

**Johannes Weyer**

**Sebastian Hoffmann**

# **MIT DEM RAD ODER MIT DEM AUTO ZUR UNI?**

**EIN SOZIOLOGISCHES MODELL ZUR ERKLÄRUNG DES  
MOBILITÄTSVERHALTENS**

**Soziologisches Arbeitspapier Nr. 62/2023**

**Herausgeber**

**Prof. em. Dr. Hartmut Hirsch-Kreinsen**

**Prof. Dr. Cornelius Schubert**

**Prof. Dr. Johannes Weyer**



# Mit dem Rad oder mit dem Auto zur Uni?

Ein soziologisches Modell  
zur Erklärung des Mobilitätsverhaltens

---

**Johannes Weyer  
Sebastian Hoffmann**

**Soziologisches Arbeitspapier Nr. 62  
(August 2023)**

**TU Dortmund**

ISSN 1612-5355

## Herausgeber

Prof. em. Dr. Hartmut Hirsch-Kreinsen  
vormals Professur Wirtschafts- und Industriesoziologie  
Hartmut.Hirsch-Kreinsen@tu-dortmund.de

Prof. Dr. Cornelius Schubert  
Professur Wissenschafts- und Techniksoziologie  
cornelius.schubert@tu-dortmund.de

Prof. Dr. Johannes Weyer  
Seniorprofessur Nachhaltige Mobilität  
johannes.weyer@tu-dortmund.de

Technische Universität Dortmund  
Fakultät Sozialwissenschaften  
D-44221 Dortmund

### *Ansprechpartner*

Marion Nölle, e-Mail: marion.noelle@tu-dortmund.de

### *Verzeichnis bereits erschienener Arbeitspapiere und Download*

<https://eldorado.tu-dortmund.de/handle/2003/26532>

<https://namo.sowi.tu-dortmund.de/forschung/soziologische-arbeitspapiere>

Die Soziologischen Arbeitspapiere erscheinen in loser Folge. Mit ihnen werden Aufsätze (oft als Preprint), sowie Projektberichte und Vorträge publiziert. Die Arbeitspapiere sind daher nicht unbedingt endgültig abgeschlossene wissenschaftliche Beiträge. Sie unterliegen jedoch in jedem Fall einem internen Verfahren der Qualitätskontrolle.

Die Reihe hat das Ziel, der Fachöffentlichkeit soziologische Arbeiten aus der Fakultät Sozialwissenschaften der Technischen Universität Dortmund vorzustellen. Anregungen und kritische Kommentare sind nicht nur willkommen, sondern ausdrücklich erwünscht.

## Zusammenfassung

In der Verkehrs- und Mobilitätsforschung sind Konzepte verbreitet, die das alltägliche Mobilitätsverhalten auf individuelle Einstellungen oder auf die Wohn- und Lebenssituation der Menschen zurückführen und dabei Zusammenhänge zwischen Bündeln unterschiedlicher Variablen aufzeigen. Der eigentliche Entscheidungsprozess, also die alltägliche Wahl zwischen den Verkehrsmitteln Privat-Pkw, ÖV, Fahrrad usw., bleibt jedoch eine Black Box.

Der folgende Beitrag basiert auf der These, dass es erforderlich ist, den Prozess der subjektiv-rationalen Verkehrsmittelwahl zu entschlüsseln, um so zu einem vertieften Verständnis des Mobilitätsverhaltens der Menschen zu gelangen. Der Beitrag verwendet daher ein soziologisches Modell der Handlungswahl, das systematisch erklärt, wie die Entscheidungen zustande kommen, die dem manifesten Mobilitätsverhalten zugrunde liegen, das in Kapitel 3 anhand des Modal Split der UA-Ruhr-Angehörigen skizziert wird.

Mithilfe von Daten aus dem Projekt InnaMoRuhr wird gezeigt, dass ein um Kontextfaktoren erweitertes soziologisches Handlungsmodell eine große Prognosekraft hat, da sich eine hohe Übereinstimmung zwischen modelliertem und realen Mobilitätsverhalten erzielen lässt. Dies hilft zugleich, Ansatzpunkte für Veränderungen in Richtung Nachhaltigkeit zu identifizieren.

### *Handlungsmodell*

Kapitel 4 skizziert die Grundzüge des soziologischen Handlungsmodells, das aus der analytischen Soziologie stammt und mit zwei Faktoren arbeitet: der subjektiven Definition der Situation und den individuellen Einstellungen bzw. Präferenzen. Anhand eines fiktiven Beispiels wird in Kapitel 4.1 gezeigt, wie der Algorithmus des subjektiv erwarteten Nutzens (SEU) funktioniert und wie sich Veränderungen der Randbedingungen auf das Mobilitätsverhalten auswirken. Kapitel 4.2 wendet diesen Algorithmus auf die Daten aus dem Projekt InnaMoRuhr an – mit dem überraschenden Ergebnis, dass das Verkehrsmittel Rad am besten bewertet wird, knapp vor dem Auto und mit weitem Abstand vor dem ÖV.

### *Kluft zwischen Einstellung und Verhalten*

Das zentrale Kapitel 5 versucht das Rätsel aufzulösen, warum viele Menschen, die das Rad am besten bewerten, es für ihre Alltagsmobilität nicht nutzen, sondern den eigenen Pkw oder den ÖV nutzen. Denn gemäß einer explorativen Berechnung beträgt die Übereinstimmung zwischen Modell und Realität im Fall des Autos akzeptable 52,6 Prozent, im Fall des ÖV gute 74,7 Prozent, im Fall des Fahrrads aber nur 19,8 Prozent.

Mithilfe von Korrelationsrechnungen werden in Kapitel 5.1 die Faktoren identifiziert, die eine Nicht-Nutzung des präferierten Verkehrsmittels erklären, z.B. der mangelnde Besitz eines eigenen Pkws (-,386\*\*) oder ein gutes ÖV-Angebot

vor Ort (,241\*\*), die beide mit der Nicht-Nutzung des Autos signifikant korrelieren.

### *Kontextfaktoren*

Auf diese Weise werden neun Kontextfaktoren identifiziert, z. B. die Entfernung zur Universität oder Kinder im Haushalt. Diese werden in den Kapiteln 5.2 bis 5.4 zur Entwicklung dreier binär logistischer Regressionsmodelle (jeweils mit den Hauptverkehrsmitteln Auto, Rad und ÖV als abhängige Variable) genutzt, um den Einfluss dieser Faktoren genauer zu bestimmen und das oben beschriebene Delta zu schließen, das sich zwischen modelliertem und realem Verhalten insbesondere beim Fahrrad ergeben hat.

### *Auto-Modell*

Alle drei Modelle liefern zufriedenstellende bis gute Werte, wobei vor allem das Auto-Modell (Kap. 5.2) mit recht guten Werten hervorsticht. Neben dem Autobesitz und dem Alter, die die Wahrscheinlichkeit der Autonutzung erhöhen, sind es vor allem das ÖV-Angebot vor Ort und die mentale Verfügbarkeit von Alternativen, die diese Wahrscheinlichkeit senken.

Die Daten des Regressionsmodells werden zudem genutzt, um die Wahrscheinlichkeit der Autonutzung zweier fiktiver Personen zu modellieren und zudem zu zeigen, welche Verhaltensänderungen möglich sind, wenn man die Kontextfaktoren ÖV-Angebot und mentale Verfügbarkeit variiert – was im letzteren Fall beispielsweise bedeuten könnte, mehr und bessere Informationen über inter- bzw. multimodale Reiseoptionen, z. B. über eine Mobilitäts-App, zur Verfügung zu stellen. Die Effekte sind deutlich erkennbar.

### *ÖV-Modell*

Ein vergleichbares Verfahren wird im ÖV-Modell (Kap. 5.4) verwendet – mit ebenfalls zufriedenstellenden Resultaten. Auch hier wirken sich Autobesitz und Alter negativ, ÖV-Angebot und mentale Verfügbarkeit hingegen positiv auf die Wahrscheinlichkeit der ÖV-Nutzung aus. Hinzu kommt die Entfernung zu Universität, die leicht positiv wirkt. Auch das Gedankenexperiment, in dem die Kontextfaktoren variiert werden, um Verhaltensänderungen zu induzieren, zeigt ähnlich gute Resultate wie beim Auto-Modell.

### *Fahrrad-Modell*

Auch das Fahrrad-Modell (Kap. 5.3) liefert weitestgehend gute Resultate. Allerdings können die Kontextfaktoren ÖV-Angebot, mentale Verfügbarkeit usw., die in den beiden anderen Modellen signifikant sind, in diesem Modell nicht verwendet werden. Im Fall des Fahrrads sind vor allem das Alter, das Geschlecht, die Entfernung zur Universität und der Autobesitz ausschlaggebend – allesamt Faktoren, die invariant sind und nicht per Gedankenexperiment variiert werden können. Dies verweist darauf, dass sich aus den Befragungsdaten zu wenige Rad-spezifische Kontextfaktoren extrahieren ließen.

Die darauf basierende, leicht erweiterte Modellierung zweier fiktiver Personen liefert dennoch plausible Daten zu den Wahrscheinlichkeiten der Rad-Nutzung bzw. -Nichtnutzung und zu den Möglichkeiten, Impulse für Veränderungen des Mobilitätsverhaltens zu setzen.

#### *Das erweiterte Modell des Mobilitätsverhaltens*

Das abschließende Kapitel 6 resümiert den theoretischen Ertrag der vorliegenden Analysen und verweist auf die Notwendigkeit, das basale Handlungsmodell der analytischen Soziologie, das mit den beiden Faktoren Präferenzen und Situationsdefinition arbeitet, um ein drittes Element, die Kontextfaktoren, zu ergänzen. Mit dieser Erweiterung lässt sich eine hohe Übereinstimmung von modelliertem und realem Verhalten erzielen.

\*\*\*

Der vorliegende Text ist eine gründlich überarbeitete und erweiterte Version des Beitrags „Modellierung des Mobilitätsverhaltens. Beiträge der analytischen Soziologie zur Gestaltung der Mobilitätswende“, der im Jahr 2024 in dem von Heike Proff herausgegebenen Band „New Dimensions of Mobility Systems“ erscheinen wird. Dieser Band enthält die Beiträge zum 15. Wissenschaftsforum Mobilität 2023 in Duisburg.

Neu hinzugekommen sind die ausführliche Zusammenfassung, das Regressionsmodell für die ÖV-Nutzung (Kap. 5.4) sowie die ausführlichen Analysen zu den Wahrscheinlichkeiten der Verkehrsmittelnutzung in den Kapiteln 5.2 bis 5.4. Zudem wurde das Radmodell (Kap. 5.3) um Kontextfaktoren erweitert und auf diese Weise verbessert. Sämtliche Berechnungen wurden erneut durchgeführt und auf mögliche Fehlerquellen überprüft. Die Kapitel 3, 4 und 5.1 wurden redaktionell überarbeitet und sind weitgehend unverändert.

## Inhalt

<b>Zusammenfassung .....</b>	<b>4</b>
<b>1 Einleitung: Mobilitätsverhalten erklären.....</b>	<b>9</b>
<b>2 Das Projekt InnaMoRuhr .....</b>	<b>9</b>
<b>3 Mobilität der UA-Ruhr-Angehörigen .....</b>	<b>10</b>
<b>4 Soziologische Modellierung des Mobilitätsverhaltens.....</b>	<b>12</b>
4.1 Der SEU-Algorithmus anhand eines fiktiven Beispiels .....	13
4.2 SEU-Werte auf Basis von Befragungsdaten.....	14
<b>5 Abgleich von modelliertem und realem Verhalten.....</b>	<b>16</b>
5.1 Korrelationsrechnungen.....	17
5.2 Regressionsmodell für die Autonutzung .....	18
5.3 Regressionsmodell für die Fahrradnutzung.....	22
5.4 Regressionsmodell für die ÖV-Nutzung .....	25
<b>6 Fazit: Das erweiterte Modell des Mobilitätsverhaltens.....</b>	<b>28</b>
<b>7 Literatur .....</b>	<b>29</b>

Der vorliegende Text ist auch als Mobility Report 8/2023  
des Projekts InnaMoRuhr (innamo.ruhr) erschienen.



## 1 Einleitung: Mobilitätsverhalten erklären

Die sozialwissenschaftliche Mobilitätsforschung ist sich einig, dass das Mobilitätsverhalten der Menschen durch eine Reihe von Faktoren wie Wohnort, Einstellungen, Autobesitz etc. erklärt werden kann (siehe z.B. Scheiner/Holz-Rau 2007). Der Entscheidungsprozess selbst – z. B. bei der Wahl zwischen Auto, öffentlichem Verkehr (ÖV) und Fahrrad – sowie die Faktoren, die dabei eine Rolle spielen, sind hingegen oftmals eine Black Box. Zudem verschwindet in den statistischen Zusammenhängen die Individualität der handelnden Personen, die auf je eigene, manchmal eigenwillige Weise Entscheidungen treffen, die ihren subjektiven Bedürfnissen entsprechen und nicht immer perfekt rational sein müssen.

Es gibt nur vereinzelt Versuche, das mobilitätsbezogene Handeln der Menschen auf Grundlage einer allgemeinen Handlungs- bzw. Entscheidungstheorie zu modellieren (Bamberg 2012, Hunecke 2015) und sich auf diese Weise der Frage anzunähern, ob und wie eine Veränderung des Mobilitätsverhaltens möglich ist.

Der folgende Beitrag greift auf ein Handlungsmodell der analytischen Soziologie zurück und nutzt Daten aus dem Projekt InnaMoRuhr für die Modellierung von Handlungswahlen. Der Beitrag zeigt, dass ein erweitertes soziologisches Handlungsmodell eine hohe Prognosekraft hat, wenn es neben zwei zentralen subjektiven Faktoren (Präferenzen, Situationsdefinition) auch den sozialen Kontext mit einbezieht. Auf diese Weise lässt sich eine hohe Übereinstimmung zwischen modelliertem und realen Mobilitätsverhalten erzielen. Damit ist es zugleich möglich, die „Stellschrauben“ zu identifizieren, an denen man drehen könnte, um eine Veränderung des Mobilitätsverhaltens anzustoßen.

## 2 Das Projekt InnaMoRuhr

Von Mai 2020 bis Juli 2023 hat das Ministerium für Umwelt, Naturschutz und Verkehr (MUNV) des Landes NRW das Projekt InnaMoRuhr („Konzept einer integrierten, nachhaltigen Mobilität für die Universitätsallianz Ruhr“) gefördert. Er wurde von sieben Professor:innen an sechs Instituten der vier Standorte der drei UA-Ruhr-Universitäten (Bochum, Dortmund, Duisburg-Essen) getragen. Das Projekt umfasste neun Arbeitspakete, die in drei Projektphasen bearbeitet wurden (vgl. Abbildung 1):

- Als erster Schritt fand im Frühjahr 2021 eine großangelegte *Befragung* aller UA-Ruhr-Angehörigen statt, in der diese Auskunft nicht nur über ihr aktuelles Mobilitätsverhalten, sondern auch über ihre Mobilitätsbedarfe und bislang nicht erfüllten Mobilitätswünsche geben sollten (vgl. Weyer 2022)
- In den *Szenario-Workshops* der zweiten Projektphase im Herbst und Winter 2021/22 haben ausgewählte Teilnehmer:innen aller drei Universitäten und aller Funktionsgruppen die Ergebnisse der Befragung diskutiert, bewertet

und gemeinsam Ideen für eine nachhaltige und zugleich alltagstaugliche Mobilität entwickelt. Dabei wurde das Team von InnaMoRuhr vom Beratungshaus Foresight Solutions unterstützt.

- Parallel dazu wurde der Verkehrssimulator der TU Dortmund so weiterentwickelt, dass er die Mobilität der UA-Ruhr-Angehörigen abbildet; auf Basis von Befragungsdaten und Szenarien werden unterschiedliche Konzepte nachhaltiger Mobilität modelliert, um mit Hilfe von Simulationsexperimenten zu überprüfen, ob die erwarteten Effekte eintreten.

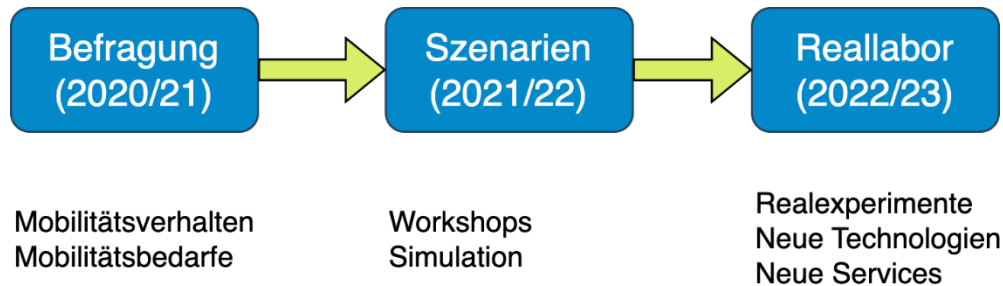


Abbildung 1: Die drei Phasen des Projekts InnaMoRuhr

- Schließlich wurden im Herbst 2022 im Rahmen eines Reallabors drei dezentrale *Realexperimente* durchgeführt, in denen einer großen Zahl von UA-Ruhr-Angehörigen die Möglichkeit geboten wurde, neue Technologien, aber auch neue Mobilitäts-Services zu erproben.

Das übergreifende Ziel des Projekts InnaMoRuhr war herauszufinden, (a) ob eine Änderung des Mobilitätsverhaltens der UA-Ruhr-Angehörigen in Richtung Nachhaltigkeit möglich ist, (b) welche Maßnahmen am ehesten Erfolg versprechen und (c) wie die Mitwirkung der Studierenden und Beschäftigten gesichert und ausgestaltet werden kann.

### 3 Mobilität der UA-Ruhr-Angehörigen

Innerhalb des Projekts InnaMoRuhr wurden im Jahr 2021, also während des Corona-bedingten Lockdowns, sämtliche Studierende und Beschäftigte der drei UA-Ruhr-Universitäten in Bochum, Dortmund, Duisburg-Essen zu ihrem Mobilitätsverhalten befragt; die Befragung ergab insgesamt 10.782 verwertbare Datensätze.<sup>1</sup> Tabelle 1 zeigt den – rückwirkend erfragten – Modal Split des Jahres 2019, also vor Ausbruch der Corona-Pandemie, der als Referenz verwendet wird, um die Veränderungen während des Lockdowns abzubilden; zudem wurden die Befragten gebeten, ihre Wunschvorstellungen in Bezug auf Mobilität der Zukunft in Form einer detaillierten Wegekette an einem fiktiven Arbeitstag in der Zukunft darzustellen (Weyer 2022).

<sup>1</sup> Das Projekt „Konzept einer integrierten, nachhaltigen Mobilität für die Universitäts-Allianz Ruhr“ (InnaMoRuhr) wurde vom Ministerium für Umwelt, Naturschutz und Verkehr (MUNV) des Landes NRW im Zeitraum von 2020 bis 2023 unter dem Förderkennzeichen 2020 18111 gefördert.

Die erste Spalte „vor Corona“ zeigt eine Verteilung, die vom bundes- bzw. landesweiten Modal Split deutlich abweicht: Knapp die Hälfte der Universitätsangehörigen (49,8 %) nutzte den ÖV oder Sharing-Angebote, ein knappes Drittel (31,1 %) den eigenen Pkw und nur 11,8 Prozent das Rad als Hauptverkehrsmittel für den Weg zur Universität.<sup>2</sup>

Verkehrsmittel	vor Corona	im Lockdown	Wunsch	Summen Wunsch	Veränderung
Pkw, Motorrad (ICE)*	30,2 %	37,8 %	11,0 %	28,2 %	-2,9 PP
Pkw (BEV, FCEV, HEV)*	0,9 %	1,4 %	17,2 %		
Fahrrad	10,6 %	15,5 %	19,9 %	27,9 %	+16,1 PP
E-Bike, E-Scooter	1,2 %	2,0 %	8,0 %		
Zu Fuß	7,0 %	23,5 %	7,4 %	7,4 %	+0,4 PP
ÖV	49,1 %	18,6 %	33,5 %	36,1 %	-13,7 PP
Sharing, MFG*	0,7 %	0,9 %	2,6 %		
Sonstiges	0,3 %	0,3 %	0,3 %	0,3 %	0,0 PP
	N= 7.483	6.478	7.766		
* ICE – Internal Combustion Engine; BEV – Battery Electric Vehicle; FCEV – Fuel Cell Electric Vehicle; HEV – Hybrid Electric Vehicle; MFG – Mitfahrgelegenheit					

Tabelle 1: Model Split der UA-Ruhr-Angehörigen auf Basis des Hauptverkehrsmittels (Quelle: Weyer 2022)

Während des Lockdowns (2. Spalte) ergab sich eine Verlagerung weg vom ÖV hin zu individuellen Formen der Mobilität (Pkw: 39,2 %, Rad: 15,5 %, Zu Fuß: 23,5 %) wie auch zu neuen Mustern eines partiellen oder vollständigen Arbeitens im Homeoffice. Fragt man die Universitätsangehörigen, wie sie sich ihre Mobilität der Zukunft vorstellen (Spalte „Wunsch“ in Tabelle 1), so hat der Pkw einen fast so großen Stellenwert wie in der Vergangenheit und büßt nur 2,9 Prozentpunkte ein. Der ÖV kann zwar wieder Anteile zurückgewinnen, bleibt aber mit einem Minus von 13,7 Prozentpunkten deutlicher Verlierer. Den höchsten Zuwachs verzeichnet das Fahrrad, das 16,1 Prozentpunkte hinzugewinnt und offenbar in den Vorstellungen der Menschen, wie sie in Zukunft mobil sein wollen, eine wichtige Rolle spielt.

Resümiert man die in Tabelle 1 dargestellten Werte, so spiegelt sich darin der Wunsch nach individueller (Pkw/Rad), nachhaltiger (Elektroauto, E-Bike) und flexibler Mobilität, die nicht den starren Schemata des klassischen ÖV unterliegt.

<sup>2</sup> Bei intermodalen Wegeketten (z. B. Rad/Bahn/zu Fuß) wurde das Verkehrsmittel gezählt, das für die längste Teilstrecke verwendet wurde.

## 4 Soziologische Modellierung des Mobilitätsverhaltens

Versucht man, dieses manifeste Mobilitätsverhalten zu erklären und Ansatzpunkte für Veränderungen zu identifizieren, so bietet sich ein Modell der analytischen Soziologie an. Der Begriff „analytische Soziologie“ wurde von einer Gruppe von Forschern geprägt, deren Ziel es ist, das Alltagshandeln der Menschen systematisch als Ergebnis eines subjektiv rationalen Entscheidungsprozesses zu erklären, der sich durch einen mathematischen Algorithmus darstellen lässt, welcher für alle Akteure gleichermaßen gilt (Esser 1993, Coleman 1995).

Die Entscheidungen der Menschen werden als Resultat einer Wahl zwischen unterschiedlichen Handlungsalternativen beschrieben, wobei angenommen wird, dass in der Regel die Alternative gewählt wird, die – aus subjektiver Sicht – den höchsten Nutzen hat bzw. – weniger ökonomisch formuliert – die eigenen Bedürfnisse am besten befriedigt. Denn Nutzen muss nicht ausschließlich monetärer Art sein; es können auch andere Faktoren wie beispielsweise die Anerkennung durch nahestehende Personen eine Rolle spielen – etwa wenn das eigene Verhalten den in der Gruppe geltenden Normen entspricht (z.B. umweltfreundlich zu reisen).

Anders als in konventionellen, ökonomisch kalkulierenden Rational-Choice-Konzepten basiert diese Nutzenkalkulation auf zwei Faktoren: den *individuellen* Einstellungen bzw. Präferenzen (Nr. 1 in Abbildung 2) – was ist mir wichtiger: schnell oder umweltfreundlich zu reisen – und der *subjektiven* Definition der Situation (Nr. 2), was im Kontext von Mobilität insbesondere die Wahrnehmung der Wahrscheinlichkeit ist, mit einer der verfügbaren Handlungsalternativen (z. B. Auto oder Rad) das gewünschte Ziel zu erreichen (z. B. schnell oder umweltfreundlich zur Universität reisen).<sup>3</sup>

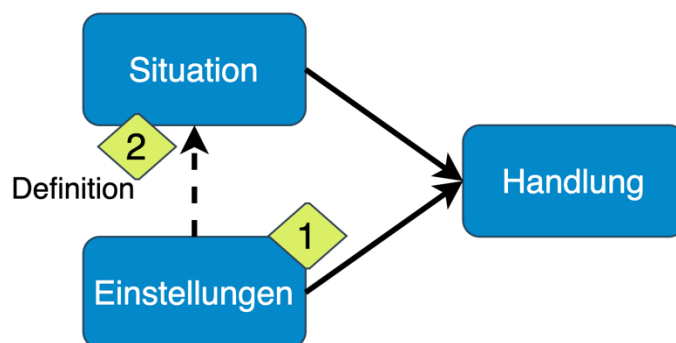


Abbildung 2: Modell des Mobilitätsverhaltens (eigene Darstellung in Anlehnung an Esser 2000)

Der Nutzen (SEU – „subjective expected utility“) verfügbarer Handlungsoptionen A („action“) errechnet sich aus dem Produkt der Ziele O („objectives“), die durch individuelle Präferenzen U („utility“) gewichtet werden, und den subjektiv

<sup>3</sup> Die folgenden Ausführungen werden zeigen, dass dieses Modell um eine dritte Komponente, die Kontextfaktoren, ergänzt werden muss.

wahrgenommenen Wahrscheinlichkeiten  $p$  („probabilities“), diese Ziele mittels der verfügbaren Handlungsoptionen zu erreichen (vgl. Abbildung 3).

$$SEU(A_i) = \sum_{j=1}^n p_{ij} * U(O_j)$$

Abbildung 3: Subjektive Nutzenkalkulation (Esser 2000: 250)

Diesem Modell zufolge sind die Handlungswahlen der Menschen individuell und von subjektiven Vorstellungen geprägt und lassen sich dennoch mithilfe eines allgemein gültigen Algorithmus modellieren, der in der Lage ist zu erklären, warum zwei Akteure in der gleichen Situation – mit dem Rad oder dem Auto zur Universität – unterschiedliche Entscheidungen treffen.

#### 4.1 Der SEU-Algorithmus anhand eines fiktiven Beispiels

Tabelle 2 veranschaulicht dieses Verfahren anhand einer fiktiven Person A mit folgenden Präferenzen: Sie reist gerne schnell (U-Wert = 10 auf einer Skala von 1 bis 10), kümmert sich aber wenig um die Kosten (U-Wert = 4). Die wahrgenommenen Wahrscheinlichkeiten der Zielerreichung (auf einer Skala von 0 bis 100 Prozent) sind ebenfalls fiktiv, liegen aber dicht an den Werten, die in der Befragung des Projekts InnaMoRuhr erhoben wurden. Das Auto wird als schnell (80 %), aber wenig kostengünstig (30 %), das Fahrrad umgekehrt als langsam (30 %) und preiswert (80 %) wahrgenommen.

Person A	Schnell Reisen	Günstig Reisen	Subjektiver Nutzen
Präferenzen (U)	10	4	
Auto (p)	80 %	30 %	<b>9,2</b>
Fahrrad (p)	30 %	80 %	6,2

Tabelle 2: Verkehrsmittelwahl einer fiktiven Person (U-Werte von 1 bis 10, p-Werte von 0 bis 100 %)

Gemäß der Berechnung mithilfe des SEU-Algorithmus entscheidet sich Person A für das Auto (subjektiv wahrgenommener Nutzen = 9,2) und gegen das Fahrrad (Nutzen = 6,2). Für eine Verhaltensänderung bedürfte es entweder einer Veränderung der Präferenzen oder der Wahrscheinlichkeiten. Da ein Wertewandel sich eher langfristig vollzieht, beschreibt Tabelle 3 ein fiktives Szenario, das schneller realisierbar wäre und aus zwei Komponenten besteht: der Einführung eines Tempolimits, das den p-Wert für die wahrgenommene Geschwindigkeit des Autos um 20 Prozentpunkte auf 60 Prozent senkt, und einer Verbesserung der Radinfrastruktur (+20 PP).

Person A	Schnell Reisen	Günstig Reisen	Subjektiver Nutzen	Maßnahmen
Präferenzen (U)	10	4		
Auto (p)	60 % (-20 PP)	30 %	7,2	Tempolimit
Fahrrad (p)	50 % (+20 PP)	80 %	<b>8,2</b>	Radinfrastruktur

Tabelle 3: Verkehrsmittelwahl einer fiktiven Person bei geänderten Randbedingungen

Der Effekt dieser beiden Maßnahmen ist in Tabelle 3 erkennbar: Person A wechselt vom Auto zum Fahrrad. Eine derartige Modellierung der Handlungswahl hilft also nicht nur, das individuelle Alltagshandeln zu verstehen und zu erklären, sondern auch die „Stellschrauben“ zu identifizieren, an denen man drehen müsste, um Verhaltensänderungen zu erzielen.

#### 4.2 SEU-Werte auf Basis von Befragungsdaten

Die folgenden Berechnungen wenden dieses Verfahren auf die Daten an, die im Projekt InnaMoRuhr erhoben wurden. Die Befragten wurden gebeten, Angaben zu ihren persönlichen Präferenzen in sechs Dimensionen zu machen. Mit Hilfe eines Schiebereglers (von 1 bis 10) konnten sie angeben, wie wichtig es ihnen ist, schnell, umweltfreundlich, komfortabel, kostengünstig, zuverlässig und sicher zu reisen. Dabei war die Summe aller sechs Werte auf mindestens 30 und höchstens 40 fixiert, um Zielkonflikte zu provozieren und Abwägungen zu erzwingen.

Dimension	Präferenzen (U)			Wahrscheinlichkeiten (p)		
	MIN	MW	MAX	Auto	ÖV	Rad
schnell	6,2	7,8	8,8	80 %	38 %	36 %
kostengünstig	3,2	6,3	7,2	32 %	54 %	87 %
umweltfreundlich	3,8	5,9	8,0	23 %	74 %	94 %
komfortabel	2,5	4,7	7,5	83 %	42 %	42 %
sicher	3,5	6,2	7,9	68 %	65 %	44 %
zuverlässig	6,2	8,1	8,9	81 %	35 %	81 %

Tabelle 4: Präferenzen in sechs Dimensionen und durchschnittliche, verkehrsmittelspezifische Wahrscheinlichkeiten (N=10.782, Quelle: Weyer 2022)

Wie Tabelle 4 zeigt, wurde die Zuverlässigkeit mit 8,1 Punkten im Durchschnitt (Spalte MW) am höchsten bewertet und der Komfort mit 4,7 Punkten am geringsten. Die – teils erheblichen – Abweichungen nach oben und unten sind in den Spalten MIN und MAX ablesbar. Diese wurden genutzt, um fünf Akteurguppen mit jeweils typischen Einstellungen zu unterscheiden: Risikoaverse Umweltbewusste, Indifferente, Pragmatiker, Komfortorientierte und Umwelt- und Kostenbewusste (vgl. dazu detailliert Weyer 2022).

Die Befragten wurden zudem gebeten anzugeben, für wie wahrscheinlich sie es halten, mit den drei Verkehrsmitteln Auto, ÖV und Rad die genannten Ziele zu erreichen (von 0 bis 100 %).<sup>4</sup> Die Werte zu den Wahrscheinlichkeiten (p) in Tabelle 4 sind nicht sonderlich überraschend, helfen aber, den SEU-Algorithmus auf Basis der Wahrnehmungen der Befragten zu kalibrieren (vgl. Abbildung 3). Die Abweichungen nach oben und unten (in der Tabelle nicht dokumentiert) sind zudem deutlich geringer als bei den U-Werten. Es herrscht also offenbar ein gewisser Konsens, dass das Auto schnell und das Rad umweltfreundlich ist. Dies ließ sich größtenteils mit einer einfaktoriellen Varianzanalyse (ANOVA) bestätigen (siehe Exkurs 1).

#### Exkurs 1: ANOVA

Zwar unterscheiden sich die 18 wahrgenommenen Wahrscheinlichkeiten der Zielerreichung zwischen den fünf Akteurstypen signifikant voneinander (höchstes  $p < ,014$ ), allerdings handelt es sich nur in einem Fall (wahrgenommener Komfort des ÖV) um einen mittelstarken Effekt ( $\omega^2 > ,06$ ; vgl. Field 2013: 738) – die anderen Bewertungen unterscheiden sich deutlich geringfügiger (größtenteils  $\omega^2$  von ca. ,03).

Die Standardabweichungen aller wahrgenommenen Wahrscheinlichkeiten betragen im Schnitt 22 Prozentpunkte, d. h., dass zum Beispiel die wahrgenommene Wahrscheinlichkeit, mit dem ÖV schnell zur Universität zu kommen, um 22 Prozentpunkte von der durchschnittlichen Bewertung von 38 Prozent abweicht (vgl. Tabelle 4).

Mithilfe des SEU-Algorithmus (vgl. Abbildung 3) und der Befragungsdaten wurden die SEU-Werte für alle drei Verkehrsmittel berechnet und dann für jeden Datensatz das Verkehrsmittel (VM) mit dem höchsten individuellen Nutzen (SEU-Wert) bestimmt (vgl. Tabelle 5).

Verkehrsmittel	Anzahl	Anteil	MW SEU (gesamt)	MW SEU (nur best-bewertetes VM)
Auto	2.660	42,6%	24,3	27,8
ÖV	551	8,8%	19,5	27,2
Rad	3.037	48,6%	25,0	28,2

Tabelle 5: Bestbewertetes Verkehrsmittel auf Basis des SEU-Algorithmus (SEU-Werte von 0 bis 40)

Demzufolge bewertet fast die Hälfte der Befragten (48,6 %) das Rad am höchsten, gefolgt vom Auto (42,6 %), während der ÖV weit abgeschlagen bei lediglich 8,8 Prozent der Menschen den ersten Platz einnimmt. Dies zeigt sich auch an den SEU-Werten (vorletzte Spalte), bei denen das Rad mit einem Mittelwert von 25,0 dicht vor dem Auto (24,3) und weit vor dem ÖV liegt (19,5). Selbst wenn man nur die Werte derjenigen betrachtet, die das jeweilige Verkehrsmittel am besten bewerten (letzte Spalte), wird deutlich, dass der ÖV selbst unter seinen

<sup>4</sup> Der Fußverkehr wurde nicht berücksichtigt, um den Umfang des Fragebogens zu begrenzen, aber auch, weil es merkwürdig gewesen wäre, nach dem Komfort oder der Zuverlässigkeit des Fußverkehrs zu fragen.



Anhänger:innen etwas schlechter abschneidet (MW = 27,2) als die anderen beiden Verkehrsmittel in den Gruppen, die von ihnen jeweils präferiert werden (MW = 28,2 bzw. 27,8).

## 5 Abgleich von modelliertem und realem Verhalten

Wie Abbildung 4 belegt, ist das basale soziologische Modell des Mobilitätsverhaltens mithilfe des SEU-Algorithmus in der Lage, das reale Mobilitätsverhalten einigermaßen treffsicher vorherzusagen – von einigen Abweichungen abgesehen: 52,6 Prozent derjenigen, die das Auto am höchsten bewerten (Max\_Auto), nutzen es tatsächlich, aber 38,9 Prozent fahren mit dem ÖV zur Universität. Im Fall des ÖV (Max\_ÖV) sind es fast drei Viertel (73,7 %) der (wenigen) Menschen, die ihn am höchsten bewerten und tatsächlich auch nutzen. Beides sind Werte, mit denen man im Prinzip zufrieden sein könnte. Beim Fahrrad sieht es jedoch deutlich schlechter aus: Nur knapp 20 Prozent, der (zahlreichen) Personen, die das Rad am höchsten bewerten (Max\_Rad), nutzen es tatsächlich; der überwiegende Teil (56,0 %) fährt hingegen mit dem ÖV zur Universität und ein kleiner Teil (15,1 %) mit dem Rad.

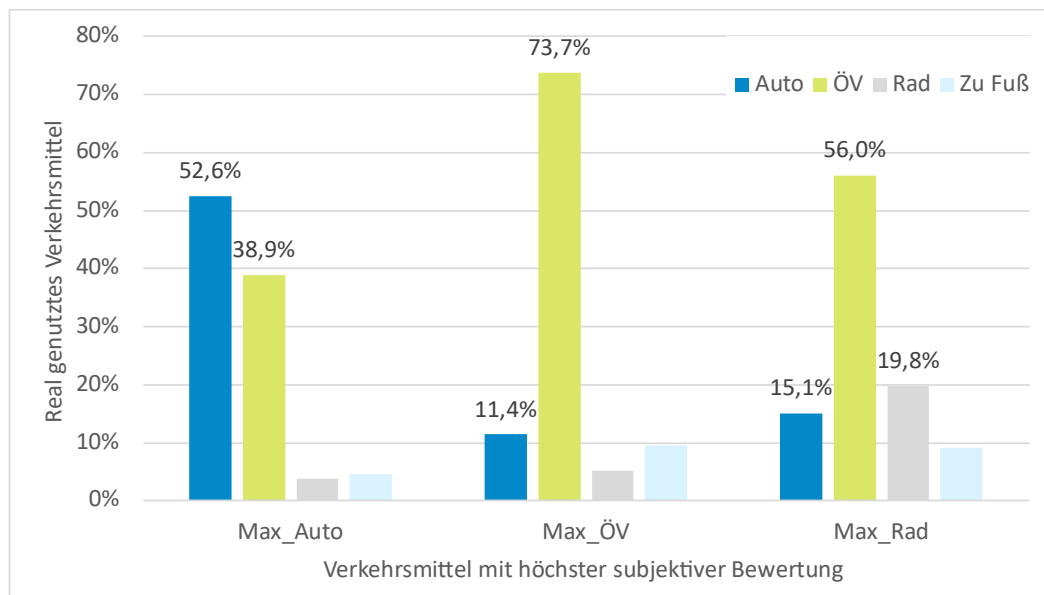


Abbildung 4: Reale Nutzung und bestbewertetes Verkehrsmittel (eigene Darstellung)

Diese Diskrepanzen zwischen dem realen und dem prognostizierten Verhalten, das mithilfe des SEU-Modells berechnet wird, lassen sich deutlich verringern, wenn man einen bislang nicht berücksichtigten Faktor in das Modell einbezieht: den sozialen Kontext, in dem sich die betreffende Person befindet. Denn es macht einen Unterschied, ob man in der Stadt oder auf dem Land wohnt, ob man Kinder hat, ob man einen Pkw besitzt, ob es ein gut ausgebautes Radwegenetz gibt oder ob der Wohnort gut an den ÖV angebunden ist oder nicht. Ergänzt man das Modell des Mobilitätsverhaltens mit seinen beiden subjektiven Faktoren um einen weiteren – eher objektiven – Faktor, den sozialen Kontext, nimmt die Prognosequalität erheblich zu.



Diese Einbeziehung der Kontextfaktoren geschieht in zwei Schritten: Zunächst werden mithilfe von Korrelationsrechnungen die Gründe identifiziert, die eine Person, die beispielsweise das Fahrrad präferiert, davon abhalten, es tatsächlich zu nutzen. In einem zweiten Schritt werden diese Kontextfaktoren in mehrere Regressionsmodelle eingespeist, um ihre Auswirkung auf das Mobilitätsverhalten zu überprüfen. Alle Berechnungen hierfür wurden mit der Statistiksoftware SPSS vorgenommen.

## 5.1 Korrelationsrechnungen

Die Ergebnisse der Korrelationsrechnungen finden sich in Abbildung 5. Auf der x-Achse sind links die negativen und rechts die positiven Korrelationskoeffizienten nach Spearman ( $r$ ) abgetragen – und zwar der besseren Übersicht halber nur die signifikanten Werte ( $p < ,001$ ). Es wurde jeweils die Nichtnutzung eines Verkehrsmittels trotz bester SEU-Bewertung (Auto, ÖV, Rad; 2 Stufen; 1 = Nichtnutzung) mit neun Kontextfaktoren korreliert:

- dem Geschlecht (2 Stufen; 0 = männlich, 1 = weiblich),
- dem Alter (7 Stufen; 7 = 60 Jahre und älter),
- dem Vorhandensein von Kindern unter 12 Jahren im Haushalt (2 Stufen; 1 = Kinder im Haushalt),
- der mentalen Verfügbarkeit von Alternativen (11 Stufen; 0 = keine Alternative mental verfügbar),
- der Bewertung des lokalen ÖV-Angebots (5 Stufen; 5 = sehr gute Bewertung),
- der Kombination von Verkehrsmitteln (8 Stufen; 1 = nur Auto),
- dem Besitz eines Autos (2 Stufen; 0 = nicht vorhanden, 1 = vorhanden),
- der Entfernung zur Universität (metrisch in Kilometern) und
- der Bevölkerungsdichte des Wohnorts (metrisch in Einwohnern pro Quadratkilometer).

Die *Nichtnutzung des Rads* trotz bester Bewertung (graue Balken) erklärt sich vor allem aus der größeren Entfernung zur Universität ( $,205$ ,  $N = 2.515$ ) und dem Autobesitz ( $,093$ ,  $N = 2.940$ ). Auch Frauen nutzen das Rad seltener ( $,108$ ,  $N = 2.986$ ). Wer das Rad nicht nutzt, ist zudem eher jünger ( $-,179$ ,  $N = 3.029$ ), hat eher keine Kinder ( $-,086$ ,  $N = 1.066$ ), bewertet das ÖV-Angebot etwas schlechter ( $-,066$ ,  $N = 2.997$ ), kombiniert seltener unterschiedliche Verkehrsmittel ( $-,117$ ,  $N = 1.976$ ) und wohnt in Gegenden mit geringer Bevölkerungsdichte ( $-,090$ ,  $N = 2.784$ ), also auf dem Land.

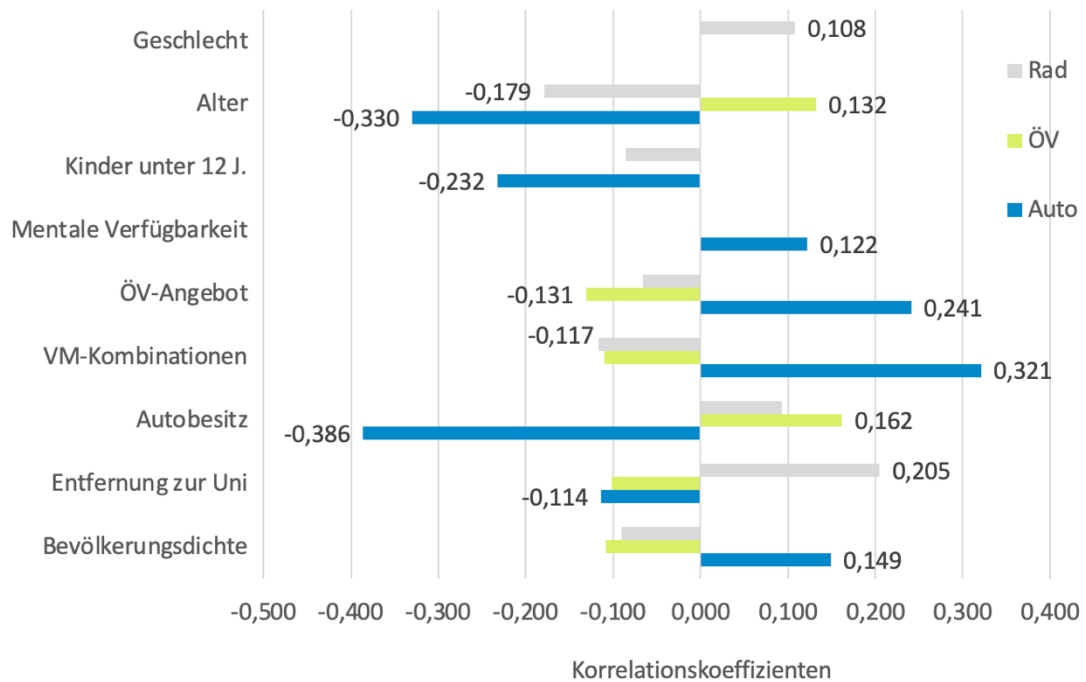


Abbildung 5: Gründe für die Nichtnutzung des bestbewerteten Verkehrsmittels; grau = Nichtnutzung des Rads, blau = Nichtnutzung des Autos, grün = Nichtnutzung des ÖVs; Balken nicht beschriftet = geringe Korrelation ( $< ,100$ ) oder nur schwach signifikant ( $< ,05$ ); fehlende Balken = kein Effekt (eigene Darstellung).

Die *Nichtnutzung des ÖVs* trotz bester Bewertung (grüne Balken) erklärt sich vor allem aus einem höheren Alter ( $,132$ ,  $N = 545$ ) und dem Autobesitz ( $,162$ ,  $N = 495$ ), aber auch aus einem unzureichenden ÖV-Angebot am Wohnort ( $-,131$ ,  $N = 544$ ). Zusätzlich spielen die geringe Entfernung zur Universität ( $-,102$ ,  $N = 460$ ) sowie eine geringe Bevölkerungsdichte ( $,108$ ,  $N = 506$ ) eine Rolle. Wer (im ersten Fall) in der Nähe der Universität wohnt, geht zu Fuß oder fährt mit dem Rad; wer (im zweiten Fall) auf dem Land wohnt, nimmt das Auto.

Die *Nichtnutzung des Autos* trotz bester Bewertung (blaue Balken) erklärt sich vorrangig aus dem mangelnden Autobesitz ( $-,386$ ,  $N = 2.591$ ), der geringen Entfernung zur Universität ( $-,114$ ,  $N = 2.057$ ), dem niedrigeren Alter ( $-,330$ ,  $N = 2.642$ ) sowie dem Nichtvorhandensein von Kindern im Haushalt ( $-,232$ ,  $N = 916$ ). Dabei handelt es sich vermutlich überwiegend um Studierende, die mit dem Semesterticket unterwegs sind, aber möglicherweise spätestens mit dem ersten Kind ein eigenes Auto anschaffen werden. Zudem sind ein gutes ÖV-Angebot ( $,241$ ,  $N = 2.603$ ), die Gewohnheit, unterschiedliche Verkehrsmittel zu nutzen ( $,323$ ,  $N = 1.353$ ), und schließlich die Befassung mit Alternativen ( $,122$ ,  $N = 1.886$ ) Faktoren, die die Nichtnutzung des Autos erklären.

## 5.2 Regressionsmodell für die Autonutzung

Die genannten neun Faktoren (vgl. Abbildung 5) wurden in drei binär logistische Regressionsmodelle übernommen und systematisch in verschiedenen Kombinationen getestet, um die Kontextfaktoren zu identifizieren, die die Nutzung des

Autos, des Fahrrads und des ÖV erklären. Ziel war, das Delta zu verringern, das sich zwischen den SEU-Berechnungen auf Grundlage des basalen Modells und dem realen Mobilitätsverhalten aufgetan hat.

Alle drei Regressionsmodelle wurden stufenweise entwickelt und getestet. Im Fall des Autos reduzierten sich die Kontextfaktoren schließlich auf vier signifikante Faktoren (Autobesitz, Alter, ÖV-Angebot und mentale Verfügbarkeit), die bereits bei den Korrelationsrechnungen Werte von größer ,200 aufwiesen. Sämtliche in das Modell aufgenommene Variablen waren signifikant ( $p < ,001$ ) und hatten damit Einfluss auf prädiktive Leistung des Modells (vgl. Tabelle 6). Die Prüfung von Voraussetzungen und Ausreißern wird in Exkurs 2 beschrieben.

Bereits Modell 1 unterstützt die Annahme, dass die ausschließliche Betrachtung der subjektiven Nutzenbewertung zu einer akzeptablen Varianzaufklärung (Nagelkerkes  $R^2 = 0,214$ ) sowie einer korrekten Gesamtklassifizierung von 71,4 Prozent aller Personen beiträgt. In den vier folgenden Modellen steigt der Klassifizierungswert sukzessive auf 79,2 Prozent;<sup>5</sup> auch die Güte des Modells verbessert sich durch die Hinzufügung weiterer Faktoren: Modell 5 weist schließlich bei den Gütekriterien die besten Werte und – den Einschätzungen von Backhaus et al. (2016: 317 f., 340) und Field (2013: 1175) folgend – eine gute Varianzaufklärung auf (Nagelkerkes  $R^2: ,487$ ,  $\text{Chi}^2: 1.895,993$ ;  $\text{df}: 5$ ; insgesamt richtig klassifiziert: 79,2 %). Neben der korrekten Gesamtklassifizierung liefert auch der sogenannte AUC-Wert („Area under Curve“ der „Receiver Operating Characteristics Curve“) einen Indikator für die Prognosegüte des Modells (vgl. Backhaus et al. 2016: 201): Dieser beträgt 0,867 für Modell 5 und kann gemäß Backhaus et al. (ebd.) als „exzellent“ eingestuft werden.

### Exkurs 2: Prüfung von Voraussetzungen und Ausreißern (Auto-Modell)

Gemäß Box-Tidvell-Verfahren ist die Voraussetzung der Linearität für alle metrischen Variablen außer der Distanz zur Universität erfüllt.

Die Korrelationen zwischen den einzelnen Faktoren waren gering (höchstes  $r = ,20$ ), die „Variance Inflation Factors“ (VIF) waren unter 10 bzw. im Schnitt nicht wesentlich größer als 1 (höchster VIF = 1,11) und die Toleranzwerte waren über dem kritischen Schwellenwert von 0,2 (kleinster Toleranzwert = 0,88), weswegen außerdem davon ausgegangen werden kann, dass keine Multikolarität vorliegt (vgl. Backhaus et al. 2016: 108, Field 2013: 534).

In allen Modellen wurden Ausreißer basierend auf den Empfehlungen von Field (2013: 1151) identifiziert und von der weiteren Auswertung ausgeschlossen. Ausgeschlossen wurden Fälle mit auffällig hohen studentisierten Residuen ( $\geq \pm 3$ ) sowie übermäßig hohem Einfluss auf das Modell (Cooke-Distanz  $> 1$  oder Hebelwert  $> 0,2$ ); vgl. (Field 2013: 1153, 1511) und (Huber 1981). Es waren 6 (Modell 5), 8 (Modelle 4 und 3) bzw. 11 (Modell 2) Fälle betroffen.

<sup>5</sup> Der Mittelwert von 79,2 Prozent ergibt sich aus der richtigen Klassifizierung der Nicht-Autonutzung (86,1 %) und der Autonutzung (64,5 %).

Variable	Skalierung	Modell 0	Modell 1	Modell 2	Modell 3	Modell 4	Modell 5
Konstante		-0,757	-1,741	-6,330	-7,216	-6,099	-5,516
Auto bestbewertet	1 = ja 0 = nein		1,845 (6,328)	1,637 (5,138)	1,722 (5,595)	1,629 (5,098)	1,616 (5,032)
Autobesitz	1 = ja 0 = nein			5,145 (171,534)	4,536 (93,312)	4,384 (80,134)	4,257 (70,598)
Altersstufen	1-7				0,408 (1,504)	0,398 (1,489)	0,389 (1,476)
ÖV-Angebot	1-5					-0,317 (0,728)	-0,326 (0,722)
Mentale Verfügbarkeit	0-10						-0,138 (0,871)
Adj. R <sup>2</sup> (Nagelkerke)			0,214	0,398	0,451	0,472	0,487
Chi <sup>2</sup>			1.036,73	2.026,39	2.347,66	2.438,41	1.895,99
Richtig klassifiziert		68,1%	71,4%	76,6%	77,6%	78,4%	79,2%
N=		6.307	6.307	6.072	6.044	5.944	4.439

Tabelle 6: Binär logistisches Regressionsmodell mit der abhängigen Variablen Hauptverkehrsmittel Auto (Dummy: 1 = Auto, 0 = andere); Variablenwerte für die verschiedenen Modelle bilden die Regressionskoeffizienten B ab; Odds-Ratio Exp (B) in Klammern (eigene Darstellung)

In Tabelle 6 sind zudem die Odds-Ratios der verschiedenen Variablen festgehalten (in Klammern): Diese sagen aus, um welchen Faktor die Chance steigt ( $> 1$ ) bzw. sinkt ( $< 1$ ), dass eine Person für die Fahrt zur Universität ein Auto nutzt, wenn sich ein Merkmal (z. B. das Alter) um eine Stufe erhöht. Modell 5 zufolge sind die Bewertung des Autos (Faktor 5,032), der Autobesitz (70,598) sowie das Alter (1,476) die drei Faktoren, die die Nutzungswahrscheinlichkeit des Autos erhöhen, während die Bewertung des ÖV-Angebots vor Ort (,722) und die mentale Verfügbarkeit von Alternativen (,871) diese senken. Dies bestätigt die deskriptiv bereits entwickelten Befunde, erlaubt nun aber, den Einfluss zu gewichten, den die einzelnen Faktoren auf die Nutzung des Autos haben. Dabei sticht der Autobesitz mit einer Odds-Ratio von 70,598 in Modell 5 hervor: Der Besitz des Autos erhöht also die Wahrscheinlichkeit, es für die Fahrt zur Universität zu nutzen, um den Faktor 70.

Die Regressionskoeffizienten (siehe Tabelle 6) wurden zudem genutzt, um die Wahrscheinlichkeiten der Autonutzung zweier fiktiver Personen gemäß der von Backhaus et al. (2016: 283) sowie Wentura/Pospeschill (2015: 60) vorgeschlagenen Formel zu kalkulieren (vgl. Tabelle 7).

Person 1 bewertet das Auto am besten (1), besitzt ein Auto (1), ist zwischen 50 und 59 Jahre alt (6), schätzt das ÖV-Angebot als wenig zufriedenstellend ein (1) und hat sich noch nie mit Alternativen befasst (0). Die Wahrscheinlichkeit der Autonutzung liegt laut Modell bei 95,3 Prozent.

Person 2 stellt einen Gegenentwurf zu Person 1 dar: Sie bewertet ein anderes Verkehrsmittel als das Auto am besten (0), besitzt selbst kein Auto (0), ist mit 25 bis 29 Jahren deutlich jünger (3), bewertet das ÖV-Angebot als recht gut (4)

und hat sich bereits mit drei Alternativen befasst (3). In diesem Fall liegt die Wahrscheinlichkeit der Autonutzung bei 0,4 Prozent.

Variable	Skalierung	Person 1	Person 2	Person 1a	Person 1b	Person 1c
Auto bestbewertet	1 = ja 0 = nein	1	0	1	0	1
Autobesitz	1 = ja 0 = nein	1	0	<del>1</del>	<del>1</del>	0
Altersstufen	1-7	6	3	<del>6</del>	<del>6</del>	<del>6</del>
ÖV-Angebot	1-5	1	4	4	4	4
Mentale Verfügbarkeit	0-10	0	3	3	3	3
<b>Wahrscheinlichkeit</b>		<b>95,3 %</b>	<b>0,4 %</b>	<b>72,6 %</b>	<b>34,5 %</b>	<b>3,6 %</b>

*Tabelle 7: Wahrscheinlichkeit der Autonutzung zweier fiktiver Personen (Zelle durchgestrichen: Variable nicht veränderbar)*

Will man Person 1 dazu bewegen, über Alternativen zum eigenen Pkw nachzudenken (Person 1a), so bietet es sich an, die beiden Kontextfaktoren entsprechend zu beeinflussen, z. B. durch Verbesserung des ÖV-Angebots vor Ort (Wert steigt von 1 auf 4) oder durch bessere Information, etwa über eine intermodale Mobilitäts-App, die die mentale Verfügbarkeit von Alternativen steigert (Wert steigt von 0 auf 3). Allein aufgrund dieser Maßnahmen würde sich die Wahrscheinlichkeit, dass Person 1 weiterhin ein Auto nutzt, um knapp ein Viertel verringern (von 95,3 % auf 72,6 %). Die anderen, in der Tabelle durchgestrichenen Faktoren (Alter und Autobesitz) lassen sich nicht durch externe Maßnahmen beeinflussen, zumindest wenn man die Idee verwirft, dass der Autobesitz verboten werden könnte.

Weiter gehende Effekte ließen sich daher nur erzielen (Person 1b), wenn der subjektive Nutzen des Autos sich derart verringern würde, dass ein anderes Verkehrsmittel erste Wahl wäre – so wie es in Kapitel 4.1 beispielhaft demonstriert wurde. In diesem Fall würde die Wahrscheinlichkeit der Autonutzung auf 34,5 Prozent sinken – eine zwar denkbare, aber nicht kurzfristig realisierbare Option.

Das Auto ganz aus dem Kopf zu bekommen – wie es Weert Canzler (2000) und Andreas Knie immer wieder fordern – wäre nur möglich, wenn die Menschen aufgrund perfekter Rahmenbedingungen in der Lage wären, ihre Mobilitätsbedürfnisse auch ohne das eigene Auto zu befriedigen (Person 1c) – ein Gedankenexperiment, demzufolge es jedoch sehr unwahrscheinlich würde (3,6 %), dass diese fiktive Person das Auto nutzt.

Das um die Kontextfaktoren erweiterte Modell ist also in der Lage, das reale Mobilitätsverhalten im Fall der Autonutzung mit hoher Treffsicherheit zu prognostizieren und das Delta weitgehend zu schließen, das sich bei der Verwendung des basalen Modells, also ohne Kontextfaktoren, ergibt. Zudem zeigt es Optionen auf, wie eine Verhaltensänderung in Richtung nachhaltiger Mobilität angestoßen werden könnte.

### 5.3 Regressionsmodell für die Fahrradnutzung

In einem analog entwickelten Regressionsmodell für die Fahrradnutzung stellte sich eine Kombination von folgenden vier Kontextfaktoren als signifikant heraus: Alter, Autobesitz, Geschlecht und Entfernung zur Universität. Das ebenfalls schrittweise entwickelte Modell 5 ist in Tabelle 8 abgebildet.

Die beiden Variablen, die beim Auto-Modell eine zentrale Rolle gespielt hatten (d. h. die Bewertung des ÖV-Angebots und die mentale Verfügbarkeit von Alternativen) wurden nicht berücksichtigt, da sie nicht zu einer signifikanten Verbesserung des Erklärungsgehalts des Rad-Modells beitrugen. Dies ist einerseits plausibel, denn es gibt – anders als im Fall der Autonutzung bzw. -nichtnutzung – keinen zwingenden Zusammenhang zwischen dem ÖV-Angebot und der Radnutzung und, wie Abbildung 5 bereits gezeigt hatte, nur eine sehr geringe Korrelation ( $r < ,1$ ) zwischen diesen beiden Variablen.

Andererseits ist dies insofern bedauerlich, als damit zwei Ansatzpunkte zur Beeinflussung des Mobilitätsverhaltens in Richtung Nachhaltigkeit entfielen, wie dies zuvor im Rahmen eines Gedankenexperiments anhand einer fiktiven Person demonstriert wurde (vgl. Tabelle 7). Die vier Faktoren, die sich beim Rad-Modell als signifikant erwiesen hatten (Alter, Geschlecht etc.), sind hingegen weitgehend invariant und lassen sich durch entsprechende Maßnahmen kaum beeinflussen – zumindest, wenn man von hypothetischen und sehr einschneidenden Optionen, wie beispielsweise einem Autoverbot, absieht.

Trotz dieser Einschränkungen weist das schrittweise entwickelte Modell 5 mit den genannten vier Kontextfaktoren bereits akzeptable Werte auf (Nagelkerkes  $R^2 = 0,262$ ; richtig klassifiziert: 87,2 %). Modell 1 belegt, dass die ausschließliche Betrachtung der subjektiven Nutzenbewertung – anders als im Fall des Autos – beim Fahrrad nicht einer akzeptablen Varianzaufklärung (Nagelkerkes  $R^2 = 0,117$ ) führt. Hier liegt offenkundig ein großes, bislang ungenutztes Potenzial derart, dass viele Menschen das Rad zwar gut bewerten und es dennoch nicht nutzen.

Um Modell 5 weiter zu verbessern, wurden in den Daten, die im Rahmen des Projekts InnaMoRuhr erhoben worden waren, weitere, radspezifische Kontextfaktoren ausfindig gemacht: Die Forderung nach einem Ausbau von Radwegen, um die Reise zum Campus nachhaltiger zu gestalten, der Zugang zu einer Bikesharing-Station, der Besitz eines Bikesharing-Abos sowie die Funktionsgruppe (Beschäftigte oder

#### Exkurs 3: Prüfung von Voraussetzungen und Ausreißern (Rad-Modell)

Die Voraussetzungen der Linearität und Nicht-Multikollinearität waren im Rad-Modell ebenfalls erfüllt (größter VIF = 1,97; kleinster Toleranzwert = 0,51): Zwar gab es eine hohe Korrelation zwischen dem Alter und der Funktionsgruppe ( $r = -0,644$ ) – gemäß der von Field aufgeführten Faustregeln sind jedoch erst Werte ab  $\pm 0,8$  als kritisch für die Nicht-Multikollinearität anzusehen (2013, S. 534).

Analog zur in Exkurs 2 beschriebenen Ausreißer-Identifikation waren nur in den Modellen 4 und 5 jeweils 6 Fälle betroffen; im erweiterten Modell 6 gab es 5 Ausreißer.

Studierende). Modell 5 wurde zunächst explorativ um diese vier Faktoren erweitert; allerdings trugen nur die Forderung nach einem Radwegeausbau sowie die Funktionsgruppe signifikant zum finalen Modell 6 bei, das ebenfalls in Tabelle 8 zu finden ist und für die folgenden Berechnungen genutzt wurde.

Analog zum oben beschriebenen Verfahren wurden auch hier zunächst Voraussetzungen und das Vorhandensein von Ausreißern geprüft (siehe Exkurs 3). Wie die Daten in Tabelle 8 zeigen, wirken sich nicht nur die positive Bewertung des Fahrrads (4,809), sondern auch ein höheres Alter (1,254), die Zugehörigkeit zur Funktionsgruppe der Beschäftigten (2,189) sowie die Forderung nach mehr und besseren Radwegen (1,557) positiv auf die Nutzung des Rads als Hauptverkehrsmittel aus. Negativ wirken sich – wenig überraschend – die Entfernung zur Universität (0,917) sowie der Autobesitz (0,589) aus. Auch nutzen Frauen, selbst wenn sie das Rad positiv bewerten, dieses Verkehrsmittel weniger häufig als Männer (0,560).

Variable	Skalierung	Modell 0	Modell 1	Modell 2	Modell 3	Modell 4	Modell 5	Modell 6
Konstante			-3,115	-4,126	-3,843	-3,022	-2,739	-2,677
Rad bestbewertet	1 = ja 0 = nein		1,717 (5,569)	1,808 (6,101)	1,793 (6,007)	1,754 (5,778)	1,673 (5,329)	1,571 (4,809)
Altersstufen	1-7			0,269 (1,308)	0,271 (1,311)	0,343 (1,409)	0,380 (1,462)	0,226 (1,254)
Geschlecht	1 = Frau 0 = Mann				-0,575 (0,563)	-0,595 (0,552)	-0,597 (0,551)	-0,580 (0,560)
Entfernung zur Uni	km					-0,092 (0,899)	-0,089 (0,915)	-0,086 (0,917)
Autobesitz	1 = ja 0 = nein						-0,532 (0,587)	-0,529 (0,589)
Funktionsgruppe	1 = Beschäft. 0 = Stud.							0,783 (2,189)
Radwegeausbau	1 = gewählt 0 = nicht g.							0,443 (1,557)
Adj. R <sup>2</sup> (Nagelkerke)			0,117	0,147	0,160	0,249	0,262	0,280
Chi <sup>2</sup>			390,531	495,144	530,679	714,146	740,712	774,876
Richtig klassifiziert		88,3%	88,3%	88,2%	88,2%	87,3%	87,2%	86,6%
N=		6.307	6.307	6.274	6.160	5.006	4.835	4.611

Tabelle 8: Binär logistisches Regressionsmodell mit der abhängigen Variablen Hauptverkehrsmittel Rad (Dummy: 1 = Rad, 0 = andere); Variablenwerte für die verschiedenen Modelle bilden die Regressionskoeffizienten  $B$  ab; Odds-Ratio  $Exp(B)$  in Klammern (eigene Darstellung)

Insgesamt liefert das erweiterte Modell 6 zufriedenstellende Ergebnisse (Chi<sup>2</sup>: 774,876; df: 7;  $p < ,001$ ; Nagelkerkes R<sup>2</sup>: ,280; insgesamt richtig klassifiziert: 86,6 %; N = 4.611), selbst wenn man es mit dem deutlich besseren Auto-Modell



vergleicht.<sup>6</sup> Zudem liegt der AUC-Wert für die Prognosegüte bei 0,818 und kann demnach als „exzellent“ eingestuft werden (Backhaus et al. 2016, S. 301).

Mit dem erweiterten Modell liefern Berechnungen, die zwei fiktive Personen kontrastierend gegenüberstellen, ebenfalls aussagekräftige Ergebnisse (vgl. Tabelle 9).

Variable	Skalierung	Person 1	Person 2	Person 2a	Person 2b	Person 2c	Person 2d
Rad bestbewertet	1 = ja 0 = nein	1	0	0	1	1	1
Altersgruppen	1-7	6	2	<del>2</del>	<del>2</del>	<del>2</del>	<del>2</del>
Geschlecht	1 = Frau 0 = Mann	0	1	<del>1</del>	<del>1</del>	<del>1</del>	<del>1</del>
Entfernung zur Uni	km	3	10	<del>10</del>	<del>10</del>	<del>10</del>	5
Autobesitz	1/0	0	1	<del>1</del>	<del>1</del>	0	0
Funktionsgruppe	1 = Beschäftigte 0 = Studierende	1	0	0	0	0	0
Radwegeausbau	1 = gewählt 0 = nicht g.	1	0	1	1	1	1
<b>Wahrscheinlichkeit</b>		<b>77,2 %</b>	<b>1,5 %</b>	<b>2,3 %</b>	<b>19,8 %</b>	<b>29,6 %</b>	<b>39,2 %</b>

Tabelle 9: Wahrscheinlichkeit der Fahrradnutzung zweier fiktiver Personen (Zelle durchgestrichen: Variable nicht änderbar)

Person 1 ist ein zwischen 50 und 59 Jahre alter (6) männlicher (0) Beschäftigter (1), der drei Kilometer von der Universität entfernt wohnt, kein Auto besitzt (0), das Rad am besten bewertet (1) und den Ausbau von Radwegen wünscht (1). Er wird mit einer Wahrscheinlichkeit von 77,2 Prozent das Fahrrad nutzen. Person 2 ist eine weibliche (1) Studierende (0), die zwischen 20 und 24 Jahren alt ist (2) und 10 Kilometer zurückzulegen hat. Sie besitzt ein Auto (1), bewertet ein anderes Verkehrsmittel als das Rad am besten (0) und zeigt kein Interesse am Ausbau von Radwegen (0). In diesem Fall ist es eher unwahrscheinlich (1,5 %), dass sie den Weg zur Universität mit dem Rad zurücklegen wird.

Daran ändert sich auch nichts Wesentliches, wenn man sie für den Ausbau von Radwegen interessieren kann (Person 2a: 2,3 %) – leider die einzige Kontextvariable, die im Radmodell als „Stellschraube“ zur Verfügung steht. Erst wenn sie aufgrund geänderter Rahmenbedingungen ihre Bewertung der drei Verkehrsmittel – wie im Experiment in Kapitel 4.1 gezeigt – zugunsten des Rads ändert, steigt die Wahrscheinlichkeit der Radnutzung auf knapp 20 Prozent (Person 2b). Falls es gelingen sollte, ihre Mobilitätsbedürfnisse auch ohne den Besitz eines privaten Pkw zu befriedigen, stiege dieser Wert auf knapp 30 Prozent (Person

<sup>6</sup> Die richtige Gesamtklassifizierung ergibt sich aus der richtigen Klassifizierung der Nicht-Radnutzung (98,2 %) und der Radnutzung (14,6 %). Die Sensitivität (Radnutzung richtig klassifiziert) ließe sich zu Lasten der Spezifität (Nicht-Radnutzung richtig klassifiziert) erhöhen, indem hier ein geringerer Schwellenwert für die richtige Klassifizierung der Radnutzung gewählt wird (z. B. ein „cut value“ von 20 % anstelle von 50 %); an der Prognosegüte im Sinne des AUC-Wertes würde dies aber nichts ändern (vgl. Backhaus et al. 2016: 302).



2c), was konkret bedeutet: Sie nutzt mit hoher Wahrscheinlichkeit den gut ausgebauten ÖV, aber nicht das Rad. Selbst ein Umzug in die Nähe der Universität (Person 2d) lässt diesen Wert nur auf knapp 40 Prozent steigen.

Als Fazit lässt sich somit festhalten, dass das Rad-Modell zwar ebenfalls gute und plausible Ergebnisse produziert, aber ein wenig darunter leidet, dass es zu wenige radspezifische Kontextfaktoren enthält, die helfen könnten, das Delta zwischen modelliertem und realem Mobilitätsverhalten zu schließen. Dies verweist auf Lücken in den (Befragungs-)Daten, die sich im Nachhinein nicht mehr schließen lassen. So wurde beispielsweise nicht nach Faktoren wie Wetter, Gesundheit, Zustand der Radwege etc. gefragt, die einen Einfluss auf die Bereitschaft zum Radfahren haben könnten.

#### 5.4 Regressionsmodell für die ÖV-Nutzung

Schließlich wurde ein drittes Regressionsmodell für die ÖV-Nutzung entwickelt, das mit den Kontextvariablen des Automodells arbeitet (Autobesitz, Alter, ÖV-Angebot, mentale Verfügbarkeit von Alternativen) und zusätzlich die Entfernung zur Universität einbezieht (vgl. Tabelle 10). Auch dieses Modell wurde hinsichtlich Voraussetzungen, Ausreißern und Gütekriterien überprüft (vgl. Exkurs 4) sowie stufenweise entwickelt; es weist ab Modell 4 zufriedenstellende bis gute Werte auf.

Im Folgenden wird Modell 6 verwendet, das in den meisten Punkten die besten Werte aufweist: Gütekriterien und Varianzaufklärung sind zwar nicht so gut wie im Auto-Modell (vgl. Kap. 5.2), jedoch insgesamt noch zufriedenstellend (Nagelkerkes  $R^2$ : ,251,  $\text{Chi}^2$ : 764,302; df: 6). Mithilfe der sechs genutzten Variablen lässt sich die korrekte Klassifizierung der Proband:innen um fast 20 Prozentpunkte – von 50,3 Prozent (Modell 0) auf 68,9

##### Exkurs 4: Prüfung von Voraussetzungen und Ausreißern (ÖV-Modell)

Es lag keine Multikollinearität vor (höchster Koeffizient  $r$  in der Korrelationsmatrix = 0,284 zwischen Entfernung und ÖV-Angebot; größter VIF = 1,14; kleinster Toleranzwert = 0,88).

Gemäß Box-Tidwell-Verfahren war die Linearität beim ÖV-Angebot nicht gegeben. Daher wurde das ÖV-Angebot testweise in eine Dummy-Variable umgewandelt (1 = zufriedenstellendes Angebot vorhanden, 0 = *kein* zufriedenstellendes Angebot vorhanden) und die Regression wiederholt. Der Effekt dieser umcodierten, binären Variable war immer noch signifikant ( $B = ,792$ ;  $\text{Exp}(B) = 2,208$ ;  $p < ,001$ ) und es ergaben sich kaum Änderungen am Gesamtmodell (z. B.  $\text{AUC} = ,750$ ;  $R^2 = ,254$ ; insgesamt richtig klassifiziert = 68,7), weswegen wir uns aus Gründen der Einheitlichkeit (vgl. Auto-Modell in Kapitel 5.2) dazu entschieden haben, die ursprüngliche Variable mit fünf Ausprägungen beizubehalten.

Weiterhin konnten gemäß den Empfehlungen von Field (2013) keine Ausreißer festgestellt werden (vgl. Exkurs 2).

Prozent (Modell 6) – erhöhen.<sup>7</sup> Mit einem AUC-Wert von 0,75 ist die Prognosegüte des finalen Modells als „akzeptabel“ einzustufen (vgl. Backhaus et al. 2016: S. 201).

Variable	Skalierung	Modell 0	Modell 1	Modell 2	Modell 3	Modell 4	Modell 5	Modell 6
Konstante			-0,079	0,657	2,020	1,478	0,795	0,680
ÖV bestbewertet	1 = ja 0 = nein		1,108 (3,029)	1,005 (2,731)	1,035 (2,814)	0,998 (2,713)	0,993 (2,698)	0,952 (2,591)
Autobesitz	1/0			-1,018 (0,32)	-0,853 (0,426)	-0,750 (0,472)	-0,812 (0,444)	-0,841 (0,431)
Altersstufen	1-7				-0,450 (0,637)	-0,445 (0,641)	-0,476 (0,621)	-0,497 (0,608)
ÖV-Angebot	1-5					0,152 (1,164)	0,241 (1,272)	0,240 (1,271)
Mentale Verfügbarkeit	0-10						0,037 (1,079)	0,075 (1,078)
Entfernung Uni	km							0,038 (1,039)
Adj. R <sup>2</sup> (Nagelkerke)			,029	,085	,193	,200	,239	,251
Chi <sup>2</sup>			137,410	400,762	943,780	967,443	952,977	764,302
Richtig klassifiziert		50,3%	53,9%	61,7%	66,3%	66,6%	67,5%	68,9%
N=		6.307	6.307	6.083	6.052	5.952	4.819	3.657

*Tabelle 10: Binär logistisches Regressionsmodell mit der abhängigen Variablen Hauptverkehrsmittel Öffentlicher Verkehr (Dummy: 1 = ÖV, 0 = andere); Variablenwerte für die verschiedenen Modelle bilden die Regressionskoeffizienten B ab; Odds-Ratio Exp (B) in Klammern (eigene Darstellung)*

Modell 6 zufolge wirkt sich neben der Bewertung des ÖVs als bestes Verkehrsmittel (2,591) insbesondere die Qualität des ÖV-Angebots am Wohnort (1,271) positiv auf die ÖV-Nutzung aus; darüber hinaus haben die mentale Verfügbarkeit von Alternativen (1,078) wie auch die Entfernung zur Universität (1,039) eine schwach positive Wirkung. Mit jeder Alternative (E-Mobilität, Sharing etc.) steigt die Wahrscheinlichkeit der ÖV-Nutzung von Stufe zu Stufe um ca. 7,8 Prozent und mit jedem Kilometer Entfernung um ca. 3,9 Prozent.

Der Autobesitz (0,431) sowie ein höheres Alter (0,608) wirken sich hingegen negativ auf die ÖV-Nutzung aus. Auch hier wurden die Regressionskoeffizienten (siehe Tabelle 10) genutzt, um die Wahrscheinlichkeiten der ÖV-Nutzung zweier fiktiver Personen zu kalkulieren (vgl. Tabelle 11).

Person 1 bewertet den ÖV am besten (1), besitzt kein Auto (0), ist zwischen 24 und 29 Jahre alt (2), kann auf ein gutes ÖV-Angebot am Wohnort zurückgreifen (4), der 10 Kilometer von der Universität entfernt liegt, und hat sich bereits mit Alternativen befasst (3). Hieraus errechnet sich eine Wahrscheinlichkeit der ÖV-Nutzung von 90,1 Prozent, die sich deutlich von Person 2 abhebt (11,7 %). Diese bildet insofern eine Kontrastfolie, als sie ein anderes Verkehrsmittel als den ÖV

<sup>7</sup> Der gewichtete Mittelwert von 68,9 Prozent ergibt sich aus der korrekten Klassifizierung der Nicht-ÖV-Nutzung (66,2 %) und der ÖV-Nutzung (71,8 %).

am besten bewertet (0), ein Auto besitzt (1), zwischen 40 und 49 Jahre alt ist (5), ein unzureichendes ÖV-Angebot am Wohnort hat (1), der ebenfalls 10 Kilometer entfernt liegt, und sich noch nie Gedanken über Alternativen gemacht hat (0).<sup>8</sup>

Variable	Skalierung	Person 1	Person 2	Person 2a	Person 2b	Person 2c
ÖV bestbewertet	1 = ja 0 = nein	1	0	0	1	1
Autobesitz	1 = ja 0 = nein	0	1	<del>1</del>	<del>1</del>	0
Altersstufen	1-7	2	5	<del>5</del>	<del>5</del>	<del>5</del>
ÖV-Angebot	1-5	4	1	4	5	5
Mentale Verfügbarkeit	0-10	3	0	3	3	3
Entfernung Uni	km	10	10	<del>10</del>	<del>10</del>	<del>10</del>
<b>Wahrscheinlichkeit</b>		<b>90,1%</b>	<b>11,7%</b>	<b>25,3%</b>	<b>52,8%</b>	<b>72,2 %</b>

*Tabelle 11: Wahrscheinlichkeit der Nutzung des ÖVs durch drei fiktive Personen (Zellen durchgestrichen: Variable nicht veränderbar)*

Person 2a stellt den Versuch dar, mehr Personen vom Typus 2 für den ÖV zu gewinnen und dabei vor allem die Faktoren zu ändern, die mit vertretbarem Aufwand gestaltbar sind: Ein attraktives ÖV-Angebot (Wert steigt von 1 auf 4) und eine verbesserte mentale Verfügbarkeit, z.B. durch Werbekampagnen, Mobilitäts-Apps, die Alternativvorschläge unterbreiten, etc. (Wert steigt von 0 auf 3). Alle anderen Faktoren wie der Autobesitz, das Alter und die Entfernung zur Universität sind nicht oder nur schwer änderbar (und daher in der Tabelle konstant gehalten und durchgestrichen).

Wie der Wert von 25,3 Prozent für Person 2a andeutet, bewirken diese Maßnahmen, dass sich die Wahrscheinlichkeit den ÖV zu nutzen nunmehr verdoppelt hat (von 11,7 % auf 25,3 %) – ein kleiner Erfolg, wenngleich die Wahrscheinlichkeit insgesamt immer noch gering ist. Ein größerer Effekt ließe sich erzielen, wenn es gelänge, ein optimales ÖV-Angebot zur Verfügung zu stellen (5) und zudem Person 2b dazu zu bewegen, den ÖV besser zu bewerten (Wert ändert sich von 0 auf 1), so wie es in dem fiktiven Beispiel in Kapitel 4.1 demonstriert wurde. Dann stiege die Wahrscheinlichkeit auf 52,8 Prozent, was konkret bedeutet, dass im Schnitt jeder zweite Weg zum Campus von Person 2b mit dem ÖV zurückgelegt wird. Noch höhere Werte – siehe Person 2c – ließen sich nur erzielen, wenn die Menschen es nicht mehr für erforderlich hielten, ein eigenes

<sup>8</sup> Der ÖV taucht in den Berechnungen insofern zweimal auf, als er einerseits als subjektive Wahrnehmung des ÖV-Angebots in die SEU-Kalkulation eingeht (vgl. Kapitel 4), andererseits als quasi objektiver – wenngleich ebenfalls von den Probanden erfragter – Kontextfaktor berücksichtigt wird. Tatsächlich korrelieren die (eher subjektiven) p-Werte des ÖV mit der (eher objektiven) Variablen „ÖV-Angebot am Wohnort“ ( $r = 0,260$ ,  $p < ,001$ ); aber dies kann akzeptiert werden und ist mit Hinblick auf eine mögliche Multikollinearität unkritisch.

Auto zu besitzen, weil sie ihre Mobilitätsbedürfnisse auch auf andere Weise befriedigen können.

## 6 Fazit: Das erweiterte Modell des Mobilitätsverhaltens

Als Fazit kann festgehalten werden, dass das soziologische Verhaltensmodell gute bis sehr gute Ergebnisse liefert, wenn man es um einen dritten, bislang wenig berücksichtigten Faktor ergänzt: den sozialen Kontext, also eine eher objektive Variable, die die beiden subjektiven Faktoren des basalen Modells (Präferenzen, Situationsdefinition) ergänzt. Die SEU-Formel muss demzufolge entsprechend modifiziert werden (vgl. Abbildung 6), wobei angenommen wird, dass die Kontextfaktoren ( $Kf$ ) vor allem die subjektive Wahrnehmung beeinflussen. Auf diese Weise lässt sich eine sehr hohe Übereinstimmung zwischen modelliertem und realem Verhalten erzielen – mit akzeptabler bis exzellenter Prognosegüte sowie richtigen Klassifizierungswerten von 70 bis knapp 90 Prozent.

$$SEU(A_i) = \sum_{j=1}^n (p * Kf)_{ij} * U(O)_j$$

Abbildung 6: Modifizierte SEU-Formel für die Nutzenberechnung

Gemäß dem erweiterten Modell (siehe Abbildung 7) ist Mobilitätsverhalten somit geprägt durch:

- die individuellen Einstellungen,
- den sozialen Kontext (Wohnort, Kinder, Autobesitz etc.) sowie
- die subjektive Wahrnehmung der Situation, in der man sich befindet (etwa der verfügbaren Mobilitätsangebote).

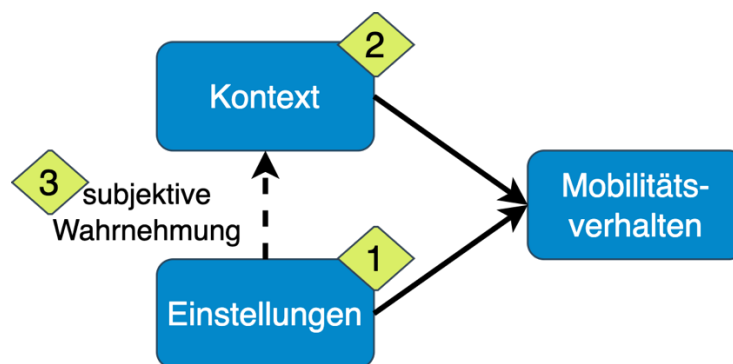


Abbildung 7: Um Kontextfaktoren erweitertes Modell des Mobilitätsverhaltens

Dies hat Konsequenzen für jeglichen Versuch, die Mobilitätswende voranzubringen. Denn es gilt nicht nur neue Mobilitätsangebote zu entwickeln, sondern darüber hinaus auch entsprechende Informationen zur Verfügung zu stellen. Diese sollten aber nicht nach dem Gießkannenprinzip gestreut, sondern zielgerichtet auf individuelle Personen und deren subjektive Sicht der Dinge ausgerichtet werden. Anders als im Fall von Einstellungen, die sich nur sehr langsam

wandeln, und neuen Bahntrassen, deren Bau Jahrzehnte benötigt, lässt sich die subjektive Wahrnehmung leichter beeinflussen und rascher verändern, z.B. durch innovative Mobilitäts-Apps, die maßgeschneiderte Angebote unterbreiten, welche an den individuellen Bedürfnissen der Menschen ansetzen.

#### *Kritische Würdigung und Ausblick*

Dennoch weisen die hier vorgestellten Modelle auch Limitationen auf. Zum einen hat sich etwa bei der Modellierung der Radnutzung herausgestellt, dass in zukünftigen Erhebungen weitere (extern) beeinflussbare Kontextfaktoren berücksichtigt werden sollten, mit deren Hilfe man Gedankenexperimente für verschiedene, fiktive Personen durchführen kann. Um nicht nur die Auswirkungen solcher Maßnahmen (z. B. einer Verbesserung des ÖV-Angebots) auf *individuelle* Personen, sondern auch größere *Populationen* abzubilden, bietet es sich ferner an, das erweiterte Modell des Mobilitätsverhaltens auch im Rahmen von agentenbasierten Simulationen anzuwenden und weiter simulativ zu erproben.

Außerdem gehen die hier vorgestellten Regressionsmodelle von separaten Einzelentscheidungen bei der Verkehrsmittelwahl aus („Nehme ich heute das Fahrrad oder nicht? Nehme ich heute das Auto oder nicht?“ etc.), wenngleich jeweils Verkehrsmittel-übergreifende Faktoren berücksichtigt werden (z. B. Autobesitz, ÖV-Angebot). Folglich könnte das Modell durch die Anwendung einer multinomial-logistischen Regression verfeinert werden, um eine direkte Konkurrenz der Verkehrsmittel besser abzubilden („Nehme ich heute Fahrrad, Auto oder ÖV?“).

## 7 Literatur

- Backhaus, Klaus/Bernd Erichson/Wulff Plinke/Rolf Weiber, 2016: Multivariate Analysemethoden. Eine anwendungsorientierte Einführung. Berlin: Springer.
- Bamberg, Sebastian, 2012: Wie funktioniert Verhaltensänderung? Das MAX-Selbstregulationsmodell. In: Mechthild Stiewe/Ulrike Reutter (Hg.), Mobilitätsmanagement - Wissenschaftliche Grundlagen und Wirkungen in der Praxis. Essen: Klartext Verlag, 76-101.
- Canzler, Weert, 2000: Das Auto im Kopf und vor der Haustür: Zur Wechselbeziehung von Individualisierung und Autonutzung. In: Soziale Welt 51: 191-207.
- Coleman, James S., 1995: Grundlagen der Sozialtheorie. Handlungen und Handlungssysteme. Band 1. München: Oldenbourg.
- Esser, Hartmut, 1993: Soziologie. Allgemeine Grundlagen. Frankfurt/M.: Campus.
- , 2000: Soziologie. Spezielle Grundlagen, Bd. 3: Soziales Handeln. Frankfurt/M.: Campus.

- Field, Andy, 2013: *Discovering statistics using IBM SPSS statistics*. London: Sage.
- Huber, Peter J., 1981: *Robust statistics*. New York: Wiley.
- Hunecke, Marcel, 2015: *Mobilitätsverhalten verstehen und verändern: Psychologische Beiträge zur interdisziplinären Mobilitätsforschung*. Wiesbaden: Springer Fachmedien.
- Scheiner, Joachim/Christian Holz-Rau, 2007: Travel mode choice: affected by objective or subjective determinants? In: *Transportation* 34 (4): 487-511.
- Wentura, Dirk/Markus Pospeschill, 2015: *Multivariate Datenanalyse*. Wiesbaden: Springer Fachmedien.
- Weyer, Johannes, 2022: *Mobilitätspraktiken und Mobilitätsbedarfe. Ergebnisse einer Befragung von Angehörigen der UA-Ruhr-Universitäten (Mobility Report 2/2022)*. Dortmund: InnaMoRuhr, [https://innamo.ruhr/wp-content/uploads/2022/06/Report\\_02\\_Befragung\\_250422\\_final.pdf](https://innamo.ruhr/wp-content/uploads/2022/06/Report_02_Befragung_250422_final.pdf).