style="list-style-type: none"> • Ausgabe und Rückgabe (1) • Benötigen Stromquelle (1) • Positionierung beeinflusst Ergebnis (z. B. in Hosentasche) (1)
<i>Befragungselemente</i>	<ul style="list-style-type: none"> • Bieten bei limitiertem Einsatz Möglichkeiten für weitere Erkenntnisse, die über App hinausgehen (2) • Ermöglichen die Erfassung soziodemografischer Daten (2) • Können als Vorab-Befragung oder nach Aufzeichnungen von Routen eingesetzt werden (1) • Kommentarfelder als Option (1) 	<ul style="list-style-type: none"> • Führen ggf. zu hoher Komplexität (1) • Können Akzeptanz der App reduzieren (2) • Verzerrung durch soziale Erwünschtheit (z. B. Lajunen & Summala, 2003), Nonresponse oder Gedächtnislücken (z. B. Roese & Vohs, 2012)

Zwischenfazit

Um die fehlenden Daten erheben zu können, empfiehlt sich ein Methodenmix mit verschiedenen Erhebungsformen, um die Vorteile der einzelnen Erhebungsformen ausnutzen zu können und Nachteile zu minimieren (vgl. Tabelle 17). Tabelle 18 fasst basierend auf den Erkenntnissen aus den geführten Interviews und der zugrundeliegenden Literatur zusammen, welche Erhebungsformen für die entsprechenden Datenlücken geeignet sind. Sie kombinieren mehrere Datenquellen für die Verkehrsplanung und Verkehrsmodellierung aus den Empfehlungen für Verkehrserhebungen (vgl. FGSV, 2012).

Zur Erhebung soziodemografischer und -ökonomischer Daten sowie Daten zur Moduswahl und zur Routenwahl bietet sich ein App-Tracking mit Routinen-Erkennung und individuellen

Anpassungsmöglichkeiten einer am Markt etablierten App-Lösung an. Es sollte eine bereits etablierte App-Lösung gewählt werden, um die hohen Kosten der Vermarktung zu reduzieren und um die Erfahrungen hinsichtlich Datenschutz und Datenaufbereitung nutzen zu können (vgl. Tabelle 17). In der App sollten zu Beginn der App-Nutzung soziodemografische Angaben inkl. Verkehrsmittel-ausstattung (ergänzt um Dienstwagen, Pedelec, Lastenrad) getroffen werden können. Die angegebenen Verkehrsmittel sollten bei der Validierung der Verkehrsmittelwahl implementiert sein, sodass Nutzende den gewählten Pkw bzw. das gewählte Fahrrad basierend auf den getätigten Angaben im Profil spezifizieren können. Durch die maschinelle Erkennung von Routinen sollte das gewählte Verkehrsmittel auch bei der nächsten Nutzung vorgeschlagen werden. Die gleiche Empfehlung gilt auch für die Erfassung von Wegezwecken, um die Nutzenden zu entlasten und die App möglichst nutzer*innenfreundlich zu gestalten. Eine App ist vergleichsweise schnell einsatzbereit und günstig (vgl. Tabelle 17). Eine langfristige Aufzeichnung gewählter Routen erlaubt Rückschlüsse auf die Sensitivität bei der Routenwahl. Durch die Spezifikation von Verkehrsmitteln, die über klassische Befragungsoptionen hinausgehen, wäre es beispielsweise möglich, Pedelec-Fahrende mit Nutzenden von herkömmlichen Fahrrädern zu vergleichen. Im Vergleich zu Wegetagebüchern kann eine App insbesondere kurze Wege zu Fuß oder mit dem Fahrrad besser erfassen, da die Aufzeichnung von Wegen durch die im Hintergrund laufende App nicht vergessen werden können (vgl. Tabelle 17). Nachbearbeitungsoptionen sollten für die Modus- und Routenwahl vorhanden sein.

Durch ein Bring-your-own-device-Konzept sind gut skalierbare Erhebungen im Sinne des Untersuchungsgebiets sowie der Stichprobengröße möglich (vgl. Tabelle 17), während bei der Ausgabe von Sensoren hohe organisatorische Kosten bei der Ausgabe und Rücknahme vorhanden wären (vgl. Tabelle 17). Durch die Kombination von Tracking-Daten mit soziodemografischen Daten kann die Erhebung repräsentativ gestaltet und wenn notwendig gewichtet werden (vgl. folgende Abschnitte zu Repräsentativität). Allerdings sollte beachtet werden, dass insb. bei Minderjährigen und zum Teil älteren Erwachsenen die Smartphone-Verfügbarkeit geringer ist als bei anderen teilnehmenden Altersklassen (vgl. Tabelle 17). Auch regional kann es Differenzen bei der Technologieanbindung und -verfügbarkeit geben. Bei der Auswertung sollte bereits vorab berücksichtigt werden, dass ggf. die Zusammenarbeit mit Kommunen notwendig ist, um die entsprechenden Infrastrukturnetze nutzen zu können, da die aufgezeichneten GPS-Koordinaten mithilfe eines Map-Matching-Algorithmus (Saki & Hagen, 2022) an das Straßennetz angepasst werden müssen (vgl. Tabelle 17).

Bei zeitlichen und räumlichen Daten sollte die Erhebungsform je nach Erhebungsgegenstand differenziert werden. Während tatsächliche Reisezeiten durch die Aufzeichnung der Routenwahl direkt mit aufgezeichnet werden, sind bei ÖV-Umstiegszeiten und Verlustzeiten an Knotenpunkten weitere Analysen notwendig. Die Erkenntnisse können nach Meinungen der Expert*innen allerdings aus den aufgezeichneten Daten generiert werden, wenn zusätzliche Abfragen programmiert und ggf. Annahmen getroffen werden. Bei Zugangszeiten an Radabstellanlagen sowie bei Umlaufzeiten an Knotenpunkten würden sich stationär verbaute bildgebende Sensoren besser als Apps zur Erhebung eignen, um individuelle Unterschiede in der Handhabung der App und dadurch eine Verzerrung der Ergebnisse zu vermeiden (vgl. Tabelle 17). Durch die einfache Installation und kontinuierliche Aufzeichnung ist eine hohe Repräsentativität bei der Erhebung möglich (vgl. Tabelle 17). Während bei Umlaufzeiten an Knotenpunkten eine Auswertung ohne Wiedererkennung eines Individuums möglich ist, wäre es bei Zugangszeiten zu Radabstellanlagen notwendig, das Individuum beim Verlassen der Abstellanlage wiederzuerkennen.

Die aktuell noch vorhandenen Lücken bei Infrastrukturdaten sehen die Expert*innen nicht als kritisch an. Dementsprechend wäre es empfehlenswert, an abgeschlossene Projekte anzuknüpfen oder mit

aktuell laufenden Projekten zu kooperieren, wenn es um die Erhebung von Infrastrukturdaten wie Kontinuität, Schienen, Bodenbeschaffenheit, Breite, Radverkehrsführung geht, und keine eigenständige Erhebung durchzuführen. Die immer weiter steigende Verfügbarkeit von Zählstellen und Zurverfügungstellung der Daten in Open-Data-Portalen ermöglicht es, aktuelle Daten zum Verkehrsaufkommen in Auswertungen zu berücksichtigen.

Tabelle 18: Erhebungsgegenstand und geeignete Erhebungsform

Datentyp	Erhebungsgegenstand	Geeignete Erhebungsform
<i>Soziodemografische und -ökonomische Daten</i>	Basisdaten	Befragungselemente
	Verkehrsmittelausstattung	Befragungselemente
<i>Daten zur Moduswahl</i>	Standard-Modi	App-Tracking mit Routinen-Erkennung
	Erweiterte Moduswahl (Pedelec, Lastenrad, Dienstwagen, neue Mobilitätsangebote)	App-Tracking mit Routinen-Erkennung und individuellen Anpassungsmöglichkeiten
<i>Daten zur Routenwahl</i>	Routenwahl mit dem Pedelec	Sensor-Daten/App-Tracking
	Sensitivität der Routenwahl	App-Tracking
<i>Wegezweck</i>	Wegezweck	App-Tracking mit Routinen-Erkennung und Nachbearbeitungsoptionen
<i>Zeitliche Daten</i>	Reisezeit (Fahrrad und zu Fuß)	App-Tracking
	ÖV-Umstiegszeiten	App-Tracking
	Zugangszeiten Radabstellanlagen	Sensor-Daten
	Verlustzeiten an Knotenpunkten	App-Tracking, Sensor-Daten
<i>Räumliche Daten</i>	Kontinuität der Infrastruktur	Video-/Sensor-Daten
	Vorhandensein von Schienen	Video-/Sensor-Daten
	Bodenbeschaffenheit	Video-/Sensor-Daten
	Breite der Infrastruktur	Video-/Sensor-Daten
	Radverkehrsführung	Video-/Sensor-Daten
	Verkehrsaufkommen	Video-/Sensor-Daten
<i>Subjektive Eindrücke</i>	Bspw. Sicherheitsempfinden, Präferenzen, Gewohnheiten, Einfluss von Naturumgebung	Befragung, Bike-along-Interview

Die Integration zusätzlicher Befragungselemente, um subjektive Daten zu erheben, ist abzuwägen. Je mehr Features in einer App ergänzt werden, desto höher wird die Komplexität für die Nutzenden und die Akzeptanz nimmt entsprechend ab (vgl. Tabelle 17). Prinzipiell wäre es möglich, zusätzliche Befragungselemente zu Beginn einer Erhebung oder nach jeder Route in einer App zu integrieren. Die Expert*innen nannten außerdem die freiwillige Befragung über Kommentarfelder als Option. Separate Befragungen und zusätzliche qualitative Methoden wie „Bike-along-Interviews“ können als weitere Alternative genutzt werden, um subjektive Daten zu erfassen.

Eine weitere Möglichkeit, fehlende Daten zu erheben, wäre die Erweiterung bestehender Befragungen. So wird im Wegetagebuch der aktuellen Welle der Befragung MiD zwischen Wegen mit einem herkömmlichen Fahrrad und einem Pedelec unterschieden (vgl. MiD, 2023). Eine weitere Aufnahme

von Lastenfahrrädern, Bike-Sharing oder Dienstwagen sowie neuen Mobilitätsangeboten wie E-Scootern erfolgte allerdings nicht (vgl. ebd.).

Weitere für eine Erhebung relevante Aspekte wie die Akquise, Repräsentativität, Stichprobengröße, Datenschutz, Anonymisierung, Datenspeicherung und -nutzung, Gamification und Incentivierung sowie organisatorische Hinweise und Hinweise zur technischen Umsetzung sind in den folgenden Abschnitten enthalten.

Akquise

Das Sampling und die Rekrutierung von Studienteilnehmenden sollten bereits bei der Konzeption der Erhebung berücksichtigt werden (1 Expert*in). Das Forschungsdesign sollte von Anfang an alle Zielgruppen einschließen. Dies beinhaltet die Berücksichtigung von unterschiedlichen Altersgruppen, Wohnorten (Stadt und Land), Geschlechtern und anderen relevanten demografischen Merkmalen (1 Expert*in). Um unterschiedliche Gruppen zu berücksichtigen, gibt es verschiedene Ansätze. Mögliche Ansätze bestehen darin, Gamification-Methoden einzusetzen (1 Expert*in), Anreize für verschiedene Gruppen anzupassen (2 Expert*innen), die App je nach Bedürfnissen von Gruppen anzupassen (1 Expert*in) und verschiedene Plattformen zu nutzen (3 Expert*innen). Genannte Beispiele für verschiedene Kanäle sind Zeitungen, Berichterstattungen im Fernsehen, Social Media, Flyer und die Teilnahme an einschlägigen Messen.

Bei der Nutzung einer App oder Befragung zur Datenerhebung gibt es die Möglichkeit, mit einem Closed Panel oder mit einem Open Panel zu arbeiten. Ein Closed Panel bedeutet, dass die App oder Befragung nur mit einem Zugangscode genutzt werden kann. Dabei stehen zwei Möglichkeiten offen: einen individuellen Zugangscode zu erhalten, der nur einmal für eine Person gültig ist, oder denselben Projekt-Code für alle Teilnehmenden zu nutzen. Ein Open Panel bedeutet, dass es einen öffentlichen Zugang gibt, den jede*r Interessierte nutzen kann (1 Expert*in). Die Rekrutierung der Teilnehmenden kann dabei durch Partner*innen wie Beratungsbüros oder Universitäten erfolgen (1 Expert*in). Die Zusammenarbeit mit einem Befragungsinstitut ist eine weitere Möglichkeit (1 Expert*in). Bei größeren Erhebungen besteht die Möglichkeit, in einer zweiten Kampagne gezielt bestimmte Altersgruppen oder gesellschaftliche Schichten anzusprechen, um eine größere Diversität in den Daten zu gewährleisten (1 Expert*in).

Repräsentativität

Die Repräsentativität der erhobenen Daten hängt von verschiedenen Einflussgrößen ab (5 Expert*innen), beispielsweise, ob ein repräsentativer Zeitraum gewählt wurde (1 Expert*in), welche Fragestellungen betrachtet werden (1 Expert*in), individuelle Eigenschaften der Teilnehmenden (3 Expert*innen) wie die persönliche Motivation zur Teilnahme an der Erhebung, das Untersuchungsgebiet (2 Expert*innen) und die auftraggebenden Kund*innen (2 Expert*innen). Aber auch die Form der Erhebung kann die Repräsentativität beeinflussen. Bei Knotenpunktzählungen könnte die Repräsentativität hoch sein, wenn ein geeigneter Zeitraum gewählt wurde. Das Verkehrsverhalten an einem Knotenpunkt unterscheidet sich normalerweise nicht stark über einen repräsentativen Zeitraum (1 Expert*in). Bei verbauten Sensoren in einem Fahrrad lohnt sich der Einbau für Hersteller erst ab einer gewissen Preisklasse. Dementsprechend bilden Daten, die mit eingebauten Sensoren erhoben werden, nicht die Gesamtmenge aller Fahrradfahrenden ab, sondern nur einen spezifischen Teil (1 Expert*in).

Ein weiterer Ansatz zur Datenerhebung von Routenwahl sind Wettbewerbe, bei denen Teilnehmende incentiviert werden, ihre Routen zu aufzuzeichnen. Diese Daten sind nicht flächendeckend oder dauerhaft verfügbar, sondern anlassbezogen. Sie könnten eine gewisse Repräsentativität aufweisen,

wenn die Erhebung ausreichend groß angelegt ist (1 Expert*in). Allerdings führt die persönliche Motivation bei Teilnehmenden bei Wettbewerben zu Verzerrungen (1 Expert*in). Wenn die Repräsentativität eine untergeordnete Rolle spielt, insbesondere bei Fragestellungen der Routenwahl, können große Stichprobengrößen bei der Erhebung innerhalb von Wettbewerben oder bei incentivierten Kampagnen erreicht werden (1 Expert*in). Daten zur Routenwahl mit dem Fahrrad, die auf Plattformen wie Strava oder Komoot erhoben werden, sind häufig nicht repräsentativ (1 Expert*in). Viele Studien benennen das Problem der Verzerrungen in GPS-Fahrraddaten (s. dazu Teil II Kapitel 3 Abschnitt Messungen). Die Erfahrung einer Expert*in ist, dass die Smartphone-Durchdringung auch in den älteren Bevölkerungssegmenten zugenommen hat und der Umgang mit Smartphones relativ geübt ist.

Krause (2020) weist darauf hin, dass aufgrund des wirtschaftlichen und sozialen Wandels, der Pluralisierung der Familienformen und der demografischen Entwicklung Geschlechterunterschiede in die Mobilitätsforschung integriert werden müssen, um das Ziel der gleichberechtigten Teilhabe an Mobilität und Gesellschaft zu gewährleisten. Zu den Gruppen, die explizit in Erhebungen berücksichtigt werden sollten, gehören Personen mit Familien- und Erziehungsaufgaben, Kinder und Jugendliche, ältere Erwachsene, Menschen mit eingeschränkter Mobilität, Menschen mit Migrationshintergrund und Menschen in schwierigen sozialen Verhältnissen (vgl. Krause, 2020). Außerdem sollten auch Nicht-Nutzende in Erhebungen integriert werden, um ein vollumfassendes Bild über die Gründe der Nichtnutzung zu erhalten.

Folgende Handlungsempfehlungen werden von den Expert*innen genannt:

- Wenn bestimmte soziodemografische Faktoren in der Stichprobe enthalten sein sollen, sollte dies bereits beim Sampling berücksichtigt werden (1 Expert*in).
- Bei einer Erhebung mithilfe einer App, sollten wichtige Angaben zur Stichprobe in einer Vorab-Befragung innerhalb der App eingebunden werden. Eine nachträgliche Gewichtung der Daten wäre so möglich (1 Expert*in).
- Repräsentativität kann durch die Implementierung eines „Frühwarnsystems“ erreicht werden (1 Expert*in).
- Proaktive Mechanismen wie regelmäßige Aufforderungen, Push-Benachrichtigungen und Gamification-Elemente wie Punktesysteme und Belohnungen können die Repräsentativität erhöhen (1 Expert*in).

Lißner (2022) nennt in seiner Dissertation soziodemografische Merkmale, die für eine potenzielle Gewichtung von getrackten Routen genutzt werden können. In den Hinweisen für die Durchführung von Haushaltsbefragungen zum Mobilitätsverhalten (FGSV, 2018) wird erläutert, wie systematische Abweichungen zwischen Stichprobe und Grundgesamtheit durch eine geeignete Gewichtung ausgeglichen oder abgemildert werden können.

Stichprobengröße

Die Stichprobengröße hängt von den spezifischen Anforderungen des jeweiligen Projekts (1 Expert*in) sowie von der gewählten Methodik zur Datenerhebung und der benachrichtigten Detaillierung der Aussagen (vgl. FGSV, 2018) ab. Die Empfehlungen für Verkehrserhebungen (FGSV, 2012) enthalten Beispielsrechnungen zur Bestimmung der notwendigen Stichprobengröße. Ein Unternehmen mit App zur Routenaufzeichnung mit dem Fahrrad berichtet von Stichproben von 100 bis 200 Teilnehmenden als eine gute Ausgangsbasis. Die sei jedoch nicht ausreichend repräsentativ, wenn es darum ginge, eine Großstadt abzudecken (1 Expert*in). Ein Projekt zur Erfassung von Fahrradrouten plant vier Feldtests, an denen jeweils 250 Proband*innen teilnehmen sollen (1 Expert*in). Ein weiteres Projekt zur Aufzeichnung von Routen von Kfz-Fahrzeugen verzeichnet etwa 5.000 Downloads, was als „recht

repräsentativ“ angesehen wird (1 Expert*in). Erfahrungsgemäß können Nachhaltigkeits-Projekte, die mit Incentives arbeiten, vergleichsweise einfach große Nutzendenzahlen erreichen. Mit überschaubarem Aufwand könne ein Prozent der Bevölkerung für die Erhebung gewonnen werden (1 Expert*in). Insgesamt sollte während der Erhebungszeit darauf geachtet werden, das Absinken der Teilnehmenden-Anzahl so gering wie möglich zu halten (2 Expert*innen).

Datenschutz

Der Datenschutz sollte bereits bei der Konzeption der Datenerhebung berücksichtigt werden (1 Expert*in, vgl. FGSV, 2018) und spielt bei allen Erhebungsformen wie bei bildgebender Sensorik (1 Expert*in), beim Aufzeichnen von Routen (3 Expert*innen) und bei der Erhebung personenbezogener Daten (3 Expert*innen) eine Rolle. Die Datenerhebung sollte DSGVO-konform (3 Expert*innen) und transparent gestaltet sein (2 Expert*innen) und technische Sicherheitsmaßnahmen berücksichtigen (1 Expert*in). Die Teilnehmenden sollten vor der Erhebung um ihre Zustimmung zur Datenverarbeitung gebeten werden (7 Expert*innen). Um diesen Anforderungen gerecht zu werden, müssen die Erhebenden die Datenschutzerklärung sorgfältig, d. h., alle möglichen Szenarien und Bedingungen abdeckend, ausformulieren, um alle relevanten Informationen zur Datenverarbeitung (wie Anonymisierung) klar und verständlich darzulegen (4 Expert*innen). Es sollte ebenfalls transparent gemacht werden, wer Zugriff auf die (Roh-)Daten erhält (3 Expert*innen). Außerdem sollte die Datenschutzerklärung für alle Nutzenden leicht zugänglich sein (1 Expert*in). Bei der Erhebung mithilfe von Apps sollte es den Teilnehmenden möglich sein, die Aufzeichnungen auch zwischendurch zu unterbrechen (2 Expert*innen). Außerdem sollte der Umgang mit Kindern bei der Konzeption berücksichtigt werden (1 Expert*in). In der Regel nutzen Haushaltsbefragungen Proxy-Interviews, um Kinder im Haushalt abzudecken (vgl. u. a. Eggs et al., 2018). Bei der Erhebung mit Apps ist die Durchdringung mit Smartphones zum einen nicht gegeben, zum anderen sehen zwei Expert*innen es kritisch, Routen von Kindern aufzuzeichnen. Weitere Anmerkungen zum Datenschutz sind darüber hinaus auch in den Empfehlungen für Verkehrserhebungen enthalten (vgl. FGSV, 2012).

Anonymisierung

Im Rahmen der Datenschutzerklärung sollte die Anonymisierung der Daten im Sinne der Datenweiterverarbeitung ebenfalls beschrieben werden. Die Anonymisierung ist vom Projektkontext (2 Expert*innen) und vom Erkenntnisinteresse (1 Expert*in) abhängig. Folgende Möglichkeiten zur Anonymisierung wurden im Rahmen der Experteninterviews genannt:

- Wenn die Quelle-Ziel-Relation nicht relevant ist, kann jede Etappe als einzelne Etappe betrachtet werden und es ist nicht notwendig, zu wissen, ob zwei Etappen von derselben Person zurückgelegt wurden. In diesen Fällen kann im Prinzip die User-ID entfernt werden (2 Expert*innen).
- Es sollte grundsätzlich immer eine Pseudonymisierung vorgenommen werden. Das heißt, die Nutzungsdaten sind nur noch mit einer eindeutigen ID versehen und nicht mit den demografischen Daten oder individuellen Personen verknüpft (5 Expert*innen).
- Die Datensätze werden aggregiert, um die Privatsphäre der Nutzenden zu schützen (4 Expert*innen).
- Es ist wichtig zu beachten, dass selbst scheinbar anonymisierte Daten möglicherweise noch Rückschlüsse auf individuelle Personen zulassen könnten, z. B. durch die theoretische Möglichkeit der Rückverfolgung von IP-Adressen (1 Expert*in).
- Es sollte bei Apps die Option geben, die App anonym nutzen zu können (1 Expert*in).

- Bei der Aufzeichnung von Routen kann als Anonymisierungsmethode die Beschneidung von Routen vorgenommen werden, z. B. indem:
 - ein zufälliger Wert zwischen 50 und 100 Metern am Anfang und Ende einer Route entfernt wird, um eine genaue Zuordnung zu verhindern (1 Expert*in),
 - einige hundert Meter entfernt werden, um die Identifizierung von Häusern zu verhindern (1 Expert*in),
 - Nutzende Anfang und Ende der Fahrt kürzen können, um Start- und Zielpunkte der Fahrt zu verschleiern. Wenn die Fahrt hochgeladen wird, gibt es keine Information darüber, ob die Fahrt geschnitten wurde oder nicht (1 Expert*in).

Darüber hinaus sind bei der Visualisierung von Daten Sicherheitsmechanismen denkbar, wie eine Blockierung von Auswertungen, wenn das Sample weniger als fünf Personen umfasst (1 Expert*in). Bei der Erhebung personenbezogener Daten müssen datenschutzrechtliche Überlegungen berücksichtigt werden. Es gibt beispielsweise ein Projekt, das die rechtlichen Aspekte der Verwendung soziodemografischer Daten und Einkommensdaten untersucht hat. Das Projekt argumentiert, dass Daten als ausreichend anonymisiert gelten, wenn sie auf eine Verkehrszelle mit mindestens sieben Haushalten aggregiert werden und keine fein granularen Informationen darüber ermöglichen (1 Expert*in). Bei der deutschlandweiten repräsentativen Befragung MiD wird ein datenschutzkonformes Konzept verwendet, das auf einem Gitternetz aus dem Forschungsprojekt „Kleinräumiges Analyseraster des Zensus 2011“ basiert (vgl. Eggs et al., 2018).

Datenspeicherung

Bezüglich der Speicherung der erhobenen Daten sollte bereits in der Datenschutzerklärung enthalten sein, ob diese dauerhaft gespeichert werden oder nach Abschluss der Studie gelöscht werden. Bei den befragten Unternehmen und Projekten wird die Speicherung von Daten unterschiedlich gehandhabt:

- Die erhobenen Daten werden dauerhaft gespeichert, da sie anonymisiert und aggregiert sind und zur Generierung von Erkenntnissen beitragen (2 Expert*innen).
- Erhobene Daten werden nach Abschluss der Studie vom Server gelöscht (2 Expert*innen).
- Die Rohdaten werden zur Auswertung gespeichert (4 Expert*innen), da erwartet wird, dass die Rohdaten erneut verarbeitet werden, um neue Metriken anzuwenden (2 Expert*innen).
- Die Daten werden nach dem Minimal-Prinzip gespeichert werden, d. h., es werden nur wirklich benötigte Daten gespeichert (2 Expert*innen).
- Die Nutzenden haben in der App immer direkten Zugriff auf die Datenlöschung (2 Expert*innen)

Nutzung der Daten

Bei der Nutzung der erhobenen Daten kann zwischen der erhebenden Institution, der beauftragenden Institution sowie Dritten differenziert werden. So nutzen fünf der befragten Expert*innen die erhobenen Daten für interne Use Cases selbst, bspw. um weitere Erkenntnisse zu generieren (2 Expert*innen) und die Erkenntnisse relevanten Akteur*innen oder der Öffentlichkeit bereitzustellen (2 Expert*innen), für Visualisierungen (3 Expert*innen), Datenveredelung und -kombination (2 Expert*innen) sowie Analysetools (2 Expert*innen).

Bei der Weitergabe von Daten an Auftraggebende sollte darauf geachtet werden, dass diese je nach Kontext und Fragestellung in unterschiedlicher Aufbereitung- und Aggregationsform weitergegeben werden sollten. Je nach Kontext und Fragestellung kann es sein, dass Auftraggebende (u. a.

Forschungseinrichtungen) Zugriff auf die Rohdaten benötigen (2 Expert*innen) oder dass es ausreicht, Daten in verarbeiteter und aggregierter Form zur Verfügung zu stellen (2 Expert*innen).

Bei der Weitergabe von Daten an andere Akteur*innen wie Verkehrsplanende oder Kommunen müssen Auftraggebende entscheiden, ob die Hoheit über die erhobenen Daten geteilt werden soll (1 Expert*in). Wenn Auftraggebende ihr Recht an den Daten teilen, können die Daten DSGVO-konform auch anderweitig genutzt werden (1 Expert*in). Die Zurverfügungstellung an Dritte oder im Rahmen von Open-Data-Portalen ist bei Teilen der Expert*innen aktuell keine Option (3 Expert*innen), während andere Expert*innen bereits Austausch mit Akteur*innen über die Erkenntnisse pflegen (3 Expert*innen). Die Weitergabe von aggregierten Daten an eine Kommune wird bei einer Expert*in aktuell geprüft. Drei Unternehmen sind offen dafür, Daten in einem Kontext zur Verfügung zu stellen, in dem für die Gesellschaft Mehrwert generiert werden kann.

Gamification und Incentivierung

Reitmaier et al. (2022) beschreiben Gamification als spieltypische Elemente wie Fortschrittsanzeigen, Ranglisten oder Herausforderungen, um die Motivation für die weitere Nutzung einer App zu steigern. Incentives umfassen alle Formen von Anreizen, an Erhebungen teilzunehmen oder auf längere Sicht, Erhebungen nicht frühzeitig abubrechen und sollte angepasst an den Erhebungskanal und die unterschiedlichen Zielgruppen berücksichtigt werden (1 Expert*in).

Folgende Formen von Gamification wurden von den Expert*innen genannt:

- Wettbewerbe (2 Expert*innen)
- Punktesysteme (2 Expert*innen)
- Virtuelle Währung (1 Expert*in)
- Individueller Statistikbereich (3 Expert*innen)
- Herausforderung, den eigenen CO₂-Ausstoß zu senken (1 Expert*in)
- Community-Bereich, um sich mit allen App-Nutzenden zu vergleichen (2 Expert*innen)

Folgende Formen von Incentives wurden von den Expert*innen genannt:

- Monetäre Belohnungen (2 Expert*innen)
- Geschenke (2 Expert*innen)
- Gutscheine (im Austausch für virtuelle Währung) (2 Expert*innen)
- Freischaltung von Features in der App (1 Expert*in)
- Mehrwert aus App-Nutzung (1 Expert*in)
- Überblick über eigenes Mobilitätsverhalten (3 Expert*innen)
- Überblick über eigenen CO₂-Ausstoß (1 Expert*in)

Weitere proaktive Mechanismen, zur Erhöhung der Teilnahmequote sind Erinnerungen, Aufforderungen, Push-Benachrichtigungen (1 Expert*in). Solche Ansätze können zusammen mit Incentives und Gamification die Akzeptanz (1 Expert*in) einer Erhebung, die Repräsentativität (2 Expert*innen), Beteiligung und -motivation erheblich (3 Expert*innen) erhöhen. Erfahrungsgemäß wird der Statistikbereich häufig genutzt und das Interesse an entsprechenden Bereichen in Apps steigt (1 Expert*in). Allerdings sollte der Einsatz solcher Elemente überlegt eingesetzt werden. Beispielsweise könne ein Community-Bereich das Verhalten der Nutzenden beeinflussen und eine objektive Erhebung verzerren (1 Expert*in).

Organisatorische Hinweise

Eine gründliche organisatorische Planung und Durchführung bilden die Basis einer Erhebung (1 Expert*in). So sollte bereits bei der Planung einer Erhebung berücksichtigt werden, dass ein repräsentativer Zeitraum für die Erhebung gewählt wird (vgl. FGSV, 2018). Als Zeitbedarf für den Gesamtprozess wird ein Jahr empfohlen (vgl. ebd.). Die Themen Datenschutz und Datensicherheit sollten direkt zu Beginn berücksichtigt werden (3 Expert*innen), da sie erfahrungsgemäß viel Zeit in Anspruch nehmen (2 Expert*innen) und die Zusammenarbeit mit weiteren Instanzen wie Datenschutzbeauftragten erfordern (1 Expert*in). Dazu zählt auch, die Form der Anonymisierung zu bestimmen, um diese sinnvoll anwenden zu können (1 Expert*in).

Organisatorisch sollte die Erhebung auf eine spezifische Erkenntnislücke hin ausgewählt und angepasst werden (2 Expert*innen). Es sollte bereits zu Beginn klar sein, welche Daten genau benötigt werden und wie sie erfasst werden können (2 Expert*innen). Wenn Daten mit einer App entwickelt werden sollen, ist es möglich, eine bereits am Markt etablierte Lösung zu nutzen oder eine neue Applikation zu entwickeln (1 Expert*in). Zusätzlich zu einer gut gestalteten (1 Expert*in) qualitativ hochwertigen und benutzerfreundlichen App (2 Expert*innen) sollten ausreichend Ressourcen und Budget zur Verfügung stehen, um die App erfolgreich auszurollen und alle relevanten Zielgruppen anzusprechen (2 Expert*innen).

In der Regel sollte es bereits vor der Erhebung umfassende Informationen für die Teilnehmenden geben (1 Expert*in). Insbesondere Startprozesse können herausfordernd sein (1 Expert*in). Deshalb ist es wichtig, zu Beginn Unterstützung anzubieten. Dazu zählen beispielsweise Anleitungen (2 Expert*innen), FAQs (1 Expert*in), technische Supportangebote (6 Expert*innen), Schulungen (2 Expert*innen), Hinweisvideos (1 Expert*in) etc. Auch an dieser Stelle sollte darauf geachtet werden, dass unterschiedliche Zielgruppen unterschiedliche Bedürfnisse haben (2 Expert*innen). Wenn externe Sensoren verwendet werden, stellen die logistischen Prozesse des Verteilens und Zurückbringens der Sensoren eine Herausforderung dar (1 Expert*in).

Bei Erhebungen über längere Zeiträume (z. B. über Monate bis Jahre) ist eine regelmäßige Kommunikation wichtig (1 Expert*in). Die Kommunikation sollte an die verschiedenen Zielgruppen der Erhebung angepasst werden (1 Expert*in). Auch Erinnerungen oder Benachrichtigungen, wie viele Tage bereits erhoben wurde, sind hilfreiche organisatorische Instrumente (2 Expert*innen). Auch die Teilnahme an einer Erhebung über unterschiedliche Kommunikationsformen kann zu besseren Ergebnissen führen und Teilnahmequoten verbessern (vgl. FGSV, 2018).

Technische Umsetzung

Bei der technischen Umsetzung einer App, ist die Gestaltung einer ansprechenden User Experience (UX) und eines benutzerfreundlichen Interfaces (UI) von hoher Relevanz (2 Expert*innen). Die Applikation sollte so gestaltet sein, dass sie von allen Zielgruppen leicht bedienbar und verständlich ist (2 Expert*innen). Neben der Bereitstellung einer App für iOS, Android (2 Expert*innen) wird empfohlen auch die APK-Datei (1 Expert*in) zur selbstständigen Installation auf dem Endgerät zur Verfügung zu stellen, falls Nutzende keinen gängigen App-Store nutzen möchten. Bei der technischen Umsetzung ist es entscheidend, dass die Anwendung reibungslos funktioniert, unabhängig davon, ob sie auf den neuesten High-End-Smartphones oder älteren Modellen verwendet wird (2 Expert*innen). Eine Betatest-Phase kann dabei helfen, Fehler frühzeitig zu erkennen (1 Expert*in).

Je nach Erhebungsmethode sind bei der technischen Umsetzung für und während der Erhebung weitere Einzelheiten zu beachten:

- Bei **Routenaufzeichnung mit GPS-Punkten** ist ein Map Matching auf die entsprechende Infrastruktur notwendig (2 Expert*innen): Über das Tracken der einzelnen erkannten Objekte im Raum werden Trajektorien gebildet, die über einen entsprechenden Algorithmus auf Kartenmaterial gemappt werden müssen (1 Expert*in).
- Falls bei **stationär angebrachter Bilderkennung** am Knotenpunkt eine Wiedererkennung von Verkehrsteilnehmenden über Knotenpunkte hinweg stattfinden soll, stellt die Wiedererkennung eine technische Herausforderung dar (1 Expert*in).
- Bei **am Fahrrad angebrachter Sensorik** sollte die Positionierung des Sensors abgefragt werden, da es je nachdem, wie das Smartphone befestigt ist (z. B. am Lenkrad oder in der Hosentasche) zu erheblichen Unterschieden bei den erhobenen Daten kommen kann (1 Expert*in).
- Bei **am Fahrrad angebrachter Sensorik** sollte ebenfalls der aktuelle Reifendruck abgefragt werden. Dies dient dazu, eine Einschätzung darüber zu erhalten, ob das Fahrrad gut oder schlecht gefedert ist. Der Reifendruck hat einen Einfluss darauf, wie stark die Erschütterungen beim Radfahren wahrgenommen werden (1 Expert*in).

Unabhängig von der Erhebungsform sollte eine gute Balance zwischen Batterienutzung und Präzision der Datenaufzeichnung hergestellt werden (2 Expert*innen). So sollten keine Daten aufgezeichnet werden, solange sich der Tracker nicht bewegt (1 Expert*in). Eine App sollte in einen Schlafmodus verfallen, wenn sich die Nutzenden nicht bewegen und wieder aufzeichnen, wenn sich die Person wieder in Bewegung setzt (1 Expert*in).

Für die Verarbeitung und Speicherung der erhobenen Daten empfehlen die Expert*innen aus technischer Perspektive folgende Punkte:

- Da die Verarbeitung großer Datenmengen sehr rechenintensiv ist, können Verarbeitungsgeschwindigkeiten durch den Einsatz von Machine Learning erhöht werden (1 Expert*in).
- Bei der technischen Umsetzung sollte an die Last auf das System gedacht werden, wenn die Durchdringung im Markt steigt (2 Expert*innen).

Aus Perspektive der Nutzenden sollte es möglich sein,

- die erhobenen Daten validieren zu können (2 Expert*innen),
- zu kommentieren (3 Expert*innen),
- Strecken zusammenzuführen (2 Expert*innen),
- Verkehrsmittel zu korrigieren oder zu ändern (3 Expert*innen) und
- die App individuell anzupassen („Customizability“) (1 Expert*in).

Eine Routinen-Erkennung vereinfacht den Aufwand für die Nutzenden einer App: Die Annahme ist, dass wenn die Nutzenden beim Validieren angeben, dass sie ein bestimmtes Verkehrsmittel genutzt haben, dieses Verkehrsmittel in der Regel automatisch als Routineverkehrsmittel erkannt wird (1 Expert*in). Dasselbe Vorgehen ist auf den Wegezweck übertragbar: Bei jedem Stopp kann in der App zunächst ein Fragezeichen erscheinen. Bei der ersten Nutzung muss ein Wegezweck eingetragen werden. Wenn der Nutzende das nächste Mal am selben Ort ist, kann die App denselben Wegezweck des ersten Besuchs vorschlagen. Je länger die App also genutzt wird, desto weniger neue Orte kommen dazu (1 Expert*in). Alternativ kann mit KI-Algorithmen der Wegezweck automatisiert erkannt werden (1 Expert*in). Es ist wichtig, dass die Nutzenden keine Frustration durch technische Probleme erleben, da dies ihre Bereitschaft zur freiwilligen Teilnahme beeinträchtigen könnte (1 Expert*in).

Fazit

Dieser Bericht umfasst die Ergebnisse des Forschungsprojektes „ModelRad – Status quo und Entwicklungsoptionen der Datengrundlage für die Modellierung des Radverkehrs“. In Teil I wurden die Einflussfaktoren, die auf die Modus- bzw. auf die Routenwahl mit dem Fahrrad wirken, dargestellt und erörtert. Durch die Priorisierung aus der Perspektive der Verkehrsmodellierung liegt als Ergebnis ein priorisierter Soll-Katalog dieser Einflussfaktoren vor. In Teil II wurden zunächst die von der PTV Group erstellten Verkehrsmodelle dargestellt und dabei vor allem die Integration radverkehrs-spezifischer Faktoren in ebendiesen betrachtet. Des Weiteren wurde eine Gegenüberstellung des Soll-Katalogs mit dem Status quo durchgeführt. Im Fokus standen dabei die Perspektiven der Datenverfügbarkeit und der Modellierung der radverkehrsrelevanten Parameter. Ein kurzer Ausblick auf mögliche weitere Forschungsthemen schließt die Gegenüberstellung von Soll-Zustand zu Ist-Zustand ab. Teil III präsentierte zum einen, wie Parameter basierend auf existierenden Studien hergeleitet werden können und zum anderen ein Erhebungskonzept, um fehlende Daten zu erheben. Die Erkenntnisse zeigen, dass bereits heute viele Daten zur Modus- und Routenwahl vorliegen, die bei entsprechender Analyse und Aufbereitung für die (Rad-)Verkehrsmodellierung genutzt werden können. Gleichzeitig liegen zu vielen Aspekten große Datenlücken vor, die eine realitätsnahe Abbildung des Radverkehrs aktuell noch erschweren. Diese Lücken gilt es zukünftig mittels der im Bericht vorgeschlagenen Erhebungsmethoden zu schließen und so der Verkehrspolitik und Verkehrsplanung bessere Entscheidungs- und Planungsgrundlagen zu bieten.

Anhang

Anhang A 1: Betrachtete Studien Moduswahl

Autor*innen	Jahr	Datenerhebung	Studiendesign	Methode	Untersuchungsgebiet	Stichprobengröße
Akar & Clifton	2009	Mobilitätsbefragung (2008)	Querschnitt	Diskrete Wahlmodelle (MNL)	Maryland, USA	1.500 Befragte
An et al.	2019	Nutzungsdaten von Citibike (2018)	Panel	Fluss-Karten und Regressionsmodelle mit räumlichen Verzögerungen	New York, USA	6.102 Fahrende 12.710 Fahrten 622 Leihstationen
Asensio	2002	Mobilitätsbefragung (1996)	Querschnitt	Zweistufiges multinomiales nested Logit	Barcelona, Spanien	1.381 Pendler
Bergström & Magnusson	2003	Befragung (1998, 2000)	Querschnitt	Deskriptiv	Lulea & Linköping, Schweden	433 (1998), 572 (2000) Mitarbeiter
Brandenburg et al.	2007	Vor-Ort-Befragungen (2002), Videobeobachtung (2002)	Querschnitt	Deskriptiv; einfache und multiple lineare Regressionsmodelle	Wien, Österreich	890 Interviews; ~55.000 Radfahrende
Broach & Dill	2016	GPS-Daten (2010-2013)	Querschnitt	Diskrete Wahlmodelle (MNL)	Portland, USA	330 Familien, 13.277 Fahrten
Cervero & Duncan	2003	Mobilitätsbefragung (1996)	Querschnitt	Diskrete Wahlmodelle (MNL)	San Francisco, USA	15,066 Familien, 7.889 Wege
Cervero et al.	2009	Internationaler Fragebogen zur körperlichen Betätigung (Interview), Beschleunigungsmesser	Querschnitt	Logit-Modell	Bogotá, Columbien	1.285 Befragte
Cervero et al.	2018	Zählungen zum Pendlerverkehr (2011)	Querschnitt	Modelle mit fixen Effekten und Zero-One Inflated Beta (ZOIB)	36 kleine bis mittelgroße Städte England und Wales	9.083 Zählungen von Verkehrszelle zu Verkehrszelle (1,23 Mio. Fahrten zur Arbeit)
Cervero	2002	Mobilitätsbefragung (1994)	Querschnitt	Diskrete Wahlmodelle (MNL)	Montgomery County, USA	1.960 Wege
Corcoran et al.	2014	Disaggregierte CityCycle-Fahrdaten (November 2010-Juli 2012)	Panel	Poisson-Verteilung, multivariates Regressionsmodell, Flusskarte	Brisbane, Australien	285.714 Fahrten
Dill & Carr	2003	Zusatzerhebung zum Zensus (2000)	Querschnitt	Regressionsmodelle	USA	42 Städte
Dill & Voros	2007	Vermessung und GPS-Daten (2005)	Querschnitt	Deskriptiv	Portland, USA	503 Befragte

Eluru et al.	2012	Webbasierte Befragung (April, Mai 2011)	Querschnitt	Logit-Modell	Montreal, Kanada	4.698 Befragte
Flynn et al.	2012	Längsschnittstudie (28 vorher festgelegte Tage über 10 Monate) 2009–2010	Panel	Logit-Modell	Vermont, USA	163 Befragte
Garrard et al.	2008	Zählung Radfahrende im Feb 2004	Querschnitt	Diskrete Wahlmodelle (MNL)	Melbourne, Australien	6.589 Radfahrende
Gebhart & Noland	2014	Bikeshare anonyme Einzelfahrtdaten 15. September 2010 bis 31. Dezember 2011	Querschnitt	Negatives Binomialmodell und OLS-Regression	Washington, USA	270.080 / 399.452 Fahrten
Goldmann & Wessel	2020	Fahrradzählungen von 122 automatischen Zählstationen (2017, 2018)	Querschnitt	Log-lineare Regression mit fixen Effekten, Fahrradindizes	Deutschland	30 Regionen und Städte
Habib	2019	2016 Mobilitätsbefragung	Querschnitt	Independent Availability Logit (IAL) und constr. MNL im Vergleich zu MNL	Toronto, Kanada	11.061 Wege
Hardinghaus et al.	2021	Haushaltsbefragung (SrV) 2008	Querschnitt	Diskrete Wahlmodelle (MNL)	Berlin, Deutschland	73.667 Wege
Heaney et al.	2019	CitiBike-Fahrten Juni 2013 bis September 2017	Zeitreihen	Nichtparametrische verallgemeinerte additive Modelle (GAMs)	New York, USA	43 Mio. Fahrten
Helbich et al.	2014	Reisetagebuch August 2012 bis Februar 2013	Querschnitt	Mlogit, autologistische Regressionen (ALRs), geographisch gewichtete Logit-Modelle (GWLMs), Heatmaps	Rotterdam, Amsterdam, Den Haag, Utrecht, Niederlande	4.317 Personen - Tag-Datensätze
Hess	2001	Befragung Mobilitätsverhalten 1994	Querschnitt	Diskrete Wahlmodelle (MNL)	Portland, USA	523 Wege
Hong et al.	2020	Strava-Daten für 2016	Panel	Panel-Regressionsmodell mit fixen Effekten und Interaktionsvariablen	Glasgow, Schottland	34.034 Fahrten
Hunecke et al.	2007	Befragungen Juni bis Dezember 2003	Querschnitt	Hierarchische Regressionsanalyse	Augsburg, Bielefeld, Magdeburg, Deutschland	1.991 Interviews
Kowald et al.	2022	Befragung September 2021 bis Februar 2022	Querschnitt	Diskrete Wahlmodelle (MNL)	20 Gemeinden in Mittel-West-Deutschland	220 Befragte, 2.184 Beobachtungen
Mertens et al.	2014	Strukturiertes Interview und eine Sortieraufgabe mit Fotos März und April 2013	Querschnitt	Lineare Regressionen auf mehreren Ebenen und qualitative Kategorisierung	Flandern, Brüssel, Belgien	66 Teilnehmende

Moudon et al.	2005	Telefonische Befragung Sommer und Frühherbst 2002	Querschnitt	Binäre Logit-Modelle unter Verwendung von Airline- und Netzwerk-Maßnahmen	Washington, USA	608 Haushalte
Nankervis	1999	Befragung frühe 1980er Jahre und 1990-1991 sowie Fahrrad-Verkehrsaufkommen	Querschnitt	Korrelationen	Melbourne, Australien	230 Teilnehmende
Parkin et al.	2008	UK-Zensus 2001	Querschnitt	Logit-Modell	England, Wales, Verein. Königreich	8.800 Bezirke
Pucher & Buehler	2006	Zensus	Querschnitt	Multiple Regression	Kanada, USA	59 Städte
Rietveld & Daniel	2004	Messung von Qualitätsaspekten und statistische Quellen	Querschnitt	Semilogarithmisches Regressionsmodell	Niederlande	103 Städte
Rowangould & Tayarani	2016	Befragung von Radfahrenden am National Bike to Work Day (16. Mai 2014)	Querschnitt	Diskrete Wahlmodelle(MNL)	Albuquerque, New Mexico, USA	585 Befragte
Rybarczyk & Wu	2014	Nationale telefonische Haushaltsbefragung zum Reiseverkehr 2001	Querschnitt	Logit-Modell	Madison, Wisconsin, USA	26.351 Wege
Saneinejad et al.	2012	Verkehrserhebung 8. September - 16. Dezember 2001 und 8. Mai - 12. Juni 2002	Querschnitt	Diskrete Wahlmodelle (MNL)	Toronto, Kanada	25.065 Wege
Santos et al.	2013	Urban Audit der Generaldirektion Regionalpolitik und Eurostat 2004	Querschnitt	Diskrete Auswahlmodelle: gemischtes Logit (MXL), Nested Logit (NL) und Multinomiales Logit (MNL)	Europa	112 Städte
Scheiner & Holz-Rau	2007	Persönliche Haushaltsbefragung in den Jahren 2002 und 2003	Querschnitt	Strukturgleichungsmodell	Köln, Deutschland	2.691 Einwohner
Thomas et al.	2009	Fahrradverkehr auf Radwegen	Zeitreihen	Zweistufige multiple lineare Regression	Niederlande	16 Wege
Ton et al.	2019	Mobilitätspanel (MPN) (September - November 2016), Befragung zu aktiven Verkehrsträgern Juni 2017	Panel	Diskretes Wahlmodell, multinomiales Logit-Modell (MNL), Paneleffekt unter Verwendung von gemischtes MNL-Modellen	Niederlande	6.368 Wege

Wardman et al.	2007	Nationale Verkehrserhebung 1985/1986, 1988-1993 und 1995-1997, 1998 RP-Daten, 1998 SP-Daten	Querschnitt	Hierarchisches Logit-Modell: Gemeinsames multinomiales RP-SP-Logit-Modell und Prognose	Leicester, Norwich, York and Hull, UK	30.116 Wege 969 RP-Angaben, 5.221 SP-Angaben
Wessel	2020	Fahrradzählung vom 01.01.2017 bis 31.12.2018	Zeitreihen	Log-lineare und negative binomiale Regression	37 Städte und Regionen in Deutschland	188 Zählstellen: 1.576.348 Beobachtungen
Wibowo & Olszewski	2005	Vor-Ort-Befragungen und Bewertungen von Routen	Querschnitt	Binäres Logit-Modell	Singapur	646 Beobachtungen
Wicki et al.	2019	Auswahlexperiment November, 2018	Querschnitt	Integriertes Modell und latente Variablen (ICLV)	Schweiz	773 Teilnehmer
Winters et al.	2007	Gesundheitsbefragung 2003	Querschnitt	Logit-Modell, mehrstufige multiple logistische Regression, hierarchische Modelle	Kanada	59.899 Personen
Winters et al.	2011	Radfahren in Städten - Befragung in drei saisonalen Wellen im Jahr 2006	Querschnitt	Mittlere Punktzahlen und Rangfolge, Faktorenanalyse	Vancouver, Kanada	1.402 Befragte
Witlox & Tindemans	2004	Mobilitätsbefragung 2000	Querschnitt	Deskriptiv	Gent, Niederlande	25.966 Wege
Zhang	2004	1991 Mobilitätsbefragung Boston, 1992 Mobilitätsbefragung Hongkong	Querschnitt	Diskrete Auswahlmodelle	Boston, USA Hong Kong, China	38.182 Wege

Anhang A 2: Betrachtete Literaturüberblicke und Meta-Studien Moduswahl

Autor*innen	Jahr	Datenerhebung	Untersuchungsgegenstand	Stichprobengröße
Carstensen & Ebert	2012	Literatur-Recherche	Radfahr-Kulturen	
Ewing & Cervero	2010	Meta-Analyse	Gebaute Umwelt	mehr als 200 Studien
Gardner & Abraham	2008	Meta-Analyse	Psychologische Korrelationen der Autonutzung	23 Studien
Heinen et al.	2010	Literatur-Recherche	Pendeln mit dem Fahrrad	
Hoffmann et al.	2017	Meta-Analyse	kognitive Mechanismen	43 Studien
Holmgren	2007	Meta-Analyse	PT-Nachfrage	81 Studien
Hunecke et al.	2022	Daten aus sechs Studien zwischen 2003-2011	Deutschland	
Hunecke	2018	Literaturstudie	Psychologie der Verkehrsmittelwahl	
Klobucar & Fricker	2007	Bestehendes Netz und sechs Szenarien	West Lafayette, Indiana	
Krizek et al.	2009	Literaturstudie	Gehen und Radfahren	
Lanzini & Khan	2017	Meta-Analyse	Psychologische und verhaltensbezogene Faktoren für die Wahl des Verkehrsmittels	58 Primärstudien
Pucher et al.	1999	Zensus-Daten	New York, San Francisco, Boston, Seattle, Madison (WI), Davis (CA), Toronto	
Pucher et al.	2011	Nationale aggregierte Daten	New York, Chicago, Toronto, Montréal, San Francisco, Washington, Vancouver, Portland, Minneapolis	
Southworth	2005	Literaturstudie	Stadtgestaltung	
Spencer et al.	2013	Qualitative Analyse	Vermont	24
Willis et al.	2015	Literaturstudie	Rad-Modelle	24 Studien

Anhang A 3: Betrachtete Studien Routenwahl

Autor*innen	Jahr	Datenerhebung	Studiendesign	Methode	Untersuchungsgebiet	Stichprobengröße
Alrutz	2015	Erhebung (Juli-Oktober 2012) und Beobachtungen (Frühjahr und Herbst 2012, Jan, Feb, Apr 2013)	Querschnitt	Deskriptiv	Bremen, Tübingen, Cuxhaven, Deutschland	358 Antworten 288 Antworten
Antonakos	1994	Befragung im Jahr 1992 bei vier Fahrradtouren	Querschnitt	Bivariate Analyse	Michigan, USA	552 Antworten
Aultman-Hall	1996	Routen von Radfahrenden	Querschnitt	Logit-Modell, Auswahlmenge = Kürzester Pfad	Guelph, Kanada	397 Fahrten
Axhausen & Smith	1986	SP-Befragung Februar 1984	Querschnitt	Lineare Regressionsanalyse	Wisconsin, USA	124 Studierende
Bernardi et al.	2018	Mobilitätspanel April und Mai 2014	Querschnitt	Mixed Logit-Modell, multinomiales Logit Auswahlmenge = Kürzester Pfad	Niederlande	3.502 Wege
Bovy & Bradley	1984	Befragung (ohne Jahr)	Querschnitt	OLS-Regression, Path-size mixed Logit-Modell; Auswahlsets mit Alternativen, die in allen Attributen variierten	Delft, Niederlande	134 Mitarbeitende
Broach & Dill	2016	GPS-Daten aus dem Jahr 2007	Querschnitt	Path-size Logit-Routenwahlmodell; Auswahlmenge: Maximierung individueller Kriterien zur Auswahl der Alternativen	Portland, USA	13.277 Fahrten
Broach et al.	2012	GPS-Daten aus dem Jahr 2007	Querschnitt	Path-size Logit-Routenwahlmodell; Auswahlmenge: Maximierung individueller Kriterien zur Auswahl der Alternativen	Portland, USA	1.449 Fahrten
Caulfield et al.	2012	Befragung (ohne Jahr)	Querschnitt	Multinomiales Logit-Modell, Segmentierung	Dublin, Irland	1.941 Befragte
Chen & Chen	2013	Befragung (Nov-Dez 2009)	Querschnitt	Multinomiale Logit (MNL), latentes Klassenmodell	Taiwan	232 Antworten
Chen et al.	2016	GPS-Daten 18.11.2009-24.03.2014	Querschnitt	Hauptkomponentenanalyse, Path-size-Logit-Modell;	Seattle, USA	2.922 Routen

				Wahlmöglichkeiten: Maximierung der prioritären Fahrradanlagen, Minimierung der Fahrstrecke		
Clark et al.	2019	Befragung 2014	Querschnitt	Lineare Regression, Regression nach Fahrertyp	Opelika, Anniston, Chattanooga, Northport, Talladega, Birmingham, USA	1.178 Antworten
Dill & Gliebe	2008	GPS-Daten März bis November 2007	Querschnitt	Ränge, Unterschiede; Auswahlmenge: kürzester Weg	Portland, USA	164 Teilnehmende; 1.953 Fahrten
Dozza et al.	2016	Naturalistische Fahrradaten (August und November 2013)	Querschnitt	Odds Ratios (OR) schätzten das Risiko, ein kritisches Ereignis zu erleben	Schweden	14 Radfahrende 88 kritische Ereignisse
Ghanayim & Bekhor	2018	GPS-gestützte Haushaltsbefragung Dezember 2013 und Juni 2014	Panel	Multinomiale Logit (MNL), C-Logit und Path-Size-Logit (PSL); verschiedene Methoden für Auswahlmengen	Tel Aviv, Israel	545 Fahrten, 221 Personen
Gonzalez et al.	2016	Erhebungen an den Verleihstationen im November 2012 und März 2013	Querschnitt	Gemischtes Logit-Modell; Auswahlmenge: alle von den Nutzern gewählten OD- Kombinationen, vier kürzeste Routen	Santiago, Chile	16.508 Fahrten
Hardinghaus & Nieland	2021	Fahrrad-Routenplaner BBBike 2017	Querschnitt	Cluster Analyse	Berlin, Deutschland	461.170 Antworten
Hardinghaus & Papantoniou	2021	Experiment; Herbst 2018 und Frühjahr 2019	Querschnitt	Mixed Logit-Modell	Deutschland Griechenland	38.200 Beobachtungen
Hood et al.	2011	Routen von CycleTracks 12. November 2009-18. April 2010	Querschnitt	Multinomiales Path-size- Logit-Modell Auswahlmengen: erzeugt durch doppelt stochastische Suche nach dem kürzesten Weg	San Francisco, USA	5.178 Fahrten
Hopkins & Wardman	1996	Befragung Juni 1993	Querschnitt	Disaggregiertes Logit-Modell für erklärte Präferenzen und inkrementelles Logit-Modell für Prognosen	Bradford, Shipley, UK	155 Personen mit 2.480 SP-Wahlen
Hunt & Abraham	2007	Befragung September 1994	Querschnitt	Logit-Wahlmodell	Edmonton, Kanada	1.128 Befragte

Koh & Wong	2013	Wahrnehmungserhebung (persönliche Befragung) (kein Jahr)	Querschnitt	Logistisches Regressionsmodell	Singapur	867 Geh- und 964 Fahrrad-Segmente
Krenn et al.	2014	Häufigste Fahrradfahrt auf einer Karte einzeichnen 2005, GPS-Datenlogger für vier Tage 2010	Querschnitt	Entfernungsunterschiede und t-Tests; Wahlmenge: kürzeste Entfernung	Graz, Schweiz	113 Teilnehmende; 278 Fahrten
Landis et al.	1997	Feedback zu Echtzeit-Wahrnehmungen (ohne Jahr)	Querschnitt	Regressionsanalyse; wahrgenommene Qualität	USA	150 Radfahrende 4.300 Beobachtungen
Liu et al.	2020	Befragung September 2018	Querschnitt	Linear-additive Nutzenfunktion und ein multinomiales Logit-Modell	Tianjin, China	803 Befragte
MacArthur et al.	2014	E-Bike-Befragung 7. März bis 1. Juli 2013 online	Querschnitt	Deskriptiv	Portland, USA	553 Befragte
Menghini et al.	2010	GPS-Beobachtungen (ohne Jahr)	Querschnitt	Multinomiales Path-size-Logit-Modell Auswahlmenge: kürzester Weg	Zürich, Schweiz	73.493 Fahrten
Mertens et al.	2014	Strukturiertes Interview und eine Sortieraufgabe mit Panoramafotos März und April 2013	Querschnitt	Lineare Regressionsmodelle auf mehreren Ebenen und qualitative Kategorisierung	Flandern, Brüssel Belgien	66 Teilnehmende
Mertens et al.	2016	Choice-Based-Conjoint-Methode (CBC) mit Wahlaufgaben und manipulierten Fotos März und April 2013	Querschnitt	Wahlbasierte Conjoint-Analyse	Flandern, Brüssel Belgien	1.949 Teilnehmende
Poorfakhraei & Rowangould	2015	Befragung (Frühjahr 2014)	Querschnitt	Logit-Modelle	Albuquerque, New Mexico, USA	161 Beobachtungen
Prato et al.	2018	GPS-Geräte und Befragung (i) von Oktober bis Dezember 2012, (ii) von Juni bis Juli 2013 und (iii) von August bis Oktober 2013	Querschnitt	Gemischte Logit-Modelle; Wahlmenge: doppelt stochastische Generierung (berücksichtigt Variationen in den Kosten und den Präferenzen der Reisenden)	Kopenhagen, Dänemark	3.384 Fahrten bei 291 Radfahrenden

Rossetti et al.	2019	Teilexperiment: Wahl des Straßendesigns (2014)	Querschnitt	Binomial-Logit-Modelle und ein integriertes Modell für Wahlmöglichkeiten und latente Klassen	Santiago, Chile	1.184 SP-Wahlen von 346 Personen
Schleinitz	2014	Naturalistische Radfahrstudie Juli-November 2012	Querschnitt	Deskriptiv	Chemnitz, Deutschland	4.300 Fahrten
Sener et al.	2009	Webbasierte Befragung (ohne Jahr)	Querschnitt	Gemischtes multinomiales Logit-Panel	Texas, USA	1.621 Befragte
Skov-Petersen et al.	2018	GPS-Geräte April/Mai, 2011	Querschnitt	Conditional Logit-Modell; Auswahlmenge: zweistufig, Straßenabschnitt, der am direktesten zum Ziel führt	Kopenhagen, Dänemark	183 Radfahrende, 1.267 Fahrten
Stinson & Bhat	2003	Befragung Februar-April, 2002	Querschnitt	Logit-Modell	USA	3.145 Personen ca. 35.000 Wege
Stinson & Bhat	2005	Befragung Februar-April, 2003	Querschnitt	Logit-Modell	USA	3.145 Personen ca. 35.000 Wege
Tilahun et al.	2007	Befragung (ohne Jahr)	Querschnitt	Gemischtes Logit-Modell; binominales Logit-Modell	Minnesota, USA	167 Befragte
Vedel et al.	2017	Experiment April und Mai 2011	Querschnitt	Random parameter Logit-Modell	Kopenhagen, Dänemark	3.891 Radfahrende 23.159 Wahlsets
Winters & Teschke	2010	Befragung mit Bildern zur Darstellung von 16 Routentypen 2006	Querschnitt	Multiple lineare Regression	Vancouver, Kanada	1.402 aktuelle und potenzielle Radfahrende
Winters et al.	2010	Ausgangs- und Zielorte der üblichen Nicht-Freizeitreisen 2-Wochen im August 2008 Interviews	Querschnitt	Logistische Regression; Auswahlmenge: Modellierung des kürzesten Weges	Vancouver, Kanada	74 Teilnehmende
Zimmermann et al.	2017	GPS-Daten (ohne Jahr)	Querschnitt	Rekursives Logit-Modell	Eugene, USA	648 Fahrten von 103 Nutzenden

Anhang A 4: Betrachtete Literaturüberblicke und Meta-Studien Routenwahl

Autor*innen	Jahr	Datenerhebung	Untersuchungsgegenstand	Stichprobengröße
Aldred et al.	2016	Literatur-Studie	Präferenzen	54 Studien
Buehler & Dill	2016	Literatur-Studie	Radwegnetze	84 Studien
Dill & Rose	2012	Interviews	Portland, Oregon	28 Personen
Heinen et al.	2010	Literatur-Studie	Pendeln mit dem Fahrrad	
Johnson et al.	2013	Naturalistische Radfahrstudie mit Pendlern (Oktober 2009-April 2010)	Melbourne, Australien	13 Ereignisse

Interviewleitfaden

Vorstellung

- Bitte stellen Sie sich und Ihr Unternehmen/Projekt kurz vor.

Datenverfügbarkeit und Datenerhebung

- Werden Mobilitätsdaten in Ihrem Unternehmen/Projekt generiert?
 - Daten zu gesamtem Wegstrecken inkl. Orts- und Zeitstempel („Trajektorien“ aus GPS-Daten) oder „nur“ Anfangs- und Endpunkte von Fahrten oder gar keine Informationen zu einzelnen Fahrten?
 - Welche Verkehrsmittel?
 - Daten zu den Nutzenden? (z. B. soziodemographische Daten)
 - Daten zum genutzten Fahrzeug?
 - Wegezwecke?
 - Als wie repräsentativ schätzen Sie Ihre gewonnenen Daten ein?
 - Weitere Besonderheiten Ihrer Daten
- Wie werden diese Daten erhoben?
 - App, Befragungen, Zählungen etc.?
 - AI / automatische Erkennung etc.?
 - Haben die Radfahrenden einer Nutzung der Daten zugestimmt? Welche Art von Nutzung? Wie erfolgt die Zustimmung?
 - Anonymisieren Sie Ihre Daten?
- Werden diese Daten gespeichert?
 - Wenn ja: Wie lange werden welche Daten gespeichert?
 - Wenn ja: In welcher Form liegen die Daten vor? (Beispiel: Daten werden in aggregierter Form gespeichert und die Originaldaten werden gelöscht)
 - Wenn nein: Warum speichern Sie bestimmte Daten nicht?
 - Rechtliche Gründe
 - Technische Gründe (z. B. IT-Infrastruktur, Personal)
 - Wirtschaftliche Gründe
- Können die Daten von anderen Akteuren genutzt werden? (z. B. von Städten für die Verkehrsplanung?)

Datenerhebung fehlender Daten

- Wäre es aus Ihrer Perspektive möglich, folgende Daten zu erheben?
 - Moduswahl
 - Routenwahl mit dem Fahrrad
 - Persönliche Daten
 - Räumliche Daten, z. B. Infrastrukturdaten
 - Befragungselemente, z. B. zu Alternativrouten, zu subjektiven Eindrücken
- Spezifischer:
 - Personenbezogene Daten
 - Alter, Geschlecht
 - Einkommen und Bildung
 - Haushaltsgröße und Anzahl Kinder
 - Art des Fahrrads
 - Verfügbarkeit Dienstwagen

- Anschaffungskosten Fahrrad
- Routenspezifische Daten
 - Tatsächliche Reisezeiten (Fahrrad und Wege zu Fuß)
 - Verlustzeiten an Knotenpunkten
 - LSA-Umlaufzeiten
 - Dauer bei Steigungen
- Durchschnittsangaben
 - Fahrradzugangszeiten insb. bei große Fahrradabstellanlagen
 - Durchschnittliche Zeit pro Umstieg im ÖV
- Flächendeckende Angaben
 - Infrastrukturerfassung (Radverkehr, Fußverkehr)
- Was muss bei einer Datenerhebung beachtet werden?
 - Nutzerakquise, Durchführung... technische Umsetzung...Repräsentativität
- Wie kann sichergestellt werden, dass unterschiedliche Gruppen bei der Datenerhebung berücksichtigt werden?
 - Jung, alt
 - Stadt, Land
 - Nutzende und Nicht-Nutzende
 - Repräsentativ

Literaturverzeichnis

Anmerkung: Studien, die in Tabelle 1 enthalten sind, mit Nummerierung in eckigen Klammern enthalten.

- ADFC (2020). Ergebnisse ADFC-Fahrradklima-Test. https://fahrradklima-test.adfc.de/fileadmin/BV/FKT/Download-Material/Ergebnisse_2020/Rankingliste_FKT_2020.pdf
- Ahrens, G., Wittwer, R., Hubrich, S., Wittig, S., & Ließke, F. (2016). Sonderauswertung zum Forschungsprojekt „Mobilität in Städten – SrV 2013“ Städtevergleich. https://tu-dresden.de/bu/verkehr/ivs/srv/ressourcen/dateien/2013/uebersichtsseite/SrV2013_Staedtevergleich.pdf?lang=de.
- Akar, G., & Clifton, K. J. (2009). Influence of Individual Perceptions and Bicycle Infrastructure on Decision to Bike. *Transportation Research Record: Journal of the Transportation Research Board*, 2140(1), 165–172. <https://doi.org/10.3141/2140-18> [1]
- Aldred, R., Elliott, B., Woodcock, J., & Goodman, A. (2017). Cycling provision separated from motor traffic: A systematic review exploring whether stated preferences vary by gender and age. *Transport Reviews*, 37(1), 29–55. <https://doi.org/10.1080/01441647.2016.1200156>
- Alrutz, D., Angenendt, W., Draeger, W., & Gündel, D. (2002). Verkehrssicherheit in Einbahnstraßen mit gegengerichtetem Radverkehr. *Straßenverkehrstechnik*, 6/2002.
- Alrutz, D., Bohle, W., Hacke, U., Lohmann, G., & Friedrich, N. (2015). Potenzielle Einflüsse von Pedelecs auf die Verkehrssicherheit: Schlussbericht der Forschungsarbeit Nr. FE 82.0533 der Bundesanstalt für Straßenwesen. https://www.iwu.de/fileadmin/publikationen/verkehr/2015_PGVetIWU_HackeEtAl_Potenzielle-Einfl%C3%BCsse-von-Pedelecs-auf-die-Verkehrssicherheit.pdf
- An, R., Zahnow, R., Pojani, D., & Corcoran, J. (2019). Weather and cycling in New York: The case of Citibike. *Journal of Transport Geography*, 77, 97–112. <https://doi.org/10.1016/j.jtrangeo.2019.04.016> [2]
- Antonakos, C. L. (1994). Environmental and Travel Preferences of Cyclists. *Transportation Research Record: Journal of the Transportation Research Board* (1438), 25–33.
- Arning, L., Silva, C., Kath, H. (2023). Review of Current Practice and Research on E-Bikes in Transport Models, *Transportation Research Record*, 0(0), 1–13.
- Asensio, J. (2002). Transport Mode Choice by Commuters to Barcelona's CBD. *Urban Studies*, 39(10), 1881–1895. <https://doi.org/10.1080/0042098022000003000> [3]
- Bergström, A., & Magnusson, R. (2003). Potential of transferring car trips to bicycle during winter. *Transportation Research Part a: Policy and Practice*, 37(8), 649–666. [https://doi.org/10.1016/S0965-8564\(03\)00012-0](https://doi.org/10.1016/S0965-8564(03)00012-0) [4]
- Bernardi, S., La Paix-Puello, L., & Geurs, K. (2018). Modelling route choice of Dutch cyclists using smartphone data. *Journal of Transport and Land Use*, 11(1). <https://doi.org/10.5198/jtlu.2018.1143>
- Blanc, B., Figliozzi, M., & Clifton, K. (2016). How Representative of Bicycling Populations Are Smartphone Application Surveys of Travel Behavior? *Transportation Research Record: Journal of the Transportation Research Board*, 2587(1), 78–89. <https://doi.org/10.3141/2587-10>

- BMU. (2018). FÖRDERPROGRAMM. <https://nationaler-radverkehrsplan.de/de/bund/foerderprogramm>.
- Boss, D., Nelson, T., Winters, M., & Ferster, C. J. (2018). Using crowdsourced data to monitor change in spatial patterns of bicycle ridership. *Journal of Transport & Health*, 9, 226–233. <https://doi.org/10.1016/j.jth.2018.02.008>
- Bovy, P. H. L., & Bradley, M. A. (1985). Route Choice Analyzed with Stated-Preference Approaches. *Transportation Research Record: Journal of the Transportation Research Board* (1037), 11–20.
- Brandenburg, C., Matzarakis, A., & Arnberger, A. (2007). Weather and cycling - a first approach to the effects of weather conditions on cycling. *Meteorological Applications*, 14(1), 61–67. <https://doi.org/10.1002/met.6> [5]
- Broach, J., & Dill, J. (2016). Using Predicted Bicyclist and Pedestrian Route Choice to Enhance Mode Choice Models. *Transportation Research Record: Journal of the Transportation Research Board*, 2564(1), 52–59. <https://doi.org/10.3141/2564-06> [6]
- Broach, J., Dill, J., & Gliebe, J. (2012). Where do cyclists ride? A route choice model developed with revealed preference GPS data. *Transportation Research Part a: Policy and Practice*, 46(10), 1730–1740. <https://doi.org/10.1016/j.tra.2012.07.005>
- Buehler, R., & Dill, J. (2016). Bikeway Networks: A Review of Effects on Cycling. *Transport Reviews*, 36(1), 9–27. <https://doi.org/10.1080/01441647.2015.1069908>
- Carstensen, T. A., & Ebert, A.-K. (2012). Chapter 2 Cycling Cultures in Northern Europe: From ‘Golden Age’ to ‘Renaissance’. In J. Parkin (Ed.), *Transport and Sustainability. Cycling and Sustainability* (pp. 23–58). Emerald Group Publishing Limited. [https://doi.org/10.1108/S2044-9941\(2012\)0000001004](https://doi.org/10.1108/S2044-9941(2012)0000001004) [7]
- Caulfield, B., Brick, E., & McCarthy, O. T. (2012). Determining bicycle infrastructure preferences – A case study of Dublin. *Transportation Research Part D: Transport and Environment*, 17(5), 413–417. <https://doi.org/10.1016/j.trd.2012.04.001>
- Cervero, R. (2002). Built environments and mode choice: toward a normative framework. *Transportation Research Part D: Transport and Environment*, 7(4), 265–284. [https://doi.org/10.1016/S1361-9209\(01\)00024-4](https://doi.org/10.1016/S1361-9209(01)00024-4) [11]
- Cervero, R., Denman, S., & Jin, Y. (2019). Network design, built and natural environments, and bicycle commuting: Evidence from British cities and towns. *Transport Policy*, 74, 153–164. <https://doi.org/10.1016/j.tranpol.2018.09.007> [10]
- Cervero, R., & Duncan, M. (2003). Walking, bicycling, and urban landscapes: Evidence from the San Francisco Bay Area. *American Journal of Public Health*, 93(9), 1478–1483. <https://doi.org/10.2105/AJPH.93.9.1478> [8]
- Cervero, R., Sarmiento, O. L., Jacoby, E., Gomez, L. F., & Neiman, A. (2009). Influences of Built Environments on Walking and Cycling: Lessons from Bogotá. *International Journal of Sustainable Transportation*, 3(4), 203–226. <https://doi.org/10.1080/15568310802178314> [9]
- Chen, C.-F., & Chen, P.-C. (2013). Estimating recreational cyclists’ preferences for bicycle routes – Evidence from Taiwan. *Transport Policy*, 26, 23–30. <https://doi.org/10.1016/J.TRANPOL.2012.01.001>

- Chen, P., Shen, Q., & Childress, S. (2018). A GPS data-based analysis of built environment influences on bicyclist route preferences. *International Journal of Sustainable Transportation*, 12(3), 218–231. <https://doi.org/10.1080/15568318.2017.1349222>
- Clark, C., Mokhtarian, P., Circella, G., & Watkins, K. (2019). User Preferences for Bicycle Infrastructure in Communities with Emerging Cycling Cultures. *Transportation Research Record: Journal of the Transportation Research Board*, 2673(12), 89–102. <https://doi.org/10.1177/0361198119854084>
- Corcoran, J., Li, T., Rohde, D., Charles-Edwards, E., & Mateo-Babiano, D. (2014). Spatiotemporal patterns of a Public Bicycle Sharing Program: the effect of weather and calendar events. *Journal of Transport Geography*, 41, 292–305. <https://doi.org/10.1016/j.jtrangeo.2014.09.003> [12]
- dell’Olio, L., Ibeas, A., Oña, J. de, & Oña, R. de. (2018). Designing a Survey for Public Transport Users. In *Public Transportation Quality of Service* (pp. 49–61). <https://doi.org/10.1016/B978-0-08-102080-7.00004-5>
- Dhakal, N., Cherry, C. R., Ling, Z., & Azad, M. (2018). Using CyclePhilly data to assess wrong-way riding of cyclists in Philadelphia. *Journal of safety research*, 67, 145-153.
- Dill, J., & Carr, T. (2003). Bicycle Commuting and Facilities in Major U.S. Cities: If You Build Them, Commuters Will Use Them. *Transportation Research Record: Journal of the Transportation Research Board*, 1828(1), 116–123. <https://doi.org/10.3141/1828-14> [13]
- Dill, J., & Rose, G. (2012). Electric Bikes and Transportation Policy. *Transportation Research Record: Journal of the Transportation Research Board*, 2314(1), 1–6. <https://doi.org/10.3141/2314-01>
- Dill, J., & Voros, K. (2007). Factors Affecting Bicycling Demand. *Transportation Research Record: Journal of the Transportation Research Board*, 2031(1), 9–17. <https://doi.org/10.3141/2031-02> [14]
- Dozza, M., Bianchi Piccinini, G. F., & Werneke, J. (2016). Using naturalistic data to assess e-cyclist behavior. *Transportation Research Part F: Traffic Psychology and Behaviour*, 41, 217–226. <https://doi.org/10.1016/j.trf.2015.04.003>
- Duncan, M. J., Badland, H. M., & Mummery, W. K. (2009). Applying GPS to enhance understanding of transport-related physical activity. *Journal of Science and Medicine in Sport*, 12(5), 549–556. <https://doi.org/10.1016/j.jsams.2008.10.010>
- Eggs, J., Follmer, R., Gruschwitz, D., Nobis, C., Bäumer, M., & Pfeiffer, M. (2018). *Mobilität in Deutschland– MiD: Methodenbericht*.
- Eluru, N., Chakour, V., & El-Geneidy, A. M. (2012). Travel mode choice and transit route choice behavior in Montreal: insights from McGill University members commute patterns. *Public Transport*, 4(2), 129–149. <https://doi.org/10.1007/s12469-012-0056-2> [15]
- Ewing, R., & Cervero, R. (2010). Travel and the Built Environment. *Journal of the American Planning Association*, 76(3), 265–294. <https://doi.org/10.1080/01944361003766766> [16]
- FGSV (2021). *H EBRA - Hinweise zur einheitlichen Bewertung von Radverkehrsanlagen*. ISBN: 978-3-86446-296-2
- FGSV (2018). *Hinweise für die Durchführung von Haushaltsbefragungen zum Mobilitätsverhalten*. ISBN 978-3-86446-211-5

- FGSV (2012). Empfehlungen für Verkehrserhebungen. ISBN: 978-3-941790-99-5
- Flynn, B. S., Dana, G. S., Sears, J., & Aultman-Hall, L. (2012). Weather factor impacts on commuting to work by bicycle. *Preventive Medicine*, 54(2), 122–124. <https://doi.org/10.1016/J.YPMED.2011.11.002> [17]
- Francke, A., Lißner, S., & Becker, T. (2018). Big Data im Radverkehr: Ergebnisbericht „Mit Smartphones generierte Verhaltensdaten im Radverkehr“. <https://tud.qucosa.de/api/qucosa%3A31011/attachment/ATT-0/>
- Gardner, B., & Abraham, C. (2008). Psychological correlates of car use: A meta-analysis. *Transportation Research Part F: Traffic Psychology and Behaviour*, 11(4), 300–311. <https://doi.org/10.1016/j.trf.2008.01.004> [18]
- Garrard, J., Rose, G., & Lo, S. K. (2008). Promoting transportation cycling for women: The role of bicycle infrastructure. *Preventive Medicine*, 46(1), 55–59. <https://doi.org/10.1016/j.ypmed.2007.07.010> [19]
- Gebhart, K., & Noland, R. B. (2014). The impact of weather conditions on bikeshare trips in Washington, DC. *Transportation*, 41(6), 1205–1225. <https://doi.org/10.1007/s11116-014-9540-7> [20]
- Goldmann, K., & Wessel, J. (2021). Some people feel the rain, others just get wet: An analysis of regional differences in the effects of weather on cycling. *Research in Transportation Business & Management*, 40, 100541. <https://doi.org/10.1016/j.rtbm.2020.100541> [21]
- González, F., Melo-Riquelme, C., & Grange, L. de (2016). A combined destination and route choice model for a bicycle sharing system. *Transportation*, 43(3), 407–423. <https://doi.org/10.1007/s11116-015-9581-6>
- Griffin, G. P., & Jiao, J. (2015). Where does bicycling for health happen? Analysing volunteered geographic information through place and plexus. *Journal of Transport & Health*, 2(2), 238–247. <https://doi.org/10.1016/j.jth.2014.12.001>
- Habib, K. N. (2019). Mode choice modelling for hailable rides: An investigation of the competition of Uber with other modes by using an integrated non-compensatory choice model with probabilistic choice set formation. *Transportation Research Part a: Policy and Practice*, 129, 205–216. <https://doi.org/10.1016/j.tra.2019.08.014> [22]
- Hagen, T., Reinfeld, N., & Saki, S. (2023). Modeling of Parking Violations Using Zero-Inflated Negative Binomial Regression: A Case Study for Berlin. *Transportation Research Record*, 2677(6), 498–512. <https://doi.org/10.1177/03611981221148703>
- Hardinghaus, M. (2021). Exploring Bikeability. <https://doi.org/10.18452/23574> [23]
- Hardinghaus, M., Nieland, S., Lehne, M., & Weschke, J. (2021). More than Bike Lanes—A Multifactorial Index of Urban Bikeability. *Sustainability*, 13(21), 11584. <https://doi.org/10.3390/su132111584>
- Haustein, S., Hunecke, M., & Manz, W. (2007). Verkehrsmittelnutzung unter Einfluss von Wetterlage und -empfindlichkeit. *Internationales Verkehrswesen*, 59(9).
- Heaney, A. K., Carrión, D., Burkart, K., Lesk, C., & Jack, D. (2019). Climate Change and Physical Activity: Estimated Impacts of Ambient Temperatures on Bikeshare Usage in New York City. *Environmental Health Perspectives*, 127(3), 37002. <https://doi.org/10.1289/EHP4039> [24]

- Heesch, K. C., & Langdon, M. (2016). The usefulness of GPS bicycle tracking data for evaluating the impact of infrastructure change on cycling behaviour. *Health Promotion Journal of Australia: Official Journal of Australian Association of Health Promotion Professionals*, 27(3), 222–229. <https://doi.org/10.1071/HE16032>
- Heinen, E. & Buehler, R. (2019). Bicycle parking: a systematic review of scientific literature on parking behaviour, parking preferences, and their influence on cycling and travel behaviour, *Transport Reviews*, <https://doi.org/10.1080/01441647.2019.1590477>
- Heinen, E., van Wee, B., & Maat, K. (2010). Commuting by Bicycle: An Overview of the Literature. *Transport Reviews*, 30(1), 59–96. <https://doi.org/10.1080/01441640903187001> [25]
- Heinrichs, D., & Jarass, J. (2020). Alltagsmobilität in Städten gesund gestalten: wie Stadtplanung Fußund Radverkehr fördern kann [Designing healthy mobility in cities: how urban planning can promote walking and cycling]. *Bundesgesundheitsblatt, Gesundheitsforschung, Gesundheitsschutz*, 63(8), 945–952. <https://doi.org/10.1007/s00103-020-03180-1>
- Helbich, M., Böcker, L., & Dijst, M. (2014). Geographic heterogeneity in cycling under various weather conditions: evidence from Greater Rotterdam. *Journal of Transport Geography*, 38, 38–47. <https://doi.org/10.1016/j.jtrangeo.2014.05.009> [26]
- Hess, D. B. (2001). Effect of Free Parking on Commuter Mode Choice: Evidence from Travel Diary Data. *Transportation Research Record: Journal of the Transportation Research Board*, 1753(1), 35–42. <https://doi.org/10.3141/1753-05> [27]
- Hoffmann, C., Abraham, C., White, M. P., Ball, S., & Skippon, S. M. (2017). What cognitive mechanisms predict travel mode choice? A systematic review with meta-analysis. *Transport Reviews*, 37(5), 631–652. <https://doi.org/10.1080/01441647.2017.1285819> [28]
- Holmgren, J. (2007). Meta-analysis of public transport demand. *Transportation Research Part A: Policy and Practice*, 41(10), 1021-1035. [62]
- Hong, J., Philip McArthur, D., & Stewart, J. L. (2020). Can providing safe cycling infrastructure encourage people to cycle more when it rains? The use of crowdsourced cycling data (Strava). *Transportation Research Part a: Policy and Practice*, 133, 109–121. <https://doi.org/10.1016/j.tra.2020.01.008> [29]
- Hood, J., Sall, E., & Charlton, B. (2011). A GPS-based bicycle route choice model for San Francisco, California. *Transportation Letters*, 3(1), 63–75. <https://doi.org/10.3328/TL.2011.03.01.63-75>
- Huber, S. (2022). Analyse des Routenwahlverhaltens von Radfahrenden auf Grundlage GPS-basierter Daten zum real beobachteten Verkehrsverhalten, <https://tud.qucosa.de/api/qucosa%3A79035/attachment/ATT-0/>
- Huber, S., Lißner, S., & Francke, A. (2019). Utility of GPS data for urban bicycle traffic planning in germany: Potentiality, limitations and prospects. *International Journal of Transport Development and Integration*, 3(1), 1–14. <https://doi.org/10.2495/TDI-V3-N1-1-14>
- Hunecke, M. (2015). *Mobilitätsverhalten verstehen und verändern*. Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-08825-5> [32]
- Hunecke, M., Haustein, S., Grischkat, S., & Böhler, S. (2007). Psychological, sociodemographic, and infrastructural factors as determinants of ecological impact caused by mobility behavior.

Journal of Environmental Psychology, 27(4), 277–292.

<https://doi.org/10.1016/j.jenvp.2007.08.001> [30]

Hunecke, M., Heppner, H., & Groth, S. (2022). Fragebogen zu psychologischen Einflussfaktoren der Nutzung von Pkw, ÖPNV und Fahrrad (PsyVKN). *Diagnostica*, 68(1), 3–13.

<https://doi.org/10.1026/0012-1924/a000277> [31]

Hunt, J. D., & Abraham, J. E. (2007). Influences on bicycle use. *Transportation*, 34(4), 453–470.

<https://doi.org/10.1007/s11116-006-9109-1>

InnaMoRuhr (2023). <https://innamo.ruhr/> (letzter Abruf 12.09.2023).

Kaur, J., Singh, J., Sehra, S. S., & Rai, H. S. (2017). Systematic Literature Review of Data Quality Within OpenStreetMap. In 2017 International Conference on Next Generation Computing and Information Systems (ICNGCIS) (pp. 177–182). IEEE. <https://doi.org/10.1109/ICNGCIS.2017.35>

Klobucar, M. S., & Fricker, J. D. (2007). Network Evaluation Tool to Improve Real and Perceived Bicycle Safety. *Transportation Research Record: Journal of the Transportation Research Board*, 2031(1), 25–33. <https://doi.org/10.3141/2031-04> [33]

Kowald, M., Gutjar, M., Röth, K., Schiller, C., & Dannewald, T. (2022). Mode Choice Effects on Bike Sharing Systems. *Applied Sciences*, 12(9), 4391.[63]

Krause, J. (2020). Genderbelange in der Verkehrsplanung. In Apel, Bracher Hg. *Handbuch der kommunalen Verkehrsplanung*. 88. Ergänzungslieferung.

Krenn, P. J., Oja, P., & Titze, S. (2014). Route choices of transport bicyclists: A comparison of actually used and shortest routes. *The International Journal of Behavioral Nutrition and Physical Activity*, 11(1), 31. <https://doi.org/10.1186/1479-5868-11-31>

Krizek, K. J., Forsyth, A., & Baum, L. (2009). *Walking and Cycling International Literature Review: Final Report*.

<https://www.pedbikeinfo.org/cms/downloads/Krizek%20Walking%20and%20Cycling%20Literature%20Review%202009-1.pdf> [34]

Kwigizile, V., Oh, J.-S., & Kwayu, K. (2019). Integrating Crowdsourced Data with Traditionally Collected Data to Enhance Estimation of Bicycle Exposure Measure.

<https://rosap.ntl.bts.gov/view/dot/44138>

Lajunen, T., & Summala, H. (2003). Can we trust self-reports of driving? Effects of impression management on driver behaviour questionnaire responses. *Transportation Research Part F: Traffic Psychology and Behaviour*, 6(2), 97–107. [https://doi.org/10.1016/S1369-8478\(03\)00008-1](https://doi.org/10.1016/S1369-8478(03)00008-1)

Lanzini, P., & Khan, S. A. (2017). Shedding light on the psychological and behavioral determinants of travel mode choice: A meta-analysis. *Transportation Research Part F: Traffic Psychology and Behaviour*, 48, 13–27. <https://doi.org/10.1016/j.trf.2017.04.020> [35]

Leao, S., Lieske, S., Conrow, L., Doig, J., Mann, V., & Pettit, C. (2017). Building a National-Longitudinal Geospatial Bicycling Data Collection from Crowdsourcing. *Urban Science*, 1(3), 23. <https://doi.org/10.3390/urbansci1030023>

Lee, K., & Sener, I. N. (2021). Strava Metro data for bicycle monitoring: a literature review. *Transport Reviews*, 41(1), 27–47. <https://doi.org/10.1080/01441647.2020.1798558>

- Lißner, S. (2022). Welche Einflussfaktoren eignen sich für die Typisierung von Radfahrer*innen mittels GPS-Daten? Ein Ansatz zur Kalibrierung von Self-Selected-Samples. <https://doi.org/10.26128/2021.256>
- MacArthur, J., Dill, J., & Person, M. (2014). Electric Bikes in North America. *Transportation Research Record: Journal of the Transportation Research Board*, 2468(1), 123–130. <https://doi.org/10.3141/2468-14>
- Matyas, M., & Kamargianni, M. (2017). A stated preference experiments for mobility-as-a-service plans. In *2017 5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)* (pp. 738–743). IEEE. <https://doi.org/10.1109/MTITS.2017.8005610>
- McBain, C. & Caulfield, B. (2018). An analysis of the factors influencing journey time variation in the cork public bike system. *Sustainable Cities and Society*, 42, 641–649, <https://doi.org/10.1016/j.scs.2017.09.030>
- Menghini, G., Carrasco, N., Schüssler, N., & Axhausen, K. W. (2010). Route choice of cyclists in Zurich. *Transportation Research Part a: Policy and Practice*, 44(9), 754–765. <https://doi.org/10.1016/j.tra.2010.07.008>
- Mertens, L., van Holle, V., Bourdeaudhuij, I. de, Deforche, B., Salmon, J., Nasar, J., van de Weghe, N., van Dyck, D., & van Cauwenberg, J. (2014). The effect of changing micro-scale physical environmental factors on an environment's invitingness for transportation cycling in adults: An exploratory study using manipulated photographs. *The International Journal of Behavioral Nutrition and Physical Activity*, 11, 88. <https://doi.org/10.1186/s12966-014-0088-x> [36]
- MiD (2023). https://www.mobilitaet-in-deutschland.de/downloads/infas_PersonenUndWegeFragebogen_MiD2023.pdf (letzter Abruf 12.09.2023)
- MoBudget (2023). <https://www.hs-rm.de/de/hochschule/aktuelles/details/artikel/forschungsprojekt-mobudget> (letzter Abruf: 12.09.2023).
- Motoaki, Y., Daziano, R., (2015). A hybrid-choice latent-class model for the analysis of the effects of weather on cycling demand, *Transportation Research Part A* 75 (2015) 217–230 <https://www.sciencedirect.com/science/article/abs/pii/S0965856415000592>
- Moudon, A. V., Lee, C., Cheadle, A. D., Collier, C. W., Johnson, D., Schmid, T. L., & Weather, R. D. (2005). Cycling and the built environment, a US perspective. *Transportation Research Part D: Transport and Environment*, 10(3), 245–261. <https://doi.org/10.1016/j.trd.2005.04.001> [37]
- Nankervis, M. (1999). The effect of weather and climate on bicycle commuting. *Transportation Research Part a: Policy and Practice*, 33(6), 417–431. [https://doi.org/10.1016/S0965-8564\(98\)00022-6](https://doi.org/10.1016/S0965-8564(98)00022-6) [38]
- Nkurunziza, A., Zuidgeest, M., Brussel, M., & Van Maarseveen, M. (2012). Examining the potential for modal change: Motivators and barriers for bicycle commuting in Dar-es-Salaam. *Transport policy*, 24, 249-259

- Nytechuk, N. (2019). Active Transportation and the Performance of Passive Infrared Sensors: A Functional Test Case Scenario in Winnipeg, Canada., 1–7.
- Orellana, D., & Guerrero, M. L. (2019). Exploring the influence of road network structure on the spatial behaviour of cyclists using crowdsourced data. *Environment and Planning B: Urban Analytics and City Science*, 46(7), 1314–1330. <https://doi.org/10.1177/2399808319863810>
- Parkin, J., Wardman, M., & Page, M. (2008). Estimation of the determinants of bicycle mode share for the journey to work using census data. *Transportation*, 35(1), 93–109. <https://doi.org/10.1007/s11116-007-9137-5> [39]
- Plaudis, M., Azam, M., Jacoby, D., Drouin, M.-A., & Coady, Y. (2021). An Algorithmic Approach to Quantifying GPS Trajectory Error. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) Workshops*, 3909–3916
- Poorfakhraei, A., & Rowangould, G. M. (2015). Estimating Welfare Change Associated with Improvements in Urban Bicycling Facilities. *Journal of Transportation Engineering*, 141(11), Article 04015025. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000799](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000799)
- Prato, C. G., Halldórsdóttir, K., & Nielsen, O. A. (2018). Evaluation of land-use and transport network effects on cyclists' route choices in the Copenhagen Region in value-of-distance space. *International Journal of Sustainable Transportation*, 12(10), 770–781. <https://doi.org/10.1080/15568318.2018.1437236>
- Pucher, J., & Buehler, R. (2006). Why Canadians cycle more than Americans: A comparative analysis of bicycling trends and policies. *Transport Policy*, 13(3), 265–279. <https://doi.org/10.1016/j.tranpol.2005.11.001> [40]
- Pucher, J., Buehler, R., & Seinen, M. (2011). Bicycling renaissance in North America? An update and reappraisal of cycling trends and policies. *Transportation Research Part a: Policy and Practice*, 45(6), 451–475. <https://doi.org/10.1016/j.tra.2011.03.001> [42]
- Pucher, J., Komanoff, C., & Schimek, P. (1999). Bicycling renaissance in North America? *Transportation Research Part a: Policy and Practice*, 33(7-8), 625–654. [https://doi.org/10.1016/S0965-8564\(99\)00010-5](https://doi.org/10.1016/S0965-8564(99)00010-5) [41]
- Reitmaier, S., Müller, P. N., Reinfeld, R., Tregel, T., Krajewski, A., Schäfer, P. K., Göbel, S. (2022). Spielerische Anreize für nachhaltige, intermodale Mobilität in der mobilen, nutzendenzentrierten Applikation »FlowMo« In: Eckart, P., Knöll, M., Lanzendorf, M., & Vöckler, K. (2022). *Mobility Design: Die Zukunft der Mobilität gestalten Band 2: Forschung* (p. 264). De Gruyter. <https://doi.org/10.1515/9783868597936-021>
- Rietveld, P., & Daniel, V. (2004). Determinants of bicycle use: do municipal policies matter? *Transportation Research Part a: Policy and Practice*, 38(7), 531–550. <https://doi.org/10.1016/J.TRA.2004.05.003> [43]
- Roese, N. J., & Vohs, K. D. (2012). Hindsight Bias. *Perspectives on Psychological Science : A Journal of the Association for Psychological Science*, 7(5), 411–426. <https://doi.org/10.1177/1745691612454303>
- Romanillos, G., Zaltz Austwick, M., Ettema, D., & Kruijff, J. de (2016). Big Data and Cycling. *Transport Reviews*, 36(1), 114–133. <https://doi.org/10.1080/01441647.2015.1084067>

- Rowangould, G. M., & Tayarani, M. (2016). Effect of Bicycle Facilities on Travel Mode Choice Decisions. *Journal of Urban Planning and Development*, 142(4), Article 04016019. [https://doi.org/10.1061/\(ASCE\)UP.1943-5444.0000341](https://doi.org/10.1061/(ASCE)UP.1943-5444.0000341) [44]
- Roy, A., Nelson, T. A., Fotheringham, A. S., & Winters, M. (2019). Correcting Bias in Crowdsourced Data to Map Bicycle Ridership of All Bicyclists. *Urban Science*, 3(2), 62. <https://doi.org/10.3390/urbansci3020062>
- Rybarczyk, G., & Wu, C. (2014). Examining the Impact of Urban Morphology on Bicycle Mode Choice. *Environment and Planning B: Planning and Design*, 41(2), 272–288. <https://doi.org/10.1068/b371133> [45]
- Saki, S. & Hagen, T. (2022). A Practical Guide to an Open-Source Map-Matching Approach for Big GPS Data. *SN COMPUT. SCI.* 3, 415. <https://doi.org/10.1007/s42979-022-01340-5>
- Sakshaug, L., Laureshyn, A., Svensson, A., & Hydén, C. (2010). Cyclists in roundabouts--different design solutions. *Accident; Analysis and Prevention*, 42(4), 1338–1351. <https://doi.org/10.1016/j.aap.2010.02.015>
- Saneinejad, S., Roorda, M. J., & Kennedy, C. (2012). Modelling the impact of weather conditions on active transportation travel behaviour. *Transportation Research Part D: Transport and Environment*, 17(2), 129–137. <https://doi.org/10.1016/j.trd.2011.09.005> [46]
- Santos, G., Maoh, H., Potoglou, D., & Brunn, T. von (2013). Factors influencing modal split of commuting journeys in medium-size European cities. *Journal of Transport Geography*, 30, 127–137. <https://doi.org/10.1016/j.jtrangeo.2013.04.005> [47]
- Scheiner, J., & Holz-Rau, C. (2007). Travel mode choice: affected by objective or subjective determinants? *Transportation*, 34(4), 487–511. <https://doi.org/10.1007/s11116-007-9112-1> [48]
- Schleinitz, K., Franke-Bartholdt, L., Petzoldt, T., Schwanitz, S., Gehlert, T., & Kühn, M. (2014). Pedelec-naturalistic cycling study. Gesamtverband der Deutschen Versicherungswirtschaft eV, Unfallforschung der Versicherer.
- Schüller, H., Niestegge, M., Hantschel, S., Kühn, B., Gerike, R., & Huber, S. (2023). Akzeptanz und Verkehrssicherheit des Radverkehrs im Mischverkehr auf Hauptverkehrsstraßen. https://bast.opus.hbz-nrw.de/opus45-bast/frontdoor/deliver/index/docId/2743/file/V366_BF_Final.pdf
- Seybold, M. P. (2017). Robust Map Matching for Heterogeneous Data via Dominance Decompositions. In N. Chawla & W. Wang (Eds.), *Proceedings of the 2017 SIAM International Conference on Data Mining* (pp. 813–821). Society for Industrial and Applied Mathematics. <https://doi.org/10.1137/1.9781611974973.91>
- Segadilha, A. B. P., & da Penha Sanches, S. (2014). Identification of factors that influence cyclists route choice. *Procedia-Social and Behavioral Sciences*, 160, 372-380.
- Sener, I. N., Eluru, N., & Bhat, C. R. (2009). An analysis of bicycle route choice preferences in Texas, US. *Transportation*, 36(5), 511–539. <https://doi.org/10.1007/s11116-009-9201-4>
- Shah, N. R., & Cherry, C. R. (2021). Different safety awareness and route choice between frequent and infrequent bicyclists: findings from revealed preference study using bikeshare data. *Transportation research record*, 2675(11), 269-279.

- Skov-Petersen, H., Barkow, B., Lundhede, T., & Jacobsen, J. B. (2018). How do cyclists make their way? - A GPS-based revealed preference study in Copenhagen. *International Journal of Geographical Information Science*, 32(7), 1469–1484.
<https://doi.org/10.1080/13658816.2018.1436713>
- Southworth, M. (2005). Designing the Walkable City. *Journal of Urban Planning and Development*, 131(4), 246–257. [https://doi.org/10.1061/\(ASCE\)0733-9488\(2005\)131:4\(246\)](https://doi.org/10.1061/(ASCE)0733-9488(2005)131:4(246)) [49]
- Spencer, P., Watts, R., Vivanco, L., & Flynn, B. (2013). The effect of environmental factors on bicycle commuters in Vermont: influences of a northern climate. *Journal of Transport Geography*, 31, 11–17. <https://doi.org/10.1016/J.JTRANGE0.2013.05.003> [50]
- Stinson, M. A., & Bhat, C. R. (2004) A Comparison of the Route Preferences of Experienced and Inexperienced Bicycle Commuters. Transportation Research Board, Washington, DC.
- Stinson, M. A., & Bhat, C. R. (2003). Commuter Bicyclist Route Choice: Analysis Using a Stated Preference Survey. *Transportation Research Record: Journal of the Transportation Research Board*, 1828(1), 107–115. <https://doi.org/10.3141/1828-13>
- Thomas, T., Jaarsma, R., & Tutert, B. (2008, November 7). Temporal variations of bicycle demand in the Netherlands: The influence of weather on cycling. TRB 2009 Annual Meeting [51]
- Tilahun, N. Y., Levinson, D. M., & Krizek, K. J. (2007). Trails, lanes, or traffic: Valuing bicycle facilities with an adaptive stated preference survey. *Transportation Research Part a: Policy and Practice*, 41(4), 287–301. <https://doi.org/10.1016/j.tra.2006.09.007>
- Ton, D., Duives, D. C., Cats, O., Hoogendoorn-Lanser, S., & Hoogendoorn, S. P. (2019). Cycling or walking? Determinants of mode choice in the Netherlands. *Transportation Research Part a: Policy and Practice*, 123, 7–23. <https://doi.org/10.1016/j.tra.2018.08.023> [52]
- Torrance, K., Sener, I.N., Machemehl, R., Bhat, C.R., Hallett, I., Eluru, N., Hlavacek, I., Karl, A. (2007). The effects of on-street parking on cyclist route choice and the operational behavior of cyclists and motorists. Draft report 0-5755-1, Center for Transportation Research, The University of Texas at Austin.
- Turner, S., & Lasley, P. (2013). Quality Counts for Pedestrians and Bicyclists. *Transportation Research Record: Journal of the Transportation Research Board*, 2339(1), 57–67.
<https://doi.org/10.3141/2339-07>
- Vedel, S. E., Jacobsen, J. B., & Skov-Petersen, H. (2017). Bicyclists' preferences for route characteristics and crowding in Copenhagen – A choice experiment study of commuters. *Transportation Research Part a: Policy and Practice*, 100, 53–64.
<https://doi.org/10.1016/j.tra.2017.04.006>
- Wardman, M., Tight, M., & Page, M. (2007). Factors influencing the propensity to cycle to work. *Transportation Research Part a: Policy and Practice*, 41(4), 339–350.
<https://doi.org/10.1016/j.tra.2006.09.011> [53]
- Wessel, J. (2020). Using weather forecasts to forecast whether bikes are used. *Transportation Research Part a: Policy and Practice*, 138, 537–559. <https://doi.org/10.1016/j.tra.2020.06.006> [54]
- Wibowo, S., & Olszewski, P. S. (2005). Modeling walking accessibility to public transport terminals: Case study of Singapore mass rapid transit. *Journal of the Eastern Asia Society for Transportation Studies*, 6, 147–156. [55]

- Wicki, M., Guidon, S., Becker, F., Axhausen, K., & Bernauer, T. (2019). How technology commitment affects mode choice for a self-driving shuttle service. *Research in Transportation Business & Management*, 32, 100458. <https://doi.org/10.1016/j.rtbm.2020.100458> [56]
- Willis, D. P., Manaugh, K., & El-Geneidy, A. (2015). Cycling Under Influence: Summarizing the Influence of Perceptions, Attitudes, Habits, and Social Environments on Cycling for Transportation. *International Journal of Sustainable Transportation*, 9(8), 565–579. <https://doi.org/10.1080/15568318.2013.827285> [57]
- Willumsen, L. (2021). Use of Big Data in Transport Modelling. *International Transport Forum Discussion Papers*(05).
- Winters, M., Davidson, G., Kao, D., & Teschke, K. (2011). Motivators and deterrents of bicycling: comparing influences on decisions to ride. *Transportation*, 38(1), 153–168. <https://doi.org/10.1007/s11116-010-9284-y> [59]
- Winters, M., Friesen, M. C., Koehoorn, M., & Teschke, K. (2007). Utilitarian bicycling: A multilevel analysis of climate and personal influences. *American Journal of Preventive Medicine*, 32(1), 52–58. <https://doi.org/10.1016/j.amepre.2006.08.027> [58]
- Witlox, F., & Tindemans, H. (2004). Evaluating bicycle-car transport mode competitiveness in an urban environment. An activity-based approach. *World Transport Policy & Practice*, 10(4), 32–42. [60]
- Wu, C., Yao, L., & Zhang, K. (2012). The red-light running behavior of electric bike riders and cyclists at urban intersections in China: An observational study. *Accident; Analysis and Prevention*, 49, 186–192. <https://doi.org/10.1016/j.aap.2011.06.001>
- Yan, H., Achkar, A., Mishra, A., & Naik, K. (2016). Automated failure detection in computer vision systems. *Journal of Computational Vision and Imaging Systems*, 2(1).
- Zhang, M. (2004). The role of land use in travel mode choice: Evidence from Boston and Hong Kong. *Journal of the American planning association*, 70(3), 344-360. [61]
- Zhao, F., Pereira, F. C., Ball, R., Kim, Y., Han, Y., Zegras, C., & Ben-Akiva, M. (2015). Exploratory Analysis of a Smartphone-Based Travel Survey in Singapore. *Transportation Research Record: Journal of the Transportation Research Board*, 2494(1), 45–56. <https://doi.org/10.3141/2494-06>