

Gender-Gaps auch in der Cloud? Die Rolle von Stereotypen und Algorithmen auf einer Freelancing Plattform.

DISSERTATION

(angenommene/accepted Dissertation)

zur Erlangung des
akademischen Grades

eines Doktors
der Staatswissenschaften (Dr. rer. pol.)

am Fachbereich: Kultur- und Sozialwissenschaften
der Rheinland-Pfälzischen Technischen Universität Kaiserslautern-Landau

vorgelegt im Promotionsfach Wirtschaftswissenschaften

Schwerpunkt Arbeitsmarkt- und Sozialpolitik

am 17.02.2023

von Benedikt Runschke

Erstgutachter: Herr Prof. Dr. Werner Sesselmeier

Zweitgutachterin: Frau Prof. Dr. Aysel Yollu-Tok

Datum der Disputation: 26.05.2023

Gender-Gaps auch in der Cloud? Die Rolle von Stereotypen und Algorithmen auf einer Freelancing Plattform.

DISSERTATION

zur Erlangung des
akademischen Grades

eines Doktors
der Staatswissenschaften (Dr. rer. pol.)

am Fachbereich: Kultur- und Sozialwissenschaften
der Rheinland-Pfälzischen Technischen Universität Kaiserslautern-Landau

vorgelegt im Promotionsfach Wirtschaftswissenschaften

Schwerpunkt Arbeitsmarkt- und Sozialpolitik

am 17.02.2023

von Benedikt Runschke

geb. am 22. 03. 1991 in Gerolstein

Erstgutachter: Herr Prof. Dr. Werner Sesselmeier

Zweitgutachterin: Frau Prof. Dr. Aysel Yollu-Tok

Inhaltsverzeichnis

Abbildungsverzeichnis	IV
Tabellenverzeichnis	V
Abkürzungsverzeichnis	VI
1 Einleitung	1
2 Grundlagen zur Plattformökonomie und der Geschlechterdiskriminierung	5
2.1 Die Charakteristika der Plattformökonomie	5
2.1.1 Definition und Abgrenzung	5
2.1.2 Organisationsform	12
2.1.3 Größe, Verbreitung und Entwicklung	15
2.1.4 Erwerbstätigenstruktur	19
2.1.4.1 Geschlechterverhältnisse	19
2.1.4.2 Herkunftsland	21
2.1.4.3 Altersverteilung	22
2.1.4.4 Bildungsstand	24
2.1.4.5 Familienstand und Haushalt	25
2.1.4.6 Erwerbsstatus	27
2.1.4.7 Arbeitsvolumen	29
2.1.4.8 Arbeitseinkommen	32
2.2 Konzepte der ökonomischen Diskriminierungsforschung	34
2.2.1 Definition	34
2.2.2 Diskriminierungsmodelle	36
2.2.2.1 Präferenzbasierte Diskriminierung	37
2.2.2.1.1 Arbeitgebendendiskriminierung	38
2.2.2.1.2 Arbeitnehmendendiskriminierung	43
2.2.2.1.3 Konsumierendendiskriminierung	44
2.2.2.2 Statistische Diskriminierung	46
2.2.2.2.1 Screening Discrimination	47
2.2.2.2.2 Stereotype	49
2.2.3 Gegenüberstellung der Diskriminierungstheorien und Übertragbarkeit auf die Plattformökonomie	52
2.3 Aktueller empirischer Forschungsstand zur Geschlechterdiskriminierung in der Plattformökonomie	56
2.3.1 Diskriminierung bei Beauftragung	57
2.3.2 Preisdiskriminierung	61
2.3.3 Kernergebnisse der Literatur und Forschungslücke	65

2.4	Zwischenfazit und Ableitung der Forschungsfrage	66
3	Plattformauswahl und Identifizierung von Diskriminierungspotenzialen	70
3.1	Auswahl des Untersuchungsgegenstandes	70
3.1.1	Einschränkung auf eine Plattformkategorie	70
3.1.2	Vorauswahl von Freelancing-Marktplätzen	73
3.1.3	Gültigkeit der Annahmen auf den Freelancing-Marktplätzen mit Fokus auf die Informations(a)symmetrie	75
3.1.4	Zusammenfassung der Plattformauswahl	80
3.2	Funktionsweise des Freelancing-Marktplatzes <i>freelancer.com</i>	82
3.2.1	Grundlegende Informationen	82
3.2.2	Auftragsarten und Vergabeverfahren	84
3.2.3	Geschäftsmodell	86
3.2.4	Informationen zur Beurteilung der Plattformakteur:innen	90
3.2.5	Algorithmisches Management	96
3.3	Zwischenfazit und Ableitung von Hypothesen	98
3.3.1	Geschlechterstereotype in Beauftragung und Angebotspreisen	98
3.3.2	Einfluss des Rankingalgorithmus auf die Beauftragungswahrscheinlichkeit	100
4	Methodisches Vorgehen	103
4.1	Datenerhebung	103
4.1.1	Wahl des Erhebungsverfahrens	103
4.1.2	Datenerhebung mittels Web-Scraping	105
4.1.3	Rechtliche und ethische Aspekte des Web-Scraping	106
4.2	Datenaufbereitung	108
4.2.1	Aufbereitung und Operationalisierung der abhängigen Variablen	108
4.2.2	Aufbereitung und Operationalisierung der zentralen unabhängigen Variablen	111
4.2.2.1	Geschlechtsbestimmung in zwei Stufen	111
4.2.2.1.1	Stufe 1: Geschlechtsbestimmung auf Basis der Profildaten	112
4.2.2.1.2	Stufe 2: Geschlechtsbestimmung auf Basis der Namen	122
4.2.2.2	Rang der Freelancer:innen	126
4.2.3	Operationalisierung weiterer Kontrollvariablen	127
4.2.4	Bereinigung des aufbereiteten Datensatzes	134
4.3	Datenanalyse	135
4.3.1	Modell zur Analyse der Beauftragungswahrscheinlichkeit	135
4.3.2	Modell zur Analyse der Angebotspreise	140

5	Ergebnisdarstellung und Interpretation	143
5.1	Deskriptive Analyse	143
5.2	Quantifizierung der Beauftragungswahrscheinlichkeit in Abhängigkeit des Geschlechts und des Rangs.....	153
5.2.1	Zu prüfende Hypothesen und Hinweise zur Bewertung der Modellergebnisse.....	153
5.2.2	Analyse über alle Tätigkeitskategorien	155
5.2.3	Analyse auf Ebene der Tätigkeitskategorien.....	159
5.3	Analyse der Geschlechterunterschiede in den Angebotspreisen.....	163
5.3.1	Zu prüfende Hypothesen und Hinweise zur Bewertung der Modellergebnisse.....	164
5.3.2	Analyse über alle Tätigkeitskategorien	165
5.3.3	Analyse auf Ebene der Tätigkeitskategorien.....	167
5.4	Kritische Würdigung der Ergebnisse.....	169
6	Fazit	173
6.1	Zusammenfassung und Ausblick.....	173
6.2	Sozialpolitische Implikationen.....	182
	Literatur	187
	Anhang.....	209

Abbildungsverzeichnis

Abbildung 1: Typisierung von kommerziellen digitalen Plattformen.....	9
Abbildung 2: Typisierung von kommerziellen digitalen Arbeitsplattformen	11
Abbildung 3: Projektkategorien der Plattform <i>freelancer.com</i> nach dem Auftragsvolumen abgeschlossener Projekte im Jahr 2021	83
Abbildung 4: Beispielfoto vor- und nach der Anwendung des Geschlechtserkennungsalgorithmus.....	118
Abbildung 5: Verteilung der abgegebenen Angebote auf die Tätigkeitskategorien	145
Abbildung 6: Frauenanteile der abgegebenen Angebote insgesamt und nach den drei häufigsten Tätigkeitskategorien	146
Abbildung 7: Durchschnittlicher Rang von Frauen und Männern nach den drei häufigsten Tätigkeitskategorien	150

Tabellenverzeichnis

Tabelle 1:	Gegenüberstellung der Diskriminierungstheorien.....	53
Tabelle 2:	Tabellarische Darstellung der Typisierung nach Schmidt (2016) von Arbeitsplattformen zur Vermittlung von bezahlten Dienstleistungen.....	71
Tabelle 3:	Zusammenfassende Darstellung der Gültigkeit der Annahmen	81
Tabelle 4:	Übersicht zu den Gebühren und Entgelten auf freelancer.com (1/2).....	88
Tabelle 5:	Übersicht zu den Gebühren und Entgelten auf freelancer.com (2/2).....	89
Tabelle 6:	Plattformerhobene Informationen zur Beurteilung der Plattformakteur:innen (1/3).....	92
Tabelle 7:	Plattformerhobene Informationen zur Beurteilung der Plattformakteur:innen (2/3).....	93
Tabelle 8:	Plattformerhobene Informationen zur Beurteilung der Plattformakteur:innen (3/3).....	94
Tabelle 9:	Einflussfaktoren des Rankingalgorithmus.....	97
Tabelle 10:	Konfusionsmatrix für eine binäre Klassifikation	115
Tabelle 11:	Gütemaße Annotationssample auf Basis der Fotos	119
Tabelle 12:	Gütemaße Annotationssample auf Basis der Vornamen und Herkunftsländer	124
Tabelle 13:	Schlüsselwörter zur Identifikation des Bildungsniveaus	132
Tabelle 14:	Gütemaße Annotationssample Bildungsvariable auf Basis der Levenshtein-Distanz.....	133
Tabelle 15:	Kontrollvariablen der beiden Regressionsmodelle	138
Tabelle 16:	Charakteristika der Freelancer:innen nach dem Geschlecht	144
Tabelle 17:	Charakteristika der Auftraggebenden und Aufträge nach dem Geschlecht der Freelancer:innen.....	148
Tabelle 18:	Übersicht über die Hypothesen zur Beauftragungswahrscheinlichkeit	154
Tabelle 19:	Ergebnisse der bedingten logistischen Regression zur Analyse der Beauftragungswahrscheinlichkeit	158
Tabelle 20:	Ergebnisse der bedingten logistischen Regression zur Analyse der Beauftragungswahrscheinlichkeit – Tätigkeitskategorien	161
Tabelle 21:	Übersicht über die Hypothesen zu den Angebotspreisen.....	164
Tabelle 22:	Ergebnisse der Fixed Effect Regression zur Analyse der Angebotspreise.....	167
Tabelle 23:	Ergebnisse der Fixed Effect Regression zur Analyse der Angebotspreise – Tätigkeitskategorien.....	168

Abkürzungsverzeichnis

AGB	Allgemeine Geschäftsbedingungen
AMT	Amazon Mechanical Turk
API	Application Programming Interface
ASX	Australian Securities Exchange
AUD	Australische Dollar
CC-Lizenz	Creative-Commons-Lizenz
DSGVO	Datenschutz-Grundverordnung
E	Erwerbstätige
EU	Europäische Union
EUR	Euro
G	Gesamtbevölkerung
GPA	Grenzprodukt der Arbeit
ILO	International Labour Office
IIA	Independence from Irrelevant Alternatives
INR	Indische Rupie
ISCED	International Standard Classification of Education
IWF	Internationaler Währungsfonds
k-NN	k-Nächste Nachbarn
MAR	Missing At Random
MCAR	Missing Completely At Random
MNAR	Missing Not At Random
MLM	Mobile Labour Market
MLP	Multilayer Perceptron
MSE	Mean Squared Error
OLI	Online Labour Index
OLM	Online Labour Market
OLS	Ordinary Least Squares
RatSWD	Rat für Sozial- und Wirtschaftsdaten
UNESCO	United Nations Educational, Scientific and Cultural Organization
URL	Uniform Resource Locators
USD	US-Dollar
WZB	Wissenschaftszentrum Berlin für Sozialforschung

1 Einleitung

Das Internet wird den Arbeitsmarkt in drei zentralen Aspekten verändern. So lautet die im Jahr 2001 vom US-amerikanischen Arbeitsmarktökonom David H. Autor getroffene Vorhersage. Dabei umfasst sie die Art und Weise, wie Angebot und Nachfrage zueinanderfinden, dass die Arbeitsleistung künftig über das Internet erbracht wird und dass die Arbeitsnachfrage sich von lokalen Arbeitsmarktbedingungen löst (Autor 2001:25). Über 20 Jahre danach bestätigen sich die von Autor getroffenen Aussagen. Entstandene Jobportale (z. B. *Indeed*) und Berufsnetzwerke (z. B. *LinkedIn*) haben den Matchingprozess zwischen Angebot und Nachfrage digitalisiert und effizienter gemacht. Die Erbringung von Arbeitsleistungen über das Internet ist spätestens seit der COVID-19-Pandemie keine Seltenheit mehr und der durch die Pandemie ausgelöste starke Anstieg der Nutzung von Homeoffice ermöglicht nun auch die ortsungebundene Erbringung von Arbeit (Destatis 2022).

Parallel zu den Entwicklungen auf dem klassischen Arbeitsmarkt hat sich seit Anfang der 2000er-Jahre mit der Plattformökonomie eine neue hybride Organisationsform gebildet. Plattformen sind onlinebasiert und steuern die wirtschaftliche und soziale Aktivität ihrer Nutzenden durch Algorithmen (Kenney und Zysman 2016:65). Sie haben es geschafft, alle drei Aspekte von Autor (2001) noch radikaler umzusetzen. Lukas Biewald, der Gründer der Plattform *CrowdFlower*, fasst dies wie folgt zusammen:

„Before the Internet, it would be really difficult to find someone, sit them down for ten minutes and get them to work for you, and then fire them after those ten minutes. But with technology, you can actually find them, pay them the tiny amount of money, and then get rid of them when you don't need them anymore.“ (Lukas Biewald zitiert nach Marvit 2014).

Das Zitat offenbart sowohl die Chancen als auch die Risiken der Arbeit über Plattformen. Einerseits haben sowohl Auftraggebende als auch Auftragnehmende eine nie dagewesene Flexibilität hinsichtlich der Auswahl an Aufträgen und der zeitlichen sowie örtlichen Erfüllung dieser. Andererseits können die

Arbeitsbeziehungen lediglich sehr kurzfristig sein und gehen in der Regel – aufgrund der Selbstständigkeit – ohne jegliche weitere soziale Absicherung einher.

Trotzdem bietet die Arbeit über Plattformen für Personen, die am klassischen Arbeitsmarkt aufgrund anderer Verpflichtungen wie Sorgearbeit nicht oder nur eingeschränkt partizipieren können, eine neue Chance, diese besser mit einer Erwerbstätigkeit in Einklang zu bringen. Damit sind Plattformen vor allem auch für Frauen interessant, die immer noch einen Großteil der Sorgearbeit in unserer Gesellschaft leisten (Lott et al. 2022:33 ff.). Empirisch zeigt sich bereits, dass Frauen diese Möglichkeit tatsächlich auch vermehrt nutzen (Urzi Brancati et al. 2020:21). Insgesamt hat die COVID-19-Pandemie den Plattformen weiteren Auftrieb verliehen (Stephany et al. 2021) und für die Zukunft wird ein stetiges Wachstum erwartet (Urzi Brancati et al. 2020:4). Die Relevanz der Plattformökonomie dürfte demnach weiter zunehmen, woraus eine Notwendigkeit entsteht, diese Plattformen in den Fokus der Wissenschaft zu stellen und hinsichtlich ökonomischer Aspekte zu untersuchen. Die zunehmende Partizipation von Frauen auf diesen Plattformen rückt dabei insbesondere mögliche Geschlechterungleichheiten in den Vordergrund.

Vom klassischen Arbeitsmarkt sind hinreichende Belege für Geschlechterungleichheiten zulasten der Frauen in Bezahlung (Gender-Pay-Gap) und im Bewerbungsprozess bekannt. Als mögliche Gründe für diese Ungleichheiten werden in der Literatur Stereotype und die damit einhergehende Segregation des Arbeitsmarkts in typische Frauen- und Männerberufe oder geringere Arbeitsmarktpartizipation aufgrund der Übernahme von Sorgearbeit angeführt (Blau und Kahn 2017:827; Busch 2013a; Litman et al. 2020:2).

Die zum klassischen Arbeitsmarkt abweichenden Rahmenbedingungen, z. B. eine hohe Informationstransparenz, die Nutzung von Algorithmen zur Marktsteuerung¹ und die fehlende physische Interaktion der Akteur:innen, bieten die Chance, dass die vom klassischen Arbeitsmarkt bekannten Ungleichheiten in der Plattformökonomie abgebaut werden. Gleichzeitig bergen diese Elemente aber auch neue Risiken. Die Vermittlung kurzweiliger Aufträge mit geringen

¹ Algorithmen werden bspw. eingesetzt, um Rankings von Plattformarbeitenden zu erstellen oder Plattformarbeitenden Vorschläge für Aufträge zu unterbreiten.

Auftragsvolumen und die für Auftraggebende eingeschränkt verifizierbaren Informationen über die Freelancer:innen könnten die Bedeutung von Stereotypen auf den Plattformen gar erhöhen (Galperin 2021:1102).

Die bisherige Evidenz dazu ist jedoch unzureichend und es fehlt an der Berücksichtigung plattformspezifischer Mechanismen in den Analysen. Hieran knüpft die vorliegende Arbeit an. Es soll geprüft werden, ob sich im Beauftragungsverhalten der Auftraggebenden Hinweise auf die Nutzung von Stereotypen finden lassen, welchen Einfluss diese auf die Preissetzung der Auftragnehmenden haben und welche Rolle dabei Plattformvariablen spielen, die von Algorithmen generiert werden. Dazu wird folgende Forschungsfrage aufgestellt:

Welche Rolle spielen Geschlechterstereotype für die Beauftragungsentscheidung von Auftraggebenden und die Preissetzung von Auftragnehmenden unter Berücksichtigung des Einflusses eines Algorithmus?

Zur Beantwortung der Forschungsfrage wird im zweiten Kapitel zunächst die Plattformökonomie charakterisiert. Hierzu wird diese definitorisch abgegrenzt und die Organisationsform eingeordnet. Anschließend wird aufgezeigt, wie verbreitet die Plattformökonomie bereits ist und welche Charakteristika die dort aktiven Personen aufweisen. Als theoretische Grundlage wird in dem nächsten Abschnitt Diskriminierung definiert und verschiedene ökonomische Diskriminierungsmodelle beschrieben sowie gegenübergestellt. Welche Forschungsergebnisse zur Geschlechterdiskriminierung in der Plattformökonomie bereits vorliegen, wird im dritten Abschnitt dargestellt. Das Kapitel schließt mit einem Zwischenfazit, das die Forschungslücke beschreibt und aus der die Forschungsfrage abgeleitet wird.

Um einen für die Fragestellung geeigneten Untersuchungsgegenstand zu finden, wird im dritten Kapitel zunächst das hierzu genutzte mehrstufige Vorgehen erläutert. Anschließend werden die Charakteristika der zu untersuchenden Plattform beschrieben. Der letzte Abschnitt des Kapitels zieht ein Zwischenfazit und leitet aus diesem die Hypothesen zur Beantwortung der Forschungsfragen ab.

Die methodische Herangehensweise zur Überprüfung der Hypothesen wird im vierten Kapitel ausführlich beschrieben. Hierin wird zunächst auf die durchgeführte Datenerhebung eingegangen. Der zweite Abschnitt beschreibt die Aufbereitung und

Operationalisierung der in der Analyse genutzten Variablen sowie die durchgeführte Datenbereinigung. Der letzte Abschnitt stellt die genutzten ökonometrischen Modelle dar.

Das fünfte Kapitel beinhaltet die Ergebnisse der Analyse. Zunächst erfolgt eine deskriptive Darstellung des Datensatzes. Anschließend werden die Modellergebnisse zur Analyse der Beauftragungswahrscheinlichkeit vorgestellt und diskutiert. Danach folgen die Modellergebnisse zur Analyse der Angebotspreise. Das Kapitel endet mit einer kritischen Würdigung.

Abschließend werden im letzten Kapitel die Kernergebnisse im Hinblick auf die Beantwortung der Forschungsfrage zusammengefasst und außerdem ein Ausblick auf künftigen Forschungsbedarf in diesem Feld gegeben. Zum Schluss werden die sich aus den Ergebnissen ergebenden sozialpolitischen Implikationen diskutiert.

2 Grundlagen zur Plattformökonomie und der Geschlechterdiskriminierung

Zur Beantwortung der Forschungsfrage werden in diesem Kapitel Grundlagen zur Plattformökonomie, zu den ökonomischen Diskriminierungsmodellen und zum aktuellen Forschungsstand vermittelt. Hierzu werden zunächst Informationen über die Definition und Abgrenzung, die Organisationsform, die Relevanz und wesentliche Charakteristika der auf Plattformen tätigen Personen dargelegt. Anschließend erfolgen die Diskussion und Gegenüberstellung der ökonomischen Diskriminierungstheorien. Danach wird der aktuelle empirische Forschungsstand zur Geschlechterdiskriminierung in der Plattformökonomie mit den Kernaussagen skizziert. Abschließend wird ein Zwischenfazit gezogen, die Forschungslücke aufgezeigt sowie die Forschungsfrage definiert.

2.1 Die Charakteristika der Plattformökonomie

Die Plattformökonomie ist nicht als etwas vollkommen Neues zu verstehen, sondern hat mitunter seit Jahrzehnten bekannte Märkte und Organisationsformen digitalisiert. Die (aktive) Teilnahme der Plattform als Intermediär am Marktgeschehen stellt die eigentliche Neuerung dar und hat die Bedingungen der Interaktion der Akteur:innen geändert (Kalleberg und Dunn 2016:11). Um abschätzen zu können, welche Auswirkungen diese neuen Rahmenbedingungen haben, ist es zunächst wichtig zu wissen, was die Plattformökonomie genau umfasst, wie sie organisationstheoretisch zu beurteilen ist, wie weit sie verbreitet ist und welche Charakteristika die Personen aufweisen, die dort ihre Dienstleistungen anbieten.

2.1.1 Definition und Abgrenzung

In der Literatur zur Plattformökonomie finden sich eine Vielzahl verschiedener Begriffe wie Gig-Economy, Collaborative Economy, Sharing Economy, On Demand Economy, Crowdsourcing, Crowdwork und Cloudwork (Codagnone et al. 2016:10; Pongratz und Bormann 2017:158; Serfling 2018:5). Eine einheitliche Definition, was genau die Plattformökonomie oder die oben genannten Begriffe umfassen, wurde bisher noch nicht entwickelt (Forde et al. 2017:21). Das hat dazu geführt, dass in

der Literatur verschiedenste Abgrenzungen kursieren. Diese fassen den Begriff mal weit oder mal sehr spezifisch und weisen zum Teil untereinander Überschneidungen auf. Das in dieser Arbeit genutzte Wort Plattformökonomie ist dabei der neutralste und umfassendste Begriff (Forde et al. 2017:21). Hierunter lassen sich sämtliche zuvor genannte Schlagwörter subsumieren. Um den Begriff Plattformökonomie greifbarer zu machen, ist es zunächst hilfreich, die Bedeutung und Abgrenzung der anderen hierunter fallenden Begriffe zu kennen.

Zunächst wären da die positiv konnotierten Wörter Sharing Economy und Collaborative Economy. In der Literatur wird rege über diese Abgrenzungen diskutiert. Zentraler und ungeklärter Diskussionspunkt ist, ob hierunter sowohl kommerzielle als auch nicht kommerzielle Plattformen fallen (Schor und Attwood-Charles 2017:2 ff.). In dieser Arbeit wird der Begriff Sharing Economy im Sinne der gemeinschaftlichen Nutzung von Gütern ohne die Verfolgung finanzieller Interessen verstanden. Damit werden hierunter Plattformen wie *Wikipedia* oder *Couchsurfing* gefasst (Schmidt 2016:5). Kommerzielle Plattformen wie der Unterkunftsvermittler *Airbnb* oder der Fahrdienstvermittler *Uber* gehören nicht dazu. Sie bieten zwar im weitesten Sinne auch Güter zur gemeinschaftlichen Nutzung an, wandeln diese aber von Konsumgütern oder Arbeitszeit in Kapitalgüter um, mit dem Ziel, Gewinne zu generieren (Zysman und Kenney 2017:333).

Der Begriff On Demand Economy greift das Flexibilitätsversprechen der Plattformen auf und ist mit dem in der Literatur auch gängigen Begriff der Gig-Economy gleichzusetzen (Lepanjuuri et al. 2018:12). Auftragnehmer können selbst entscheiden, wann sie arbeiten, für wen, wo und wie oft. Auftraggebenden stehen bei Bedarf austauschbare Arbeitskräfte zur Verfügung, die auftragsbezogen angeheuert werden können (Schmidt 2016:13). Im Gegensatz zur Sharing Economy werden hierunter kommerzielle Plattformen gefasst, auf denen Dienstleistungen digital gehandelt werden, wobei die Ausführung der Dienstleistung sowohl ortsungebunden als auch ortsabhängig erfolgen kann. Beispielplattformen sind der Fahrdienstvermittler *Uber*, die Crowdfunding Plattform *Amazon Mechanical Turk* sowie der Freelancing Marktplatz *freelancer.com*. Werden die Dienstleistungen nur ortsunabhängig durchgeführt, ist der Begriff Online Labour Market (OLM) zutreffend (Horton 2010:516) und werden sie nur ortsabhängig

durchgeführt, hat sich Mobile Labour Market (MLM) in der Literatur etabliert (Codagnone et al. 2016:10).

Von der On Demand Economy nicht erfasst sind Plattformen, auf denen Güter zwischen Unternehmen und Konsumierenden gehandelt werden. Diese werden als Product Service Economy bezeichnet. Beispiele hierfür sind klassische Autovermietungen wie *Hertz* oder *Sixt* oder der *Amazon Marktplatz*. Findet der Handel zwischen Konsumierenden statt, wie auf dem Marktplatz *Ebay Kleinanzeigen*, so handelt es sich um die Second Hand Economy (Frenken und Schor 2019:125).

In dieser Arbeit wird Plattformökonomie als Begriff für einen Onlinedienst verstanden und genutzt. Dieser kann sowohl kommerziell als auch nicht-kommerziell sein und ermöglicht den Handel von Dienstleistungen und Gütern. Die Dienstleistungen können dabei ortsungebunden als auch ortsabhängig ausgeführt werden.

Die nächste Herausforderung in diesem Forschungsfeld besteht darin, eine Typologie für die Vielzahl an Plattformen zu finden (vgl. Abschnitt 2.1.3). In der Literatur werden hierzu verschiedenste Ansätze verfolgt, die häufig auf einer zweidimensionalen Einteilung beruhen.

Am gängigsten ist die Einteilung der Plattformen anhand der Anforderungen der vermittelten Aufgaben. Eine frühe Typisierung hat dazu Martin et al. (2008:1259) in Kombination mit dem Innovationsgrad der Aufgabe vorgenommen. Die Autor:innen beschränken sich hierbei auf Plattformen des Crowdsourcings². Neben der Komplexität der Aufgaben beziehen Kuek et al. (2015:1) auch den Aufgabenumfang mit ein und kommen dadurch zu einer Unterscheidung von Microwork und Online Freelancing. Weiter haben mehrere Studien den Ausführungsort des Auftrags in den Blick genommen. Hierbei wird zwischen Plattformen unterschieden, die ortsunabhängige und ortsabhängige Aufträge vermitteln und dabei hohe oder geringe Anforderungen an die Auftragnehmenden

² Crowdsourcing beschreibt hierbei eine Teilmenge der On Demand Economy. Der Begriff ist in den frühen Jahren der Plattformökonomie geprägt worden, maßgeblich durch das Aufkommen von Crowdfunding Plattformen wie *Amazon Mechanical Turk*, und hat sich in der Literatur der späteren Jahre und vor allem im englischsprachigen Raum jedoch nicht durchgesetzt.

stellen (De Groen et al. 2016:2; Huws et al. 2016:2 f.; Vallas und Schor 2020:276). Die Autor:innen stützen sich bei ihren Typisierungen auf die On Demand Economy.³

Weitere Beiträge von Forde et al. (2017:30 ff.) und Kalleberg und Dunn (2016:12 ff.) beziehen neben dem Ort der Tätigkeit und der Auftragshöhe auch die Kontrolle durch die Plattform in ihre Typisierung mit ein. Weiter wird die Ausübungsart der Tätigkeiten (kognitiv vs. manuell) in Typisierungen aufgegriffen (Codagnone et al. 2016:18; OECD 2016:12) sowie die grobe Einteilung in Kapital- und Arbeitsplattformen (Farrell und Greig 2016:20) vorgenommen oder eine umfangreiche Clusteranalyse für Crowdfunding Plattformen durchgeführt (Leimeister, Zogaj, et al. 2016).

All die vorgenannten Typisierungen beschränken sich auf bestimmte Bereiche der Plattformökonomie, meist auf die On Demand Economy. Die einzig bekannte Typisierung, die den Blick auf sämtliche Arten kommerzieller⁴ digitaler Plattformen richtet, ist die von Schmidt (2016). Sie umfasst damit neben der On Demand Economy auch die Product Service Economy und die Second Hand Economy. Um in dieser Arbeit eine möglichst ergebnisoffene Identifikation des Untersuchungsgegenstandes innerhalb einer konsistenten Typisierung vornehmen zu können (vgl. Kapitel 3), wird fortan die Typisierung nach Schmidt (2016) genutzt und im Folgenden ausführlich beschrieben.

In der ersten Ebene teilt Schmidt (2016) die kommerziellen digitalen Plattformen in Abhängigkeit der vermittelten Ware ein. Diese kann dabei ein *Gut*, eine *Dienstleistung*, *Geld*, *Kommunikation*, *Unterhaltung* und *Informationen* darstellen. Diese ersten Ebenen können dann weiter untergliedert werden. Bei *Gütern* ist die Unterscheidung in Verkauf und Vermietung von materiellen oder immateriellen Gütern untergliedert (vgl. Abbildung 1). Sogenannte Crowdfunding Plattformen wie *Kickstarter* sind eindeutig der Kategorie *Geld* zuzuordnen. Andere wie Social-Media-Plattformen (*Facebook*, *YouTube*) sind hybride Plattformen und lassen sich

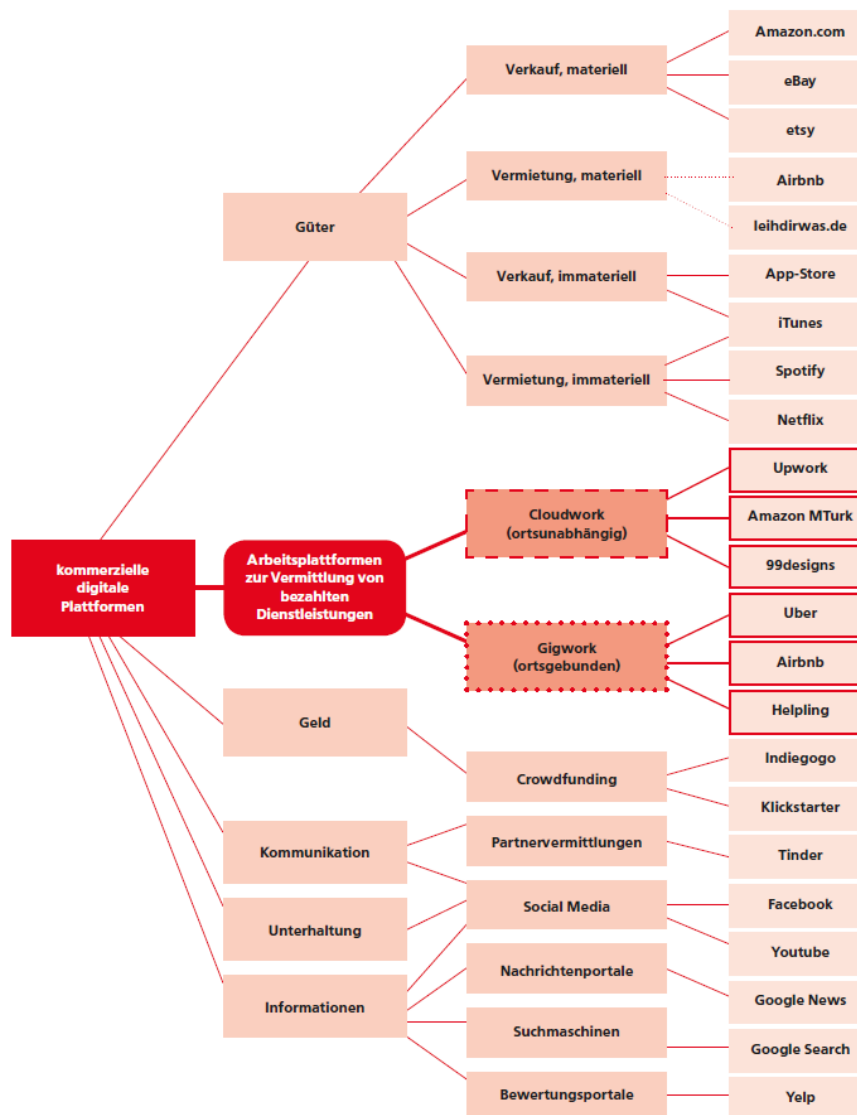
³ Die Autor:innen sprechen in den einzelnen Forschungsbeiträgen auch von Crowdwork (Huws et al. 2016) und Gig-Economy (Vallas und Schor 2020), was in dieser Arbeit unter On Demand Economy zusammengefasst wird.

⁴ Die in dieser Arbeit durchgeführte Analyse beschränkt sich auf Arbeitsplattformen. Diese arbeiten ausschließlich kommerziell, weshalb der Bereich der nichtkommerziellen Plattformen nicht weiter betrachtet wird.

sowohl den Kategorien *Kommunikation*, *Unterhaltung* als auch *Informationen* zurechnen.

Der Fokus dieser Arbeit liegt auf Ebene der Dienstleistungen. Diese Kategorie kann wiederum auch in zwei Unterkategorien unterteilt werden. Plattformen, bei denen die Dienstleistung vollständig digital geleistet wird, sind ortsunabhängig und werden fortan unter der Kategorie Cloudwork subsumiert. Beschränkt sich die Leistung der Plattform jedoch rein auf die Vermittlung und wird die Dienstleistung danach vor Ort ausgeführt, so handelt es sich um ortsabhängige Dienstleistungen, fortan Gigwork genannt. In dieser Arbeit werden diese beiden Formen zur Vermittlung bezahlter Dienstleistungen unter dem Begriff Arbeitsplattformen zusammengefasst.

Abbildung 1: Typisierung von kommerziellen digitalen Plattformen



Quelle: Schmidt (2016:6)

Eine zweite Ebene der Untergliederung von Cloud- und Gigwork ergibt sich über die Anzahl der Personen, die die Dienstleistung erbringen (vgl. Abbildung 2). Hierbei werden zwei Fälle unterschieden: Erstens wird die Dienstleistung nur von einem Individuum erbracht und dieses ist auch persönlich für die Ausführung verantwortlich. Oder zweitens wird der Auftrag an eine undefinierte Masse an Menschen (Crowd) vergeben und dem Auftraggebenden ist egal, wer genau die Aufgabe erledigt (Schmidt 2016:5). Dabei charakterisieren drei Kernprinzipien die Vergabe von Aufgaben an die Crowd: (1) Ein offener Aufruf zur Durchführung von Aufgaben, (2) die Selbstselektion der Auftragnehmenden und (3) die Interaktion über IT-gestützte Plattformen (Leimeister, Zogaj, et al. 2016:13 f.).

Der Bereich des Crowdwork bei den ortsunabhängigen Dienstleistungen (Cloudwork) wird in zwei weitere Felder untergliedert. Microtasking umfasst hierbei den Bereich, der durch die Aufteilung von Aufgaben in Kleinstaufgaben z. B. zu einem festen Stückpreis charakterisiert ist. Führen hingegen mehrere Auftragnehmende die Aufgabe gleichzeitig aus und wählt der Auftraggebende am Ende das für ihn beste Ergebnis und wird nur dieses entlohnt, handelt es sich um Kreativwettbewerbe (Schmidt 2016:5).

Plattformen, die ortsunabhängige Dienstleistungen an Individuen vermitteln, werden unter dem Begriff Freelancing-Marktplätze zusammengefasst. Diese Plattformkategorie stellt zugleich die am längsten existierende dar. Bereits 1999 wurde mit *Elance*⁵ die erste Plattform dieser Art gegründet (Schmidt 2016:14).

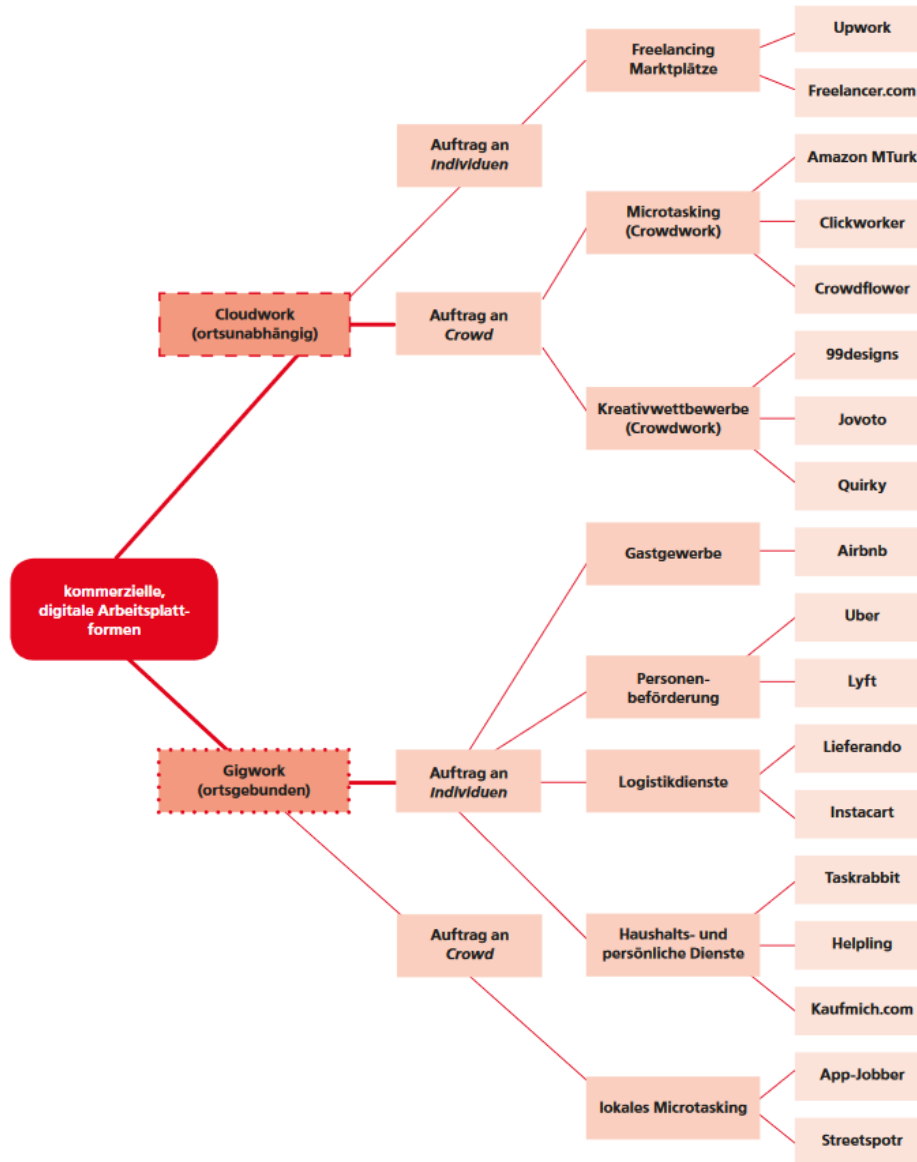
Dienstleistungen, die ortsgebunden über Plattformen vermittelt werden (Gigwork), sind erst durch die weite Verbreitung des Smartphones in der heutigen Form möglich, da hierdurch die Kontrolle der Arbeit abseits des Computers zu Hause gegeben ist (Schmidt 2016:19).

Der Bereich des ortsgebundenen Crowdworkings umfasst alle Plattformen, die lokales Microtasking betreiben. Es handelt sich also um Kleinstaufgaben, die an eine undefinierte Masse von Menschen vergeben werden, z. B. das Fotografieren von Warendisplays im Geschäft vor Ort (Schmidt 2016:16). Im Gegensatz zu den

⁵ Die Plattform *Elance* wurde 2013 durch eine Fusion mit der Plattform *o-Desk* zu *Elance-o-Desk* und 2015 zu *upwork* umbenannt.

anderen Formen des Gigwork ist ortsgebundenes Crowdworiking nicht zeit- und personengebunden und daher als eine Sonderform anzusehen (Schmidt 2016:16).

Abbildung 2: Typisierung von kommerziellen digitalen Arbeitsplattformen



Quelle: Schmidt (2016:7)

Erfolgt hingegen bei den ortsgebundenen Dienstleistungen die Vergabe an Individuen, lassen sich die Plattformen in vier verschiedene Bereiche einteilen: Gastgewerbe, Personenbeförderung, Logistikdienste sowie Haushalts- und persönliche Dienste. Insbesondere im Bereich Gastgewerbe (z. B. *Airbnb*), der Personenbeförderung (z. B. *Uber*) und den Haushalts- und persönlichen Diensten (z. B. *Taskrabbit*), erfolgt die Auswahl von Auftragnehmenden und -gebenden meist auf Basis der jeweiligen Profile. Bei Logistikdiensten ist ebenfalls nur eine Person

für die Durchführung beauftragt und verantwortlich, die Selektion durch den Auftraggebenden ist jedoch eher unüblich.

Nachdem nun für diese Arbeit geklärt ist, was unter der Plattformökonomie zu verstehen ist und durch welche Typisierung sie sich einteilen lässt, wird im folgenden Abschnitt betrachtet, welche Organisationsform die Plattformen bilden.

2.1.2 Organisationsform

Das Ausmaß, wie die Plattformökonomie Organisationen verändert, ist in der Literatur umstritten und es fehlt an organisationstheoretischer Fundierung. Ein Teil spricht von einer radikalen Transformation (Boes et al. 2015:80; Davis 2015), ein anderer, in Bezug auf die bisher überschaubare Verbreitung (vgl. Abschnitt 2.1.3), von einer begrenzten Transformation (Eichhorst et al. 2017:305 ff.; Kirchner 2019:5).

Der Begriff Plattform beschreibt dabei die gemeinsame Basis der doch heterogenen Landschaft in der Plattformökonomie (Schmidt 2016:9). Kenney und Zysman (2016:65) definieren das Wort wie folgt: „[...] “platform” simply points to a set of online digital arrangements whose algorithms serve to organize and structure economic and social activity.“.

Plattformen gibt es seit dem Beginn des Computerzeitalters (Dolata 2018:10). Damit sind auch die onlinebasierten Plattformen nicht vollkommen neu und bringen bisher auch keine massive disruptive Veränderung mit sich, wie sie in der Literatur manchmal mit Begriffen wie Plattform-Kapitalismus postuliert wird (Kenney und Zysman 2016; Langley und Leyshon 2017; Srnicek 2017; Staab 2016; Sundararajan 2017). Die sogenannte Plattformisierung lässt sich eher als eine sich über mehrere Jahrzehnte erstreckende soziotechnische Umbruchperiode charakterisieren, die durch säkulare „[...] anhaltend radikale Innovationsdynamiken, ungleichzeitige Verläufe und zahlreiche Transformationsschritte geprägt [...]“ ist (Dolata 2018:21). Vor allem haben Plattformen in der Vergangenheit durch die Nutzung von neuen Technologien eine Neujustierung und damit zu einem hohen Anpassungsdruck auf traditionelle Branchen und Märkte beigetragen (z. B. der Fahrdienstvermittler *Uber* auf das Taxigewerbe, *Airbnb* auf die Hotellerie- und Übernachtungsbranche und *Netflix* auf den Video-/DVD-Verleih). Dabei sind weder vollständig neue

Wirtschaftsbereiche noch fundamental unterschiedliche Geschäftsmodelle im Vergleich zu Beginn des Internetzeitalters entstanden (Dolata 2018:8 ff.).

Aus mikroökonomischer Sicht ist eine Plattform zunächst ein Intermediär auf einem zweiseitigen Markt (Rochet und Tirole 2003). Die Bedeutsamkeit der Plattformen steigt mit ihrer Zahl der Nutzenden (direkte Netzwerkeffekte). Steigt die Nutzung auf einer Seite des Marktes, so erhöht dies auch die Attraktivität für die andere Seite auf der Plattform aktiv zu werden (indirekte Netzwerkeffekte). Mit zunehmender Nutzendenzahl, wird es damit für andere ähnliche Angebote schwierig, mit der Plattform zu konkurrieren. Die Plattform als Intermediär verhält sich jedoch keineswegs als neutraler Vermittler, sondern bestimmt bspw. über Features, Bewertungssysteme oder die allgemeinen Geschäftsbedingungen (AGB) die wesentlichsten Rahmenbedingungen für die Akteure selbst (van Dijck 2013:29 ff.). Damit nehmen die Plattformen die Rolle von Marktbildnern und durch die aktive Steuerung des Marktes auch die eines Regulierers ein (Dolata 2018:7 f.). Diese aktive Rolle und die Kommerzialisierung der auf der Plattform entstehenden Daten macht die Plattform zu keinem neutralen Intermediär. Nach Dolata (2018:11) stellt dies den wesentlichen Unterschied zu früheren Plattformen dar.

In Bezug auf Arbeitsplattformen ordnet Kirchner (2019:6 ff.) die Plattformen als Hybrid zwischen Organisation und Markt ein. Einerseits stellen die Plattformen einen Marktplatz bereit, der dabei hilft, dass sich Angebot und Nachfrage finden und somit vorrangig Transaktionskosten reduziert. Andererseits greift die Plattform selbst als profitorientierter dritter Akteur in diesen Markt ein, indem sie mit ihrer „[...] Infrastruktur Transaktionen ermöglicht, garantiert und absichert, Zahlungen abwickelt und Systemvertrauen schafft.“ (Kirchner 2019:8) und im Gegenzug hierfür eine Provision erhält. In der Literatur wird die Architektur der Plattformen daher häufig auch als Dreiecksverhältnis beschrieben (Kirchner 2019:8; Schmidt 2016:9 ff.). Die Plattform organisiert dabei den Marktzugang für Anbietende und Nachfragende und agiert als Infrastruktur-Provider und Intermediär (Schmidt 2016:10). Anbietende stellen selbstständig und als Einzelpersonen ihre Arbeitskraft auf der Plattform zur Verfügung und Nachfragende suchen danach und bewerten nach Abschluss die Anbietenden. Die Nachfragenden werden also auch Teil der Wertschöpfungskette auf Plattformen (Bauer und Gegenhuber 2015; Kirchner 2019:8; Kleemann et al. 2008). Das Dreiecksverhältnis an sich ist nicht die

Neuerung der Plattformen, denn auch bei regulären Dienstleistungen formt sich ein Dreieck aus Betrieb, Mitarbeitenden und Kund:innen. Der Unterschied liegt im Verbleib der Risiken und Ressourcen der Leistungserbringung, die nicht die Plattform, sondern der Anbietende trägt. Daraus folgt, dass Plattformen die betriebliche Organisation auflösen und in eine Marktorganisation überführen, die ohne Beschäftigungsverhältnisse und betriebliche Regulierung auskommt (Kirchner 2019:8). Gleichzeitig bedienen Plattformen die fünf Elemente der Organisation (nach Ahrne et al. 2015): Mitgliedschaft (Accounts), Regeln (AGB, Weboberfläche, Algorithmen), Überwachung (Bewertungen, Tracking), Sanktionen (Ausschluss, Bewertungen) und Hierarchie (Marktorganisator) (Kirchner 2019:9 f.; Kirchner und Schüßler 2019) und lösen die drei Koordinationsprobleme bei der Organisation von Arbeit: Schwankung von Angebot und Nachfrage (z. B. über dynamische Preise, Prozessdaten), Verfügbarkeit erforderlicher Qualifikationen (z. B. über plattformeigene Zertifikate, Bewertungen), Bereitschaft zur Erstellung der Arbeitsleistung (z. B. über Tracking, Bewertungen, Gamification). Je nach Ausgestaltung der Plattformen sind sie daher näher an der Organisation oder am Markt anzusiedeln (Kirchner 2019:12 ff.).

Die zentrale Rolle der Plattform schafft eine Informations- und Machtasymmetrie. Sie kontrolliert über Algorithmen, Bewertungssysteme, die Weboberfläche, sowie über die von ihr einseitig festgelegten AGB das Marktgeschehen (Schmidt 2016:10). Sowohl der Auftragnehmende als auch der Auftraggebende ist diesen Rahmenbedingungen ausgesetzt, wobei letzterer noch Einfluss auf Auftragsausgestaltung, die Höhe der Bezahlung und die Abnahme des Arbeitsergebnisses nehmen kann. Die Auftragnehmenden hingegen befinden sich gegenüber der Plattform und den Auftraggebenden in einem doppelten Abhängigkeitsverhältnis (Greef et al. 2017:17 f.).

Aufgrund der spezifischen Organisationsform der Plattformen und der Risiken und Ressourcenübertragung auf Anbietende und Nachfragende, ist es der Plattform möglich, exponentiell zu wachsen, ohne im gleichen Maße Mitarbeitende oder Kapital einsetzen zu müssen (Schmidt 2016:10). Die direkten und indirekten Netzwerkeffekte führen dazu, dass Plattformmärkte zur Bildung von Oligopsonen oder Monopsonen neigen (Dube et al. 2020).

Der nächste Abschnitt zeigt auf, wie viele Auftragnehmende und Auftraggebende die Plattformökonomie nutzen und gibt damit einen Eindruck zur Relevanz der Plattformökonomie. Um die Dynamik des Marktes abschätzen zu können, wird weiter die Entwicklung der Nutzendenzahlen der letzten Jahre dargestellt.

2.1.3 Größe, Verbreitung und Entwicklung

Die Bestimmung der Relevanz der Plattformökonomie ist aufgrund der fehlenden zentralen Erfassung bspw. in amtlichen Statistiken schwierig. Hinzu kommt, dass der Plattformmarkt sich ständig wandelt. Neue Plattformen entstehen und bestehende Plattformen verschwinden vom Markt. Aufgrund dieser hohen Dynamik ist es schwierig, die Anzahl aktiver Plattformen weltweit abzuschätzen. Das International Labour Office (ILO) (2021:46) geht in ihrem Bericht von 777 aktiven Plattformen im Jahr 2020 aus.⁶ Ebenfalls schwierig abzuschätzen, ist die Anzahl der Personen, die diese nutzen. In der Literatur findet sich ein Strang, der über verschiedene Ansätze versucht, diese Nutzendenzahlen zumindest näherungsweise zu bestimmen.

Ein Ansatz ist, die Anzahl derjenigen festzustellen, die auf ihr aktiv sind. Hierzu greift die Literatur auf unterschiedlichste Datenquellen zurück. Für die USA finden Katz und Krueger (2019:382 f.) für das Jahr 2015 heraus, dass 0,5 Prozent der amerikanischen Beschäftigten über Plattformen arbeitet. Sie stützen sich dabei auf repräsentative Umfragedaten. Damit liegt der Wert relativ nahe an anderen Studien, die den Anteil z. B. auf Basis von Google Trends Daten auf 0,4 Prozent (Harris und Krueger 2015:12) oder Bankkontodaten von JPMorgan auf 0,4 bis 0,6 Prozent (Farrell und Greig 2016:36) geschätzt haben.

Huws et al. (2016:22 f.) finden in einer für die Gesamtbevölkerung der jeweiligen Länder repräsentativen Omnibusbefragung heraus, dass die Partizipation auf digitalen Arbeitsplattformen zur Einkommensgenerierung in den Niederlanden bei 9 Prozent, Österreich bei 19 Prozent, Deutschland bei 12 Prozent, Schweden bei 10 Prozent und im Vereinigten Königreich bei 9 Prozent liegt. Bonin und Rinne (2017:17) halten diese hohen Werte eher für überzeichnet und verweisen auf vielfältige Probleme bei der Erfassung von Plattformarbeit, die sich in ihrer Umfrage

⁶ Die Autor:innen merken dazu an, dass die Daten keinen Anspruch auf Vollständigkeit haben und insbesondere Plattformen aus Entwicklungsländern womöglich untererfasst sind (International Labour Organization 2021:46).

zeigen (Bonin und Rinne 2017:9 f.). Korrigiert um offensichtliche Fehleinschätzungen der Befragten, kommen die Autor:innen für Deutschland im Rahmen einer repräsentativen Omnibusbefragung auf einen Wert von 0,6 Prozent der Gesamtbevölkerung, die einer Plattformarbeit im Jahr 2017 nachgeht (Bonin und Rinne 2017:11).

Weitere Befragungen für Deutschland werden im Rahmen des Projekts des Crowdfunding-Monitors durchgeführt (Serfling 2018, 2019). Die Civey-Umfrage⁷ ist dabei repräsentativ für Internetnutzende in Deutschland. Im letzten Erhebungszeitraum für die Jahre 2017 und 2018 sind 6,9 Prozent der Befragten auf einer Plattform aktiv oder waren es in der Vergangenheit. Betrachten die Autor:innen nur jene, die auch mindestens einmal eine Zahlung erhalten haben und auf den Plattformen zur Einkommensgenerierung aktiv sind, so fällt der Anteil auf 2,3 Prozent und liegt dabei noch deutlich höher als der von Bonin und Rinne errechnete Wert (Serfling 2019:12). Hierbei ist jedoch zu beachten, dass sich unter den Internetnutzenden mehr junge Leute befinden, die mutmaßlich auch neuen digitalen Arbeitsformen aufgeschlossener gegenüberstehen und dadurch der Wert höher ausfällt als bei Bonin und Rinne, die die Gesamtbevölkerung als Grundlage heranziehen.

Ohnemus et al. (2016) gehen der Frage nach, wie intensiv Arbeitsplattformen⁸ bereits durch Unternehmen genutzt werden und haben dazu Unternehmen aus unterschiedlichen Branchen befragt. Wie zu erwarten, finden die Autor:innen heraus, dass die Nutzung von Plattformarbeit im Jahr 2017 in der Informationswirtschaft mit 3,2 Prozent deutlich stärker verbreitet ist als im verarbeitenden Gewerbe mit 1,2 Prozent und dass in der Informationswirtschaft Plattformarbeit primär unter kleinen Unternehmen (5–19 Mitarbeitende) und großen Unternehmen (>100 Mitarbeitende) verbreitet ist. Insgesamt zeigt sich jedoch noch eine geringe Verbreitung der Plattformarbeit unter den Unternehmen (Ohnemus et

⁷ Bei Civey handelt es sich um ein Markt- und Meinungsforschungsunternehmen, das onlinebasierte Befragungen auf verschiedensten Portalen wie z. B. populären Presseseiten in Echtzeit durchführt. Methodische Details zur Erhebungsmethode können dem Whitepaper des Unternehmens entnommen werden (Richter et al. 2022).

⁸ Die Autor:innen nutzen den Begriff des Crowdfworkings, ohne diesen vorher zu definieren. Grob wird von Onlineplattformen ausgegangen, die Aufgabe und Projekte an externe Arbeitskräfte vergeben, die diese gegen Bezahlung ausführen (Ohnemus et al. 2016:3). Dies geht gemäß der Abgrenzung dieser Arbeit über das Crowdfunding hinaus, weshalb der Begriff Arbeitsplattformen hier genutzt wird.

al. 2016:6 ff.). Neuere Zahlen von Erdsiek (2021:913) zeigen einen sprunghaften Anstieg der Nutzung von Crowdfunding Plattformen durch Unternehmen sowohl in der Informationswirtschaft (+6 Prozentpunkte) als auch im verarbeitenden Gewerbe (+4,1 Prozentpunkte). Die Erhebung erfolgt im September 2020 und geht zum Teil auch auf die COVID-19-Pandemie und den damit einhergehenden höheren Bedarf an IT-Spezialist:innen zurück (Erdsiek 2021:913).

Auf europäischer Ebene wird im Rahmen des Projekts Collaborative Economy (COLLEEM) die Verbreitung von Arbeitsplattformen durch eine großangelegte Befragung in 16 Ländern genauer untersucht (Pesole et al. 2018; Urzi Brancati et al. 2020). Insgesamt zeigt sich, dass der Anteil jener Personen, die mindestens einmal über eine Plattform arbeiteten, von 2017 auf 2018 um 1,5 Prozentpunkte auf 11 Prozent der Erwerbsbevölkerung angestiegen ist. Besonders stark ist der Zuwachs in Spanien und den Niederlanden. In Italien und der Slowakei kommt es zu einem Rückgang (Urzi Brancati et al. 2020:14 ff.). Da die Definition sehr breit gefasst ist und auch solche Personen einbezieht, die nur einmalig aktiv sind, haben die Verfasser:innen die Antworten in Kategorien in Abhängigkeit ihrer Aktivität und dem Anteil am Gesamteinkommen eingeteilt. Hierbei zeigt sich, dass Plattformarbeit zwischen den beiden Befragungszeiträumen leicht zugenommen hat. Der Anteil jener Personen, die mehr als 50 Prozent ihres Einkommens und mindestens zehn Stunden pro Woche auf der Plattform arbeiten, liegt 2018 bei 1,4 Prozent der Erwerbsbevölkerung der 16 Länder (Urzi Brancati et al. 2020:17).

Einige weitere Studien stützen sich zur Abschätzung der Relevanz der Plattformökonomie auf die von den Plattformen bereitgestellten Nutzendenzahlen. Codagnone et al. (2016:22 f.) kommt über die Recherche dieser Zahlen bei den Plattformen selbst und anderen Studien für 41 Plattformen auf weltweit 52,6 Mio. registrierte Nutzende. Die OECD (2016:11 ff.) stellt die Umsatz- und Nutzendenzahlen einzelner Plattformen wie *Airbnb*, *Uber*, *Upwork* und *Freelancer* dar, um einen Eindruck zur Größe der Plattformökonomie zu gewinnen. Mit der Nutzung dieser Zahlen zur Einschätzung der Plattformökonomie als Ganzes gehen mehrere Limitationen einher. Eine Auswahl einzelner Plattformen wird, nicht zuletzt aufgrund der hohen Dynamik des Marktes, nie vollständig sein und damit wird es nicht gelingen, den gesamten Plattformmarkt abzudecken. Weiter muss bei den von den Plattformen selbstberichteten Nutzendenzahlen berücksichtigt werden, dass

diese gerade auch für Investoren und zu Marketingzwecken dienen und eher davon auszugehen ist, dass diese überschätzt dargestellt werden (Schmidt 2016:14). Nicht zuletzt lässt sich von den reinen Nutzendenzahlen nicht auf das realisierte Transaktions- oder Beschäftigungsvolumen schließen (Bonin und Rinne 2017:19). Studien haben gezeigt, dass große Teile der registrierten Nutzenden inaktiv sind und keine größeren Einkünfte generieren, was ebenfalls zu einer Überschätzung beiträgt (De Groen et al. 2016; Gheorghe 2015; Maier und Viete 2017:18).

Auch wenn der Anteil der Bevölkerung, die über die Plattformen arbeitet, noch im niedrigen einstelligen Prozentbereich liegt, ist es zur Beurteilung der Relevanz der Plattformökonomie wichtig, das bisherige Wachstum dieses Marktes zu betrachten. Einzelne Plattformen haben in der Vergangenheit ein sehr dynamisches bis exponentielles Wachstum bei den registrierten Auftragnehmenden und -gebenden verzeichnet (Agrawal et al. 2015:223 ff.; Codagnone et al. 2016:24; Hall und Krueger 2018:13). Über Web-Scraping Daten der größten englisch-, spanisch- und russischsprachigen Freelancing-Marktplätze und Microtask Plattformen, haben Forscher des iLabour Projekts der Universität Oxford den Online Labour Index (OLI) berechnet (Kässi und Lehdonvirta 2018; Stephany et al. 2021). Dieser misst sämtliche auf den Plattformen eingestellte Aufträge in Echtzeit und gibt Informationen zu den Tätigkeitskategorien, Herkunftsländern und dem Geschlecht der Auftragnehmenden. Bis Dezember 2022 hat sich der Index seit seinem Basiszeitpunkt (30.05.2016) um mehr als 40 Prozent erhöht. Weiter zeigt eine Auswertung des Indexes, dass während der COVID-19 Pandemie die Zahl der Auftragnehmenden, insbesondere aus den USA, auf den Plattformen deutlich angestiegen ist (Stephany et al. 2020:568). Insgesamt hat die Pandemie die Aktivität in der Plattformökonomie auf ein höheres Niveau gehoben (Erdsiek 2021:913; Hildenbrand et al. 2021:7 ff.).

Zusammenfassend kann festgehalten werden, dass die Plattformökonomie als Ganzes eine weite Verbreitung genießt. Wird der Fokus auf die On Demand Economy und die Arbeitsplattformen im Speziellen beschränkt, fallen die Anteile an der Erwerbs- oder Gesamtbevölkerung geringer aus. Neuere Daten zur Einschätzung der Verbreitung liegen nicht vor. Dennoch hat sich in der Vergangenheit gezeigt, dass es sich hierbei um einen sehr dynamischen Markt mit hohen Wachstumsraten handelt. Nicht zuletzt durch den Trend zur

Erwerbshybridisierung (Bührmann et al. 2018) und dem zunehmenden Arbeiten von zu Hause, dürfte diese Arbeitsform Beschäftigten immer attraktiver erscheinen, weshalb von einer weiter steigenden Relevanz in der Zukunft ausgegangen werden kann.

2.1.4 Erwerbstätigenstruktur

Um die Forschungsfrage in Bezug auf die Plattformökonomie analysieren zu können, ist es zunächst wichtig zu wissen, wer auf den Plattformen aktiv ist und welche Charakteristika diese Personen aufweisen. Ein besonderes Augenmerk wird dabei auf das Geschlecht gelegt und die Ergebnisse, soweit möglich, dahin gehend getrennt betrachtet.

2.1.4.1 Geschlechterverhältnisse

Die Vorteile der Plattformökonomie, wie eine hohe zeitliche und räumliche Flexibilität, bietet gerade Frauen die Chance, am Erwerbsleben zu partizipieren (Hensel 2020:25 ff.). Dementsprechend wäre zu erwarten, dass sich für die Plattformökonomie höhere Frauenanteile im Vergleich zum klassischen Arbeitsmarkt feststellen lassen. Im Folgenden werden dazu die empirisch ermittelten Geschlechteranteile der betrachteten Studien auf den Plattformen mit den Frauenanteilen der Erwerbsbevölkerung (E) der jeweiligen Länder verglichen.⁹ Diese können, bspw. aufgrund von kulturellen oder religiösen Unterschieden zwischen den Ländern, erheblich schwanken. Da die Plattformökonomie auch als Möglichkeit für Zuverdienste genutzt wird (vgl. Abschnitt 2.1.4.7), ist davon auszugehen, dass auch nichterwerbstätige Personen auf den Plattformen aktiv sind. Als Annäherung werden daher zusätzlich noch die Frauenanteile der Gesamtbevölkerung (G) der Länder angegeben. Diese Gegenüberstellung wird in bisherigen Studien kaum berücksichtigt. Jedoch lässt sich erst dadurch beurteilen, ob die Plattformökonomie zu einer höheren Erwerbsbeteiligung von Frauen beitragen kann oder nicht.

⁹ Hierzu wird auf Umfragedaten der International Labour Organization (ILO) für das Jahr 2021 zurückgegriffen, die jeweils in Klammern im Text dargestellt werden. Auch wenn Plattformarbeitende grundsätzlich zur Erwerbsbevölkerung zählen und damit wiederum in der Statistik erfasst sein dürften, ist aufgrund der noch geringen Verbreitung davon auszugehen, dass dadurch die aggregierten Statistiken nicht wesentlich beeinflusst werden und daher als Vergleichsgröße herangezogen werden können (Weltbank 2022b, 2022a).

Europaweit¹⁰ sind Plattformarbeitende im Jahr 2018 zu ca. 35 Prozent weiblich (E 46 %; G 51 %). Zwischen 2017 und 2018 hat sich laut der COLLEEM Umfrage der Anteil insbesondere junger Frauen (<35 Jahre) stärker erhöht als der junger Männer, d. h. die Männerdominanz ist rückläufig (Urzi Brancati et al. 2020:21 f.). Zurückzuführen ist das hauptsächlich auf das stärkere Wachstum von frauentypischen Tätigkeitskategorien, z. B. von Übersetzungsdienstleistungen auf den Plattformen (Pesole et al. 2018:39; Urzi Brancati et al. 2020:30). Ähnliche Werte finden auch Huws et al. (2016:29 f.). Nur im Vereinigten Königreich ist das Geschlechterverhältnis mit 48 Prozent Frauen nahezu ausgeglichen (E 47 %, G 51 %). Für Deutschland dokumentieren Leimeister et al. (2016:4) ebenfalls einen niedrigeren Frauenanteil von 44 Prozent (E 47 %, G 51 %). Dieses Ergebnis bestätigen auch andere Untersuchungen für Deutschland (Baethge et al. 2019:16; Bertschek et al. 2016:20; Giard et al. 2021:19; Serfling 2019:17).

Unterschiede werden hingegen bei der differenzierten Analyse nach Plattfortmtypen deutlich. So zeigen Kuek et al. (2015:31), dass auf dem Freelancing-Marktplatz *Elnance* rund 42 Prozent weiblich sind. Für den Bereich der Haushalts- und persönlichen Dienste finden De Groen et al. (2016:5) hingegen auf einer belgischen Plattform einen Frauenanteil von 62 Prozent, der bei Betrachtung derjenigen, die bereits Einkünfte über die Plattform generiert haben, auf 38 Prozent fällt. Für den Kreativwettbewerb *jovoto* lässt sich ein nahezu ausgeglichenes Geschlechterverhältnis feststellen (Al-Ani und Stumpp 2015:18). Erste Studien im Bereich des Microtaskings zeigen sehr hohe Frauenquoten von ca. 70 Prozent. Zugleich ergeben sich große Unterschiede in Abhängigkeit des Herkunftslandes. So sind bspw. 2010 zwar 70 Prozent der Arbeitenden aus den USA auf *AMT* weiblich (E 46 %, G 51 %), aber nur 30 Prozent der Arbeitenden aus Indien (E 20 %, G 48 %) (Ipeirotis 2010b:3). Auch wenn sich die Geschlechterverhältnisse im Zeitverlauf angeglichen haben (Ross et al. 2010:2866), zeigen aktuellere Daten erhebliche Geschlechterdifferenzen auf *AMT*. Für die USA (55 %) (E 46 %, G 51 %) und die Philippinen (~52 %) (E 39 %, G 50 %) finden Difallah et al. (2018:137) einen höheren Frauenanteil, alle anderen Länder weisen höhere Männeranteile auf. Für

¹⁰ Europaweit bezieht sich hierbei auf die 16 untersuchten Länder von Urzi Brancati et al. (2020).

Deutschland ermitteln Giard et al. (2021:19) im Microtasking ein ausgeglichenes Geschlechterverhältnis.

Stephany et al. (2021:6) finden eine erhebliche Variation in den Geschlechteranteilen in Abhängigkeit der Tätigkeitskategorie. Frauendominiert sind demnach vorwiegend Schreib- und Übersetzungstätigkeiten. Männerdominiert hingegen Tätigkeiten aus dem Bereich Software und Technologie sowie Sales und Marketing. Weiter sind Plattformen, die lokale Haushalts- und persönliche Dienste vermitteln, frauendominiert und bei Kreativwettbewerben herrscht ein nahezu ausgeglichenes Verhältnis. Diese Segregation zeigt sich länderübergreifend. Bei der Aktivität der Plattformarbeitenden hingegen lassen sich, differenziert nach dem Geschlecht, kaum Unterschiede feststellen (Huws et al. 2016:29 f.).

Zusammenfassend zeigt sich, dass die grundsätzlich höhere Erwerbsbeteiligung auf dem klassischen Arbeitsmarkt von Männern sich auch in der Plattformökonomie widerspiegelt. Europaweit sind Frauen in der Plattformökonomie im Vergleich zum klassischen Arbeitsmarkt unterrepräsentiert. Für das Vereinigte Königreich und Deutschland liegen die Frauenanteile näher an denen des klassischen Arbeitsmarkts. Die USA und die Philippinen weisen auf *AMT* leicht höhere Frauenanteile auf der Plattform im Vergleich zur Erwerbs- und Gesamtbevölkerung auf. In Indien sind Frauen im Vergleich zur Erwerbsbevölkerung auf Plattformen ebenfalls überrepräsentiert. Dies deutet daraufhin, dass kurzweilige Aufträge mit geringen Anforderungen Frauen die Chance bieten, über Plattformen erwerbstätig zu werden. In einer qualitativen Befragung geben Plattformarbeitende an, dass Plattformarbeit die (einzige) Möglichkeit bietet, auch neben Sorgeverpflichtungen, z. B. für kleine Kinder, erwerbstätig zu sein (Berg 2016:7 ff.). Dies dürfte mehrheitlich auf Frauen zutreffen.

2.1.4.2 Herkunftsland

Gemäß dem *Online Labour Index* (OLI), der sowohl Freelancing-Marktplätze als auch Microtasking erfasst, lässt sich bei der Betrachtung von Angebot und Nachfrage auf den Plattformen ein Gefälle zwischen entwickelten und nichtentwickelten Ländern feststellen. Zu den drei häufigsten Herkunftsländern¹¹

¹¹ Die Daten wurden auf der Internetseite des *Online Labour Observatory* am 20.12.2022 um 15:48 Uhr abgerufen (Online Labour Observatory 2022; Stephany et al. 2021).

der Plattformarbeitenden gehören Indien (28 %), Bangladesch (14 %) und Pakistan (12 %). Mit größerem Abstand folgen dann erst Länder wie die USA (6 %) und das Vereinigte Königreich (4 %). Die Nachfrageseite wird von Auftraggebern aus den USA (42 %) dominiert. Dann folgen das Vereinigte Königreich (8 %), Indien (6 %), Kanada (6 %) und Australien (6 %). Beide Ergebnisse decken sich mit bisherigen Ergebnissen zu IT Freelancing auf *Elance* (Gheorghe 2015:1476) und für den Freelancing-Marktplatz *oDesk* (Agrawal et al. 2015:220 ff.). Studien, die sich auf die Microtasking Plattform *AMT* beschränken, zeigen ein anderes Bild. Auf *AMT* stellen die USA und Indien mit über 90 Prozent den größten Anteil an Plattformarbeitenden (Difallah et al. 2018:137). Der Grund hierfür liegt darin, dass die Plattform zu Beginn nur Zahlungen an Bankkonten aus den USA vorgenommen hat. Erst später wurden Auszahlungen auch an Bankkonten anderer Länder ermöglicht, was die Länderverteilung dann nicht mehr grundsätzlich verändert hat (Ipeirotis 2010b; Ross et al. 2010).

Im Hinblick auf die hohen Anteile von Auftragnehmenden aus Entwicklungsländern und der gleichzeitigen Überrepräsentation von Frauen auf Plattformen in diesen Ländern besteht die Chance, dass eine nicht unerhebliche Anzahl an Frauen den Weg über die Plattformen in die Erwerbstätigkeit finden.

2.1.4.3 Altersverteilung

Im Rahmen der COLLEEM Befragung hat sich gezeigt, dass Plattformarbeitende mit durchschnittlich 34 Jahren jünger sind als Befragte des klassischen Arbeitsmarkts (43 Jahre). Die Verteilung der Plattformarbeitenden ist rechtsschief (Median < Mittelwert) und unterscheidet sich damit deutlich von der eher symmetrischen Altersverteilung der restlichen Erwerbsbevölkerung. Weiter finden die Autor:innen nur geringfügige Unterschiede in Abhängigkeit des Aktivitätsniveaus. In Kombination mit dem Geschlecht zeigt sich in der Umfrage, dass es ein größeres Altersgefälle bei Frauen gibt als bei Männern. Rund 23 Prozent der Plattformarbeitenden im Haupterwerb sind weiblich und unter 35 Jahre alt, wohingegen nur 12 Prozent weiblich und über 35 Jahre alt sind. Bei Männern liegen diese Werte bei 37 Prozent unter 35 Jahren und 28 Prozent über 35 Jahren (Urzi Brancati et al. 2020:20 f.). Plattformarbeit scheint demnach bei Frauen primär in jüngeren Altersjahren genutzt zu werden.

Die grundsätzliche Überrepräsentation von jungen Plattformarbeitenden (<35 Jahren) im Vergleich zur Altersverteilung der erwerbsfähigen Bevölkerung bestätigt sich auch bei Huws et al. (2016:36 ff.). Jedoch finden sich auch bedeutende Anteile bei älteren Jahrgängen, bspw. für die Kategorie 55 Jahre oder älter von 11 Prozent in Schweden und 17 Prozent in den Niederlanden (Huws et al. 2016:37). In Deutschland sind, laut Befragung des Crowdfunding Monitors, rund 20 Prozent der aktiven Plattformarbeitenden zwischen 22 und 29 Jahren alt (Serfling 2019:17).

Nach Plattformtypen differenziert, finden Leimeister et al. (2016:32) eine hohe Heterogenität. Arbeitende auf Microtasking Plattformen sind durchschnittlich 29 Jahre alt, auf Freelancing-Marktplätzen hingegen 37 Jahre. Die Unterschiede im Durchschnittsalter in Abhängigkeit der Plattformkategorien zeigen sich auch in der Studie von Baethge et al. (2019:16), in der das Durchschnittsalter der Befragten mit 41 Jahren relativ hoch ausfällt. Dies dürfte maßgeblich mit der breiten Definition von Plattformökonomie zusammenhängen, die die Autor:innen nutzen. Neben Arbeitsplattformen berücksichtigen sie auch Plattformen aus dem Gastgewerbe (*Airbnb*) und Personenbeförderung (*Uber*). Dahingegen sind fast 70 Prozent der Plattformarbeitenden auf *Listminut.be*, eine Plattform für Haushalts- und persönliche Dienste, unter 30 Jahre alt (De Groen et al. 2016:5). Al-Ani und Stumpff (2015:18) wiederum stellen für den Kreativwettbewerb *javoto* ein ausgeglicheneres Altersverhältnis mit jeweils rund 40 Prozent unter 35 Jahren und zwischen 35 und 49 Jahren fest. Ebenso homogener zeigt sich die Altersverteilung auf *Elance* (Kuek et al. 2015:31 f.). Die jüngeren Plattformarbeitenden scheinen gerade im Bereich des Microtaskings zu finden zu sein. Der hohe Anteil junger Plattformarbeitenden von Leimeister et al. (2016:32) bestätigt sich auch in der Umfrage von Giard et al. (2021:20) und Bertschek et al. (2016:20). Letztere Autor:innen dokumentieren auf Basis zweier deutscher Microtasking Plattformen, dass über 60 Prozent der Plattformarbeitenden unter 30 Jahre alt ist. Auf *AMT* sind die jungen Altersklassen ebenfalls deutlich überrepräsentiert (Berg 2016:5 f.; Difallah et al. 2018:137; Ipeirotis 2010b:4; Ross et al. 2010:2866). Das Durchschnittsalter unter indischen *AMT* Plattformarbeitenden liegt nach Ross et al. (2010:2866) um die 26–28 Jahre und das der amerikanischen um 33–35 Jahre.

Zusammenfassend zeigt sich, dass Plattformarbeitende tendenziell jünger sind als die Erwerbsbevölkerung. Differenziert nach dem Geschlecht zeigen erste

Ergebnisse, dass der Anteil junger Frauen an allen Frauen deutlich höher ist als bei Männern. Grundsätzliche Altersunterschiede zeigen sich in Abhängigkeit der Plattformtypen. Auf Kreativwettbewerben und Freelancing-Marktplätzen liegt das Alter höher als auf Microtask Plattformen.

2.1.4.4 Bildungsstand

Plattformarbeitende sind nach der COLLEEM Umfrage höher gebildet als die durchschnittliche Erwerbsbevölkerung. Fast die Hälfte der Befragten weist eine tertiäre Bildung¹² auf und Arbeitende, die auf der Plattform sehr aktiv sind, weisen höhere Bildungsniveaus auf (Urzi Brancati et al. 2020:25 f.). Serfling (2019:19 f.) hingegen kommt zum Schluss, dass Plattformarbeitende in Deutschland keine höhere Bildung als die Gesamtbevölkerung aufweisen. Baethge (2019:16 f.) widerspricht dem und findet für Onlinearbeitende, dass 73 Prozent Abitur und 57 Prozent einen Hochschulabschluss haben. Dies liegt deutlich über dem Anteil der Personen mit Hochschulabschluss von 18,5 Prozent in Deutschland (Statistisches Bundesamt 2022a). Zu einem ähnlichen Ergebnis kommen auch Leimeister et al. (2016:35). Die Autor:innen weisen aber auch hier auf die Unterschiede zwischen den Plattformtypen hin. So finden sich auf Microtasking Plattformen 31 Prozent, die sich noch in einer beruflichen Ausbildung befinden, wohingegen z. B. auf Freelancing-Marktplätzen dieser Wert bei nur 8 Prozent liegt. Hochqualifizierte finden sich laut den Autor:innen hauptsächlich auf Freelancing- und Kreativmarktplätzen. Diese Diskrepanz bestätigen auch Kuek et al. (2015:32 f.) und Al-Ani und Stumpp (2015:19). Bertschek et al. (2016:23) hingegen findet auch unter den deutschen Microtaskingplattformen 41 Prozent Plattformarbeitende, die einen Hochschulabschluss haben.

Auf der Microtaskingplattform *AMT* hingegen zeigt sich ein anderes Bild. Für die USA und Indien lässt sich ein höheres Bildungsniveau unter den Plattformarbeitenden feststellen. Ipeirotis (2010b:4 f.) führt dies auf die junge Altersstruktur zurück, mit der ein höheres Bildungsniveau einhergeht. Vor allem indische Microtasker:innen auf *AMT* weisen zu über 90 Prozent eine

¹² Die Autor:innen beziehen sich dabei auf die Bildungsniveaus 5-8 der International Standard Classification of Education (ISCED) 2011 der UNESCO.

Hochschulausbildung auf. Ihre amerikanischen Kolleg:innen kommen nur auf gut 45 Prozent (Berg 2016:6).

Insgesamt zeigt sich, dass die Plattformarbeitenden gut ausgebildete Arbeitskräfte sind, wobei das Bildungsniveau zwischen den Plattformentypen schwankt. Auf Freelancing-Marktplätzen scheinen Höherqualifizierte häufiger vertreten zu sein als auf Microtasking Plattformen. Letztlich passt dies auch zu den Aufgaben, die auf solchen Plattformen bearbeitet werden. Im Bereich des Microtaskings handelt es sich meist um sehr granulare Aufgaben mit geringer Komplexität, die ohne besondere Vorkenntnisse erledigt werden können (Leimeister, Durward, et al. 2016:37). Im Vergleich sind auf Freelancing-Marktplätzen die Aufgaben komplex und hochspezialisiert und erfordern mehr Vorkenntnisse, die sich in höheren Bildungsniveaus widerspiegeln (Schmidt 2016:14).

2.1.4.5 Familienstand und Haushalt

Laut dem Crowdfunding Monitor sind aktive Plattformarbeitende rund 5 Prozentpunkte häufiger alleinlebend als Arbeitende des klassischen Arbeitsmarkts. Weiter sind sie 6 Prozentpunkte weniger häufig verheiratet oder fast 4 Prozentpunkte weniger häufig geschieden (Serfling 2019:18 f.). In der Befragung von Leimeister et al. (2016:33) geben 53 Prozent an, ledig zu sein. Hierzu abweichend gaben im Befragungssample von Baethge et al. (2019:16) nur 22 Prozent an, Single zu sein und 44 Prozent gaben an, verheiratet zu sein, was wiederum mit der breiten Betrachtung der Plattformökonomie zusammenhängen könnte. Differenziert nach den Plattformentypen zeigt sich ein höherer Anteil an ledigen Plattformarbeitenden auf Kreativwettbewerben (72 %) und Microtask Plattformen (64 % (Leimeister, Durward, et al. 2016:34) und 76 % (Bertschek et al. 2016:21)). Bezogen auf *AMT* zeigt der *MTurk-Tracker*¹³ hingegen große Anteile von verheirateten Plattformarbeitenden (70–80 %).

In Bezug zur Haushaltsgröße leben Plattformarbeitende im Vergleich zu Arbeitenden des klassischen Arbeitsmarkts häufiger in Haushalten mit drei oder mehr Personen. Zugleich tragen Sie häufiger die Verantwortung für Kinder im Haushalt. Der größte Unterschied zeigt sich diesbezüglich bei jungen Paaren unter

¹³ Der *MTurk-Tracker* zeigt in Echtzeit die Aktivität auf *AMT* an und stellt dabei auch detaillierte soziodemografische Informationen bereit (Difallah et al. 2018).

35 Jahren. Ältere Paare über 35 Jahre mit Kindern sind leicht unterrepräsentiert in der Plattformwelt (Urzi Brancati et al. 2020:22 ff.). Auf deutschen Microtask Plattformen geben 26 Prozent an, in einem Haushalt mit Kindern zu leben (Bertschek et al. 2016:21). Für *AMT* zeigt sich, dass sich im Gegensatz zu amerikanischen, indische Plattformarbeitenden in Haushalten mit drei oder mehr Mitgliedern aufhalten, was laut den Autor:innen kulturell bedingt ist und nicht zwingend auf Kinder hindeuten muss. Unter den verheirateten Plattformarbeitenden haben die meisten auch Kinder (Ipeirotis 2010b:6 f.).

Das gesamte Haushaltseinkommen ist für deutsche Plattformarbeitende recht homogen auf die drei von Bertschek et al. (2016:26) festgelegten Intervalle (< 1.500 EUR, 1.500-3.000 EUR, > 3.000 EUR) verteilt. Wobei das persönliche monatliche Nettoeinkommen der befragten Plattformarbeitenden zu 78 Prozent im untersten Intervall < 1.500 EUR liegt. Damit tragen Plattformarbeitende den kleineren Teil zum Haushaltseinkommen bei. Dies begründet sich hauptsächlich über den hohen Anteil jener, die sich in schulischer oder beruflicher Ausbildung befinden (Bertschek et al. 2016:5). Verglichen mit der US-Bevölkerung finden Difallah et al. (2018:138) geringere Haushaltseinkommen unter den Plattformarbeitenden. Ross et al. (2010:2866 f.) dokumentieren, dass die meisten Arbeitenden auf *AMT* mit 32 Prozent im November 2009 ein Haushaltseinkommen von unter 10.000 USD aufweisen. Dies lässt sich hauptsächlich auf die indischen Arbeitenden zurückführen, die mit 64 Prozent in dieser Kategorie vertreten sind. Zum Vergleich: Bei den amerikanischen Plattformarbeitenden auf *AMT* macht dieser Anteil nur 10 Prozent aus. Maßgeblich für diesen Unterschied sind die Differenzen in den Lebenshaltungskosten zwischen den Ländern, die es den indischen Plattformarbeitenden ermöglicht, mit relativ wenig Geld auszukommen (Ross et al. 2010:2867). Interessanterweise fallen 23 Prozent der befragten amerikanischen Arbeitenden auf *AMT* in die höchste Haushaltseinkommensklasse mit >70.000 USD. Auf dem Kreativwettbewerb *jovoto* ordnen sich hingegen die befragten Plattformarbeitenden zu über 50 Prozent im niedrigen Haushaltseinkommenssegment von weniger als 1.500 EUR ein (Al-Ani und Stumpff 2015:20).

Je nach Befragung zeigen sich unterschiedliche Ergebnisse bzgl. des Familienstands der Plattformarbeitenden. Internationale Unterschiede lassen sich

hinsichtlich der Haushaltsgröße feststellen. Diese spiegeln die unterschiedlichen kulturellen Normen der Herkunftsländer von Plattformarbeitenden wider (vgl. Abschnitt 2.1.4.2). Das Haushaltseinkommen der Plattformarbeitenden ist in Deutschland und den USA relativ homogen über die Einkommensintervalle verteilt. International zeigen sich aber auch hier die Länderunterschiede und unterschiedlichen Kaufkraftniveaus.

2.1.4.6 Erwerbsstatus

Mit der zunehmenden Verbreitung der Plattformökonomie ist insbesondere in der juristischen Literatur eine Debatte darüber entbrannt, wie der rechtliche Status der Plattformarbeitenden einzuordnen ist. Sind sie als Selbstständige, Arbeitnehmende oder arbeitnehmendenähnlich einzustufen? In Deutschland sind an diese Einstufung gewisse Rechte und soziale Sicherheit geknüpft (Schneider-Dörr 2019:4). Arbeitende, die neben einer sozialversicherungspflichtigen Beschäftigung auf den Plattformen aktiv sind, nutzen das Einkommen von der Plattformarbeit lediglich als Möglichkeit zum Zuverdienst und sind über ihren Hauptberuf sozial abgesichert. Erzielte Preise, die womöglich unterhalb von Mindestlöhnen liegen, sind in diesem Fall weniger problematisch als bei solchen Arbeitenden, die ihren Lebensunterhalt mit der Plattformarbeit bestreiten müssen. Auch finanzielle Probleme, die bei der Alterssicherung, im Krankheitsfall oder bei fehlenden Aufträgen auftreten können, sind für diese Personengruppe weniger dramatisch, wohingegen Arbeitende im Haupterwerb womöglich ohne Rentenversicherung, Lohnfortzahlung und Arbeitslosenversicherung auskommen müssen. Dies wäre insoweit nicht bemerkenswert, als diese Risiken auch andere Selbstständige zu tragen haben. Jedoch befinden sich Arbeitende in der Plattformökonomie in einem gewissen Abhängigkeitsverhältnis zur Plattform (vgl. Abschnitt 2.1.2), das sie in ihrer unternehmerischen Freiheit einschränkt.

Ob eine Arbeitnehmeneigenschaft vorliegt oder nicht, ist rechtlich nicht allgemeingültig geklärt. Daher besteht für die Beschäftigten der Plattformökonomie das Risiko der Scheinselbstständigkeit. Entscheidend ist immer die Betrachtung aller Umstände (Däubler und Klebe 2015:1036) und somit ist der Status von Fall zu Fall individuell zu beurteilen (Günther und Böglmüller 2015:1025; Urzi Brancati et al. 2020:46). Lingemann und Otte (2015:1045) kommen zum Schluss, dass das Risiko der Scheinselbstständigkeit steigt, desto konkreter die zu erbringende

Leistung nach Vertragsschluss durch Weisungen des Auftraggebenden konkretisiert wird. Daher stufen die Autor:innen das Risiko der Scheinselbstständigkeit bei geringqualifizierten Tätigkeiten höher ein als bei hochqualifizierten Tätigkeiten.

Aus geschlechterpolitischer Sicht ergibt sich hieraus ein Problem, wenn ein Geschlecht häufiger geringqualifizierte Tätigkeiten ausübt und dadurch diesem Risiko häufiger ausgesetzt ist als das andere Geschlecht. Eine Einschätzung hierzu lässt sich aufgrund der hohen Heterogenität in den bisherigen Daten zu den Geschlechteranteilen auf verschiedenen Plattformen oder Tätigkeitskategorien und Herkunftsländern nicht tätigen (vgl. Abschnitt 2.1.4.1). Dennoch wurde in der Literatur über Befragungen versucht, den Erwerbsstatus der Plattformarbeitenden zu ermitteln.

Urzi Brancati et al. (2020:50) haben die Befragten nach dem Erwerbsstatus ihrer Haupttätigkeit gefragt. Über 70 Prozent der mindestens monatlich aktiven Plattformarbeitenden geben an, angestellt zu sein. Im Vergleich zu den Arbeitenden außerhalb der Plattformökonomie sind dies 10 Prozentpunkte mehr. Ebenfalls überdurchschnittlich fällt mit 10 Prozent der Anteil der Selbstständigen auf den Plattformen aus. Die drittgrößte Gruppe machen Studierende aus. Weiter geben unter denen im Hauptberuf nicht selbstständigen Plattformarbeitenden zwischen 33 (Gelegentliche Plattformarbeitende) und 45 Prozent (Aktive Plattformarbeitende) der Befragten an, selbstständig neben der Haupttätigkeit zu arbeiten. Immerhin 42 bis 25 Prozent klassifizieren die Nebenbeschäftigung ebenfalls als abhängige Beschäftigung. Dies könnte auf Rechtsurteile zurückzuführen sein, die für bestimmte Plattformen bereits Arbeitsverhältnisse anerkannt haben (Urzi Brancati et al. 2019:18 ff.). Der Anteil der vollständig Selbstständigen nimmt mit der Plattformnutzung von 6 auf 19 Prozent zu (Urzi Brancati et al. 2020:50). Serfling (2019:20 f.) findet in seiner Befragung hingegen mit 27,9 Prozent der aktiven Plattformarbeitenden einen deutlich höheren Anteil Selbstständiger. 24,7 Prozent sind Vollzeit und lediglich 4,7 Prozent Teilzeit abhängig beschäftigt. Die drittgrößte Gruppe bilden Rentner mit 18,4 Prozent.

Bezüglich des Erwerbsstatus zeigen sich ebenfalls größere Unterschiede zwischen den Plattformtypen. Die Microtask Plattform *AMT* scheint ein Großteil der

Arbeitenden als Nebenerwerb zu nutzen. Berg (2016:10) kommt in ihrer Befragung auf einen Angestelltenanteil von 81,5 Prozent für die USA und 84,3 Prozent für Indien. Bertschek et al. (2016:22) bestätigt diese Einschätzung mit einem hohen Anteil von Studierenden oder Personen in beruflicher Ausbildung. Auf Freelancing Marktplätzen deklarieren sich die Mehrheit der Arbeitenden als selbstständig. Leimeister et al. (2016:40 ff.) kommen für diese Kategorie auf einen Anteil von 47 Prozent und für die Plattform *javoto* kommen Al-Ani und Stumpp (2015:19) auf über 55 Prozent Selbstständige.

Unabhängig von der juristischen Bewertung der Arbeitnehmereigenschaft von Plattformarbeitenden, zeigen die Ergebnisse, dass Plattformarbeit zu einem Großteil als Nebenbeschäftigung ausgeübt wird. Entweder neben einer abhängigen Beschäftigung, Selbstständigkeit oder, gerade im Microtaskbereich, neben dem Studium oder einer anderen beruflichen Ausbildung. Damit stellt Plattformarbeit meist ein Zusatzeinkommen dar und die soziale Sicherheit wird bei vielen bereits über die Haupttätigkeit abgedeckt. Mit Zunahme der Komplexität der Aufgaben steigt auch der Anteil Selbstständiger, sodass Fragen zur sozialen Absicherung auf solchen Plattformen relevanter erscheinen. Zugleich sind aber dort auch die Verdienstmöglichkeiten oft besser (vgl. Abschnitt 2.1.4.7), sodass eine Hauptbeschäftigung durchaus lukrativ sein kann.

2.1.4.7 Arbeitsvolumen

In der Literatur wird häufig das Prekaritätspotenzial der Plattformarbeit hervorgehoben (z. B. Lorig 2015; Vallas und Schor 2020:279 ff.). Zunächst ist ein geringes Einkommen über die Plattform nur dann problematisch, wenn dieses als Haupteinkommen dienen soll, anderweitig keine Einkommensquelle zur Verfügung steht und hieraus auch Probleme der sozialen Sicherung entstehen. Im letzten Abschnitt wurde festgehalten, dass die meisten Plattformarbeitenden im Nebenerwerb tätig sind und dies somit lediglich ein Zuverdienst darstellt, sodass geringere Einkommen nicht unbedingt ein Problem darstellen müssen. Weiter könnte es aber auch sein, dass Arbeitsvolumen und Einkommen in einem Missverhältnis stehen. Um dies einschätzen zu können, werden in den folgenden beiden Abschnitten Ergebnisse der Literatur dargestellt, die sich auf Arbeitsstunden, Tätigkeitsfelder, die genutzte Anzahl an Plattformen und das erzielte Einkommen der Arbeitenden beziehen.

Die Befragungsergebnisse zu den Arbeitsstunden auf den Plattformen sind sehr heterogen. Europaweit finden Urzi Brancati et al. (2020:42 f.) unter den Plattformarbeitenden im Haupterwerb einen doppelt so hohen Anteil derjenigen, die mehr als 60 Stunden pro Woche arbeiten im Vergleich zu Arbeitenden außerhalb der Plattformökonomie. Die Anteile derjenigen, die nur sporadisch auf den Plattformen aktiv sind (<20 Stunden pro Woche) fallen im Vergleich zum klassischen Arbeitsmarkt höher aus. Serfling (2019:15) findet für Deutschland ebenfalls hohe Anteile derjenigen, die über 40 Stunden pro Woche arbeiten (31 %) und derjenigen, die unter fünf Stunden arbeiten (22,5 %). In der Umfrage von Baethge et al. (2019:15) hingegen arbeiten nur 20 Prozent der Onlinearbeitenden mehr als zehn Stunden pro Woche.

Differenziert nach Plattfortmtypen dokumentieren Leimeister et al. (2016:50 f.) für Microtask Plattformen mit 7,4 Stunden die geringsten durchschnittlichen wöchentlichen Arbeitsstunden und für Freelancing-Marktplätze mit 17,0 Stunden die höchsten. Ähnlich niedrigere Wochenarbeitszeiten finden auch Bertschek et al. (2016:35) und Ipeirotis (2010b:8) für Microtask Plattformen. Der Grund für die Diskrepanz zu den Freelancing Marktplätzen dürfte darin liegen, dass gerade Microtasking fast ausschließlich als Nebenverdienst betrieben wird (vgl. Abschnitt 2.1.4.6). Bei Betrachtung der Arbeitsstunden hauptberuflicher Plattformarbeitenden bestätigt sich diese Vermutung. Arbeitende auf Microtask Plattformen geben mit 17,0 Stunden und Arbeitende auf Freelancing Marktplätzen mit 31,6 Stunden deutlich höhere Arbeitsstunden an.

Unterschiede zeigen sich auch bei der Zugehörigkeitsdauer zu den einzelnen Plattformen. Die Hälfte der Befragten bei Leimeister et al. (2016:32) weisen eine Zugehörigkeit zur Plattform von acht Monaten auf. Im Microtask Bereich findet sich mit zwei Monaten im Median die geringste und im Bereich der Freelancing Marktplätze mit zwölf Monaten die größte Zugehörigkeitsdauer. Die im Vergleich zu Freelancing Marktplätzen geringere Bindung der Arbeitenden an Microtask Plattformen bestätigen sich auch in der Umfrage von Bertschek et al. (2016:33), in der zwei Drittel der Befragten angeben erst bis zu einem Jahr auf der Plattform zu sein. Indische Arbeitende auf *AMT* bilden hierbei die Ausnahme. Berg (2016:6 f.) findet heraus, dass über 70 Prozent der indischen *AMT* Arbeitenden länger als drei Jahre auf der Plattform arbeiten. Dies spiegelt nicht die Regel wider, da es

maßgeblich auf eine Entscheidung von Amazon im Jahr 2012 zurückzuführen ist, Neuregistrierungen von außerhalb der USA stark einzuschränken (Admin 2013).

Neben den teils geringen Arbeitsstunden auf den Plattformen kann die absolute Anzahl an Plattformarbeitenden ohnehin irreführend sein und sagt nicht zwangsläufig etwas über die Anzahl derjenigen aus, die auch tatsächlich Aufträge ausführen. Ein Großteil der Arbeitenden auf Microtask Plattformen bearbeitet nur sporadisch Aufträge. Für die Plattform *oDesk* stellt Gheorge (2015:1476) fest, dass 85 Prozent der registrierten Nutzenden kein Einkommen generiert haben. De Groen et al. (2016) finden heraus, dass 57 Prozent der registrierten Nutzenden auf *Listminut.be* innerhalb von zwei Jahren nur einen Auftrag absolviert haben. Der Großteil der Aufträge wird nur durch einen kleinen Anteil der Plattformarbeitenden absolviert. Diese werden in der Literatur auch als „Power-User“ bezeichnet (Schmidt 2016:14).

Die Dauer der einzelnen Aufträge unterscheidet sich stark zwischen den Plattformtypen. Im Bereich des Microtaskings geben ca. zwei Drittel der Plattformarbeitenden an, dass sie weniger als 15 Minuten für einen Auftrag benötigen (Bertschek et al. 2016:34). Plattformübergreifend kommt Serfling (2019:28) diesbezüglich auf einen Anteil von 36 Prozent. Die meisten benötigen laut seiner Umfrage bis zu einer Stunde pro Auftrag und über 18 Prozent benötigen länger als eine Woche. Im Bereich der Haushalts- und persönlichen Dienste liegt die Arbeitszeit pro Auftrag mehrheitlich bei bis zu drei Stunden (De Groen et al. 2016:9).

Um an möglichst viele Aufträge zu kommen, bieten Plattformarbeitende ihre Dienstleistungen in mehreren Tätigkeitskategorien an. Die wöchentlich aktiven Plattformarbeitenden sind laut Huws et al. (2016:32) in fünf bis sieben verschiedenen Tätigkeitskategorien aktiv. Urzi Brancati et al. (2020:30) kommen bei 80 Prozent der Befragten auf bis zu drei verschiedene Tätigkeiten. Bzgl. des Geschlechts zeigt sich, dass Frauen über alle Länder hinweg Dienstleistungen in weniger Tätigkeitskategorien anbieten als Männer (Huws et al. 2016:32).

Neben der Diversifizierung über mehrere Tätigkeitskategorien nutzen Plattformarbeitende meist auch mehrere Plattformen. Die Befragung von Leimeister et al. (2016:31) ergibt diesbezüglich, dass die Hälfte der Plattformarbeitenden auf

zwei Plattformen aktiv ist. Dabei ist die Bandbreite groß. Das Maximum bei den Antworten schwankt zwischen vier Plattformen im Bereich der Kreativwettbewerbe, 10 bei Freelancing Marktplätzen und bis zu 25 im Bereich Testing. In der Umfrage von Giard et al. (2021:36) nutzen rund 70 Prozent der Befragten bis zu zwei Plattformen. Laut Bertschek et al. (2016:37) machen rund ein Drittel der Befragten von zwei oder mehr Plattformen Gebrauch. Auf Basis von Kontoumsätzen der Bank JPMorgan erhalten lediglich 14 Prozent der analysierten Bankkunden Einkommen von mehreren Arbeitsplattformen (Farrell und Greig 2016:23).

Zusammenfassend zeigt sich, dass der Großteil der Plattformarbeitenden wenige Stunden pro Woche auf den Plattformen aktiv ist. Dies deckt sich mit dem Ergebnis des vorhergehenden Abschnittes, dass die Arbeit zum Großteil als Nebenerwerb genutzt wird. Daneben gibt es einige wenige besonders aktive Arbeitende, die teilweise sehr hohe Arbeitsstunden pro Woche aufweisen und einen Großteil der Aufträge auf den Plattformen bearbeiten. Die hohen Arbeitszeiten deuten auf die Ausführung der Plattformarbeit als Haupterwerb hin. Weiter kann festgehalten werden, dass die registrierten Nutzendenzahlen die tatsächlich aktive Nutzendenbasis stark überzeichnen. Die Charakteristika der einzelnen Plattfortmtypen spiegeln sich sowohl in den Arbeitszeiten als auch in den Zeiten pro Auftrag wider. Zur Diversifizierung nutzen die meisten Plattformarbeitenden mehrere Tätigkeitskategorien und mehrere Plattformen.

2.1.4.8 Arbeitseinkommen

Korrespondierend zu der Verteilung der Arbeitsstunden generieren die meisten Plattformarbeitenden ein Einkommen in Höhe von bis zu 10 Prozent ihres Gesamteinkommens (33 % in Schweden bis zu 58 % in Österreich). Lediglich zwischen 5 Prozent (AT) und 12 Prozent (UK) der Befragten erwirtschaften mehr als 75 Prozent des Gesamteinkommens über die Plattformen (Huws et al. 2016:45). Mit einem durchschnittlichen monatlichen Einkommen von 533 USD und 33 Prozent des Gesamteinkommens über Arbeitsplattformen¹⁴ oder 314 USD und 20 Prozent des Gesamteinkommens über Kapitalplattformen, kommen Farrell und Greig (2016:24) zu einem etwas höherem Ergebnis, wenn es auch nicht als

¹⁴ Die Autor:innen clustern die untersuchten Plattformen in Arbeits- und Kapitalplattformen. Erstere umfassen Plattformen, auf denen Dienstleistungen gehandelt werden. Zweitere sind Plattformen, auf denen Güter verkauft oder vermietet werden (Farrell und Greig 2016:5).

Haupteinkommensquelle ausreicht. Insgesamt liegt der Anteil derjenigen, die weniger als 25 Prozent ihres Gesamteinkommens über die Plattformen erwirtschaften, mit 82 Prozent auf Arbeitsplattformen und 96 Prozent auf Kapitalplattformen ebenfalls auf einem hohen Niveau (Farrell und Greig 2016:24). Weiter stellen die Autor:innen fest, dass der Anteil des Plattformeinkommens am Gesamteinkommen in ihrer Stichprobe im Zeitverlauf konstant geblieben ist (Farrell und Greig 2016:25). Bezogen auf das Wocheneinkommen geben in der Befragung von Serfling (2019:27) 18 Prozent an, weniger als 25 EUR zu verdienen. Immerhin 43,4 Prozent generieren mehr als 1.000 EUR pro Woche. Baethge et al. (2019:22 f.) kommen zu deutlich niedrigeren Ergebnissen. 56 Prozent der Befragten verdienen weniger als 400 EUR pro Monat und lediglich 7 Prozent generieren mehr als 1.500 EUR pro Monat.

Differenziert nach den Plattfortmtypen, ergibt sich eine hohe Heterogenität in den generierten Einkommen und Stundenlöhnen. Im Vergleich zu Freelancing Marktplätzen liegen auf Microtask Plattformen sowohl die durchschnittlichen Gesamteinkommen als auch die Löhne je Auftrag oder Stunde im niedrigen Bereich (Baethge et al. 2019:23; Urzi Brancati et al. 2020:37). In der Umfrage von Bertschek et al. (2016:36) verdienen 68,5 Prozent der befragten Microtask Arbeitenden bis zu 5 EUR pro Woche. Auf AMT verdienen über 80 Prozent der Arbeitenden bis zu 50 USD pro Woche und über 75 Prozent der Plattformarbeitenden absolvieren in dieser Zeit bis zu 200 Aufträge (Ipeirotis 2010b:9). Fast 90 Prozent der deutschen Microtask Arbeitenden verdienen weniger als 300 EUR und im Durchschnitt 144 EUR pro Monat (Leimeister, Durward, et al. 2016:45). Die höchsten Einkommen mit maximal 10.000 EUR und durchschnittlich 663 EUR werden auf Freelancing Marktplätzen generiert, auch wenn die Verteilung der Einkommen dort deutlich breiter gestreut ist. Für eine Plattform aus dem Bereich der Haushalts- und persönlichen Dienste vergleicht De Groen et al. (2016:13) die Stundenlöhne auf der Plattform mit jenen außerhalb. Abgesehen von der Kategorie Babysitting weisen alle Tätigkeiten, die über die Plattform vermittelt werden, um bis zu 15 Prozent höhere Stundenlöhne auf. In der Befragung des Crowdworking Monitors liegt der Medianlohn bei 30 EUR pro Stunde und der Mittelwert bei 60 EUR pro Stunde. Urzi Brancati et al. (2020:34) kommen für Freelancing-Marktplätze auf Stundenlöhne

zwischen 8 (*Upwork*) und 25 EUR (*PeoplePerHour*) und bei Logistikdiensten auf 11,5 EUR (*Deliveroo*).

In den Einkommen zeigt sich, wie auch in den Arbeitsstunden, dass Plattformarbeit oft als Zuverdienst genutzt werden dürfte. Gleichzeitig gibt es aber auch sehr aktive Plattformarbeitende, die entweder viele Aufträge abwickeln oder komplexe Tätigkeiten, auch über längere Zeiträume ausüben oder sogar beides tun und hierüber Einkommen generieren, das durchaus als Haupteinkommen dienen kann. Die beiden letzten Abschnitte haben gezeigt, dass lediglich für eine geringe Anzahl an Plattformarbeitenden ein hohes Prekaritätsrisiko bestehen dürfte.

2.2 Konzepte der ökonomischen Diskriminierungsforschung

Ziel dieses Abschnittes ist es, für die Funktionsweise der ökonomischen Diskriminierungsmodelle ein Verständnis zu entwickeln und die zentralen Annahmen und Voraussetzungen herauszuarbeiten. Dazu wird zunächst definiert, was unter Diskriminierung zu verstehen ist. Anschließend erfolgt die Darstellung der ökonomischen Diskriminierungstheorien in Bezug auf das Geschlecht. Zum Schluss werden die beiden Haupttheoriestränge gegenübergestellt.

2.2.1 Definition

Der Begriff Diskriminierung wird im heutigen Sprachgebrauch genutzt, um eine Benachteiligung, Demütigung oder Entwürdigung zu beschreiben.¹⁵ Es handelt sich also, ganz allgemein gesprochen, um eine Ungleichbehandlung.

Diskriminierung kann in den vielfältigsten Bereichen auftreten, etwa auf verschiedenen Märkten (z. B. Arbeits-, Immobilien-, Versicherungsmarkt), bei Gesetzen wie dem Wahlrecht¹⁶, dem Zugang zu Bildung¹⁷ und Berufen oder der Besteuerung (Arrow 1971:1). Zusätzlich gibt es verschiedenste Merkmale, auf deren Basis die Ungleichbehandlung vollzogen wird, z. B. das Geschlecht, die Hautfarbe, Herkunft, Religion, das Alter oder die sexuelle Orientierung.

Grundsätzlich ist nicht jede Form der Ungleichbehandlung auch gesellschaftlich ein Problem. Unterscheiden sich bspw. Arbeits-, Güter- und Dienstleistungen

¹⁵ Synonyme laut [duden.de](https://www.duden.de) für das Wort „Diskriminierung“ (aufgerufen am 21.12.2022).

¹⁶ In Deutschland wurde Frauen erstmalig bei der Wahl der Nationalversammlung am 19. Januar 1919 das Wahlrecht zugesprochen.

¹⁷ Ein Hochschulzugang für Frauen setzte sich in Deutschland erst nach dem ersten Weltkrieg durch.

hinsichtlich ihres Leistungsumfangs oder der Qualität, ist ein unterschiedlicher Preis gerechtfertigt (Cain 1986:710) und es würde in einem solchen Fall nicht von Diskriminierung gesprochen. Kommt es hingegen zu einer Ungleichbehandlung auf Basis von Merkmalen, die nicht im Zusammenhang mit der Leistung oder Qualität stehen, wird von Diskriminierung gesprochen. Um diese konkret fassen zu können, werden etablierte Definitionen aus der ökonomischen Diskriminierungsforschung herangezogen.

Erste Begriffsbestimmungen, etwa von Arrow (1971:4), sind sehr stark von der präferenzbasierten Theorie von Becker (1971)¹⁸ geprägt und nehmen direkten Bezug auf die Annahme einer Abneigung („distaste“) gewisser Akteur:innen gegenüber bestimmten Gruppen als Ursache.

„Discrimination means that some economic agent has some negative valuation for B [Gruppe, die die Ungleichbehandlung erfährt] or positive valuation for W [Gruppe, die bevorzugt wird] or both, a valuation for which he is willing to pay and has the opportunity to pay.“
(Arrow 1971:4)

Spätere Definitionen erweitern und verallgemeinern den Begriff und nehmen weniger Bezug auf die Ursache, sondern stellen die Ungleichbehandlung im Allgemeinen in den Vordergrund:

„Labor market discrimination is a situation in which persons who provide labor market services and who are equally productive in a physical or material sense are treated unequally in a way that is related to an observable characteristic such as race, ethnicity, or gender.“
(Altonji und Blank 1999:3168)

Zentrale Merkmale dieser Definition sind die gleiche Leistungsfähigkeit („equally productive“) und die Ungleichbehandlung („treated unequally“) auf Basis beobachtbarer Merkmale („observable characteristic“) etwa der Herkunft oder dem Geschlecht. Im Verständnis von Altonji und Blank bedeutet Ungleichbehandlung, dass Personen, die Diskriminierung ausgesetzt sind, unterschiedliche Löhne

¹⁸ Die erste Version von Beckers Theorien wurde bereits 1957 im Rahmen seiner Dissertation veröffentlicht. Die folgenden Zitationen beziehen sich alle auf die zweite Auflage, die 1971 veröffentlicht wurde.

erhalten oder eine unterschiedliche Nachfrage nach ihren Gütern- und Dienstleistungen erfahren, nur weil sie einer bestimmten Gruppe angehören (Koopmans et al. 2018:6). Zur Messung von Diskriminierung ist es demnach essenziell, nur Personen mit ähnlichen Charakteristika zu vergleichen. Diese Definition findet auch in den meisten Forschungsbeiträgen Anwendung und liegt den zahlreich durchgeführten Audit- und Korrespondenzstudien zugrunde.¹⁹ Diese Arbeit schließt sich dem Diskriminierungsbegriff von Altonji und Blank (1999:3186) ebenfalls an.

Zum theoretischen Verständnis von Diskriminierung werden im nächsten Abschnitt die relevantesten ökonomischen Diskriminierungsmodelle beschrieben und gegenübergestellt.

2.2.2 Diskriminierungsmodelle

Die Landschaft der ökonomischen Diskriminierungsmodelle kann nach Becker (1971) und Cain (1986) in neoklassische, institutionelle und marxistische Modelle unterschieden werden. Hierunter kommen den institutionellen Modellen, in denen etwa vorhergehende Arbeitsmarktdiskriminierung („pre-labor market discrimination“) oder Verhandlungsmacht explizit modelliert wird, sowie den marxistischen Modellen, eine untergeordnete Rolle zu (Cain 1986:709). Die neoklassischen Modelle lassen sich in präferenzbasierte Modelle und Modelle der statistischen Diskriminierung aufteilen. Zusätzlich zu diesen beiden neoklassischen Ansätzen hat sich mit der impliziten Diskriminierung in den letzten Jahrzehnten eine weitere dritte Variante in der Forschungsliteratur etabliert, die sich psychologischen Konzepten bedient und davon ausgeht, dass ein gewisser Anteil der beobachteten Diskriminierung implizit und damit unbewusst geschieht (Bertrand et al. 2005:95; Greenwald et al. 1998; Rooth 2007; Ziegert und Hanges 2005).

Als theoretische Fundierung für diese Arbeit werden die neoklassischen Modelle herangezogen. Diese lassen sich in präferenzbasierte und statistische Diskriminierungsmodelle unterteilen und werden in den folgenden Abschnitten hinsichtlich ihrer Annahmen und Vorhersagen näher beschrieben. Grundsätzlich sind die Modelle auf verschiedene Diskriminierungsvariablen wie Herkunft,

¹⁹ Ein guter Überblick über die relevantesten durchgeführten Studien findet sich im Forschungsbeitrag von Bertrand und Duflo (2017).

Geschlecht, Alter, Religion etc. übertragbar. Gemäß der Fragestellung dieser Arbeit werden die Modelle in Bezug auf die Geschlechterdiskriminierung dargestellt. Dabei wird zur Illustration angenommen, dass weibliche Arbeiter diskriminiert werden. An dieser Stelle sei jedoch darauf hingewiesen, dass die Modelle in gleicher Weise auch eine Diskriminierung von männlichen Arbeitern abbilden können und sich die Aussagen der Modelle dadurch nicht verändern.

2.2.2.1 Präferenzbasierte Diskriminierung

Die präferenzbasierte Diskriminierung geht maßgeblich auf den US-Ökonomen Gary Becker zurück. Dieser führte erstmals den Begriff der „taste-based discrimination“ ein (Becker 1971). Gemeint ist damit die Ungleichbehandlung von Personen, Gütern oder Dienstleistungen aufgrund einer Abneigung („distaste“) gegenüber einer bestimmten Gruppe, die sich z. B. durch das Geschlecht, die Herkunft, das Alter o. ä. abgrenzt.

Um Diskriminierung messbar und interpretierbar zu machen, führt Becker (1971) in seinen Modellen einen Diskriminierungsparameter (d) ein, der den Grad der Diskriminierung angibt. Die präferenzbasierten Modelle modellieren Diskriminierung als Disnutzen in der Nutzenfunktion der diskriminierenden Akteur:in und unterstellen diese damit per Annahme (Lang und Lehmann 2012:15). Die Nutzenfunktion der diskriminierenden Akteur:in lässt sich wie folgt darstellen:

$$u = u(\pi, L_w) \quad (1)$$

Wobei die Gewinne (π) positiv und die Anzahl der weiblich Beschäftigten (L_w) negativ in die Nutzenfunktion eingehen.

In Abhängigkeit dessen, von wem die Diskriminierung ausgeht, unterscheidet Becker (1971) die präferenzbasierten Diskriminierungsmodelle in drei verschiedene Varianten: Arbeitgebernden-, Arbeitnehmenden- und Konsumierendendiskriminierung. Im Folgenden wird das Modell der Arbeitgeberndendiskriminierung ausführlicher beschrieben. Da sich die Mechanismen in den anderen Modellen sehr stark ähneln, werden für diese nur die Abweichungen zum Arbeitgeberndenmodell diskutiert.

2.2.2.1.1 Arbeitgebendendiskriminierung

Im Basismodell²⁰ von Becker (1971) kann ein:e Arbeiter:in entweder ein Mann oder eine Frau sein. Es wird unterstellt, dass diskriminierende Arbeitgebende eine Abneigung gegenüber weiblichen Arbeitern aufweisen. Becker (1971) unterstellt folgende Annahmen:

Annahme 1: Männliche und weibliche Arbeiter sind perfekte Substitute und weisen demnach keine Produktivitätsunterschiede auf.

Annahme 2: Präferenz zur Diskriminierung wird durch den Parameter d beschrieben. Hierbei steht $d = 0$ für einen nichtdiskriminierenden Arbeitgeber, $d < 0$ für positive Diskriminierung (Bevorzugung) und $d > 0$ für negative Diskriminierung (Benachteiligung).

Annahme 3: Polypolistische Marktstruktur.

Annahme 4: Handel homogener Güter.

Annahme 5: Unendlich schnelle Reaktion der Marktteilnehmenden auf Veränderungen.

Annahme 6: Keine Marktzutrittsbarrieren.

Annahme 7: Vollständige Information.

Hierbei lassen sich die Annahmen drei bis sieben zum Konzept der vollständigen Konkurrenz zusammenfassen. Insbesondere die Annahme der vollständigen Information ist für die Ergebnisse der Modelle zentral. Der:die Arbeitgebende weiß demnach, welches Geschlecht der Arbeitende aufweist. Das diskriminierende Unternehmen²¹ kann somit gezielt den Kontakt mit weiblichen Arbeitern vermeiden, ohne dass ihr dadurch zusätzliche Kosten entstehen (z. B. Suchkosten).

Weiterhin gilt, dass sowohl das diskriminierende als auch nichtdiskriminierende Unternehmen ihren Gewinn maximieren, woraus folgt, dass sie jene Arbeitende einstellen, die am günstigsten sind. Die Gewinnfunktion lässt sich wie folgt darstellen:

²⁰ Die Beschreibung des Basismodells folgt im Wesentlichen dem Buch von Borjas (2015) und Altonji und Blank (1999).

²¹ Zur Vereinfachung und um Wortwiederholungen zu reduzieren, werden die Begriffe Arbeitgebende und Unternehmen synonym verwendet.

$$\pi = pf(L_w, L_m) - w_w L_w - w_m L_m \quad (2)$$

Hierbei stellt p den Preis, $f(L_w, L_m)$ die Produktionsfunktion, L_i die Anzahl an Arbeitenden der Gruppe $i = \{w, m\}$ und w_i den entsprechenden Lohn der Gruppe dar.

Wird die Gewinnfunktion in die Nutzenfunktion des Arbeitgebenden eingesetzt, eine vereinfachte Nutzenfunktion nach (Arrow 1972b) mit dem Disnutzenterm ($-d L_w$) angenommen und die Bedingung erster Ordnung gebildet, ergeben sich die folgenden beiden Gleichungen (Lang und Lehmann 2012:16):

$$\frac{\partial u}{\partial L_w} = p \frac{\partial f}{\partial L_w} - w_w - d = 0 \quad (3)$$

$$\frac{\partial u}{\partial L_m} = p \frac{\partial f}{\partial L_m} - w_m = 0 \quad (4)$$

Da per Annahme beide Geschlechter perfekte Substitute sind, gilt für das Grenzprodukt der Arbeit (GPA):

$$\frac{\partial f}{\partial L_w} = \frac{\partial f}{\partial L_m} \quad (5)$$

Einsetzen von (5) in (4) und Gleichsetzen von (3) und (4) ergibt:

$$w_m - w_w = d \quad (6)$$

Welche Vorhersagen aus dem Modell resultieren, wird im Folgenden unter Annahme dreier Fälle veranschaulicht:

Fall 1: Keine Diskriminierung $d = 0$:

Aus Gleichung (3) und (4) folgt, dass gewinnmaximierende und nichtdiskriminierende Arbeitgebende ($d = 0$) beide Geschlechter anhand ihres GPA ($\frac{\partial f}{\partial L_m} = w_m$; $\frac{\partial f}{\partial L_w} = w_w$) entlohnt. Unter Einbezug von (5) folgt, dass beide Geschlechter den gleichen Lohn erhalten ($w_m = w_w$). In diesem ersten Fall kommt es demnach weder zu einer Lohndiskriminierung noch zu einer Segregation des Arbeitsmarkts.

Fall 2: Annahme eines homogenen Diskriminierungsparameters $d > 0$:

In diesem zweiten Fall wird angenommen, dass alle diskriminierenden Arbeitgebenden die gleiche Diskriminierungsneigung aufweisen. Damit sind für diskriminierende Arbeitgebende die Lohnkosten für weibliche Arbeiter nicht $w_w L_w$

sondern $L_w(w_w + d)$. D. h. solange die Lohndifferenz zwischen männlichen und weiblichen Arbeitern kleiner ist als die Kosten der Diskriminierung ($w_m - w_w < d$), werden die diskriminierenden Arbeitgebenden nur männliche Arbeiter einstellen. Ist die Diskriminierungsneigung hinreichend groß, folgt unmittelbar, dass es zu einer vollständigen Segregation des Arbeitsmarkts kommt. Diskriminierende Arbeitgebende werden nur männliche Arbeiter beschäftigen und solche, die nicht diskriminieren, nur weibliche. Aufgrund der vollständigen Segregation kommt es nicht zu einer Lohndiskriminierung, da beide Arbeitertypen anhand ihres GPA entlohnt werden und beide per Annahme gleich produktiv sind.

Fall 3: Annahme eines heterogenen Diskriminierungsparameters $d_j \geq 0$:

Eine verallgemeinerte Version des Modells erlaubt unterschiedliche Diskriminierungsparameter. Ob ein Unternehmen (j) zu einem männlichen oder weiblichen Unternehmen wird, ist dann abhängig von der individuellen Diskriminierungsneigung (d_j). Männliche Arbeiter werden bevorzugt, solange die Lohndifferenz zwischen männlichen und weiblichen Arbeitern nicht größer ist als der Diskriminierungsparameter ($w_m - w_w < d_j$).

Ist die Anzahl der diskriminierenden Unternehmen im Markt groß genug, sodass das Angebot an weiblichen Arbeitern die Nachfrage zum Preis $w_m = w_w$ übersteigt, wird sich eine Lohndifferenz am Markt einstellen ($w_m > w_w$). Weibliche Arbeiter müssten in einem solchen Fall auf Lohn verzichten, um eine Beschäftigung bei diskriminierenden Unternehmen zu erhalten (partielles Gleichgewicht).

Unter der Annahme der vollständigen Konkurrenz werden langfristig nichtdiskriminierende Arbeitgebende die Lohndifferenz zwischen männlichen und weiblichen Arbeitern als Arbitrage ausnutzen, bis sich Angebot und Nachfrage ausgleichen und der Lohn dem GPA entspricht. Das führt dazu, dass diskriminierende Unternehmen die Kosten der Diskriminierung selbst tragen und, sofern es nicht genügend männliche Arbeiter gibt, auch die für sie teureren weiblichen Arbeiter einstellen müssen (allgemeines Gleichgewicht).

Als Implikation des Modells ergibt sich, dass Diskriminierung kostspielig ist. Denn das diskriminierende Unternehmen könnte, aufgrund gleicher Produktivität der Arbeitenden und perfekter Substituierbarkeit, den gleichen Output zu geringeren

Kosten produzieren, wenn es nicht diskriminiert. Damit ist der nichtdiskriminierende Arbeitgebende stets der profitablere. Vollständige Konkurrenz und damit einhergehender freier Marktzutritt führt dazu, dass Unternehmen keine Gewinne erzielen und diskriminierende Unternehmen einen Wettbewerbsnachteil erleiden. Sobald ein Unternehmen im Markt existiert, das nicht diskriminiert, wird dieses wirtschaftlich erfolgreicher sein und die diskriminierenden Unternehmen in der langen Frist verdrängen. Unter vollständiger Konkurrenz wird Arbeitgebendendiskriminierung demnach verschwinden.

Zusammenfassend macht das Basismodell von Becker drei zentrale Aussagen:

Ergebnis 1: Um Kosten der Diskriminierung zu vermeiden, führt präferenzbasierte Diskriminierung zur Segregation des Arbeitsmarkts.

Ergebnis 2: Ist der Anteil diskriminierender Arbeitgebende hinreichend groß, müssen weibliche Arbeitskräfte in der kurzen Frist einen geringeren Lohn akzeptieren (oder produktiver als männliche Arbeitskräfte sein), um Beschäftigung zu finden.

Ergebnis 3: Langfristig werden diskriminierende Arbeitgebende aufgrund vollständiger Konkurrenz aus dem Markt gedrängt, da sie die Diskriminierungskosten selbst tragen müssen und damit weniger profitabel sind als nichtdiskriminierende Arbeitgebende.

Das Basismodell wurde im Laufe der Zeit weiterentwickelt. Arrow (1972b, 1972a) nimmt die Zusammensetzung der Belegschaft eines Unternehmens in den Blick und modellierte den Grad der Diskriminierung als steigende Funktion des Verhältnisses von diskriminierten zu nichtdiskriminierten Arbeitenden. Arrow (1972a:89), Marshall (1974:853) und Thurow (1975:162) argumentieren, dass die Abneigung abhängig ist von dem Kontakt der nichtdiskriminierten mit den diskriminierten Arbeitenden und damit mit der sozialen Distanz ansteigt. Das Modell von Becker wird dadurch zwar realistischer, die Kernaussagen ändern sich aber nicht.

Arbeitsmärkte sind in der Realität nicht friktionslos. Aufgrund von Informationsasymmetrien, Transaktionskosten und Zutrittsbarrieren entstehen den Akteur:innen Suchkosten. Um die beobachteten persistenten Lohnunterschiede am Markt zu erklären, die es so nach dem Modell von Becker nicht geben dürfte, sofern

Diskriminierung die Ursache ist, wurde die präferenzbasierte Diskriminierung in suchtheoretische Modelle implementiert („random search models“). Zu der Entwicklung solcher Modelle im Kontext der Arbeitgebendendiskriminierung haben maßgeblich die Forschungsarbeiten von Black (1995) und Bowlus und Eckstein (2002) beigetragen.

Die in diesen Modellen eingeführten Konzepte der Informationsasymmetrie und der Suchkosten können unter präferenzbasierter Diskriminierung für die beobachtete Lohn- und Beschäftigungsdiskriminierung eine Erklärung liefern. Zentrale Ergebnisse des Basismodells, wie die vollständige Segregation des Arbeitsmarkts und die Verdrängung von diskriminierenden Arbeitgebenden, sind nicht mehr ohne Weiteres gültig. Konträr zum Basismodell ist das Ergebnis von Black (1995), denn in seinem Modell führt eine Zunahme von weiblichen Arbeitern im Markt und damit einem Anstieg des Anteils an allen Arbeitenden zu einem Anstieg des Lohns. Im Basismodell hingegen sinkt der Lohn mit steigender Anzahl von weiblichen Arbeitern. Der Unterschied resultiert aus dem Mechanismus, dass die höhere Anzahl an weiblichen Arbeitern die Profite der diskriminierenden Unternehmen und damit deren Anzahl am Markt reduziert. Für einen weiblichen Arbeiter reduziert sich also die Wahrscheinlichkeit, mit einem diskriminierenden Unternehmen gematcht zu werden, wodurch dessen Suchkosten geringer und damit der Lohn höher ausfällt.

Das Modell von Bowlus und Eckstein (2002) erweitert das Modell von Black (1995). Dabei berücksichtigen die Autor:innen neue Elemente wie unterschiedliche Produktivität für männliche und weibliche Arbeiter und die zufällige Auflösung von Matches. Weiter modellieren sie eine Matchingwahrscheinlichkeit, die abhängig vom Grad der Diskriminierung ist. Ferner ist es Arbeitenden in dem Modell möglich, während sie einem anderen Job nachgehen, nach einem neuen zu suchen („on-the-job search“). Überdies wird die Möglichkeit hinzugefügt, dass diskriminierende Unternehmen ab einem gewissen Lohnniveau auch weibliche Arbeiter einstellen. Rosén (2003) erweitert wiederum Bowlus und Ecksteins (2002) Modell um Lohnverhandlungen.

Ein Nachteil der genannten random search Modelle ist, dass sie einen relativ hohen und unrealistischen Anteil stark diskriminierender Unternehmen benötigen, um die empirisch zu beobachtenden Differenzen hinsichtlich Lohn und Beschäftigung zu

erklären (Lang und Lehmann 2012:25). Neuere Entwicklungen modellieren daher den Suchmechanismus nicht mehr als zufällig, sondern erlauben die gerichtete Suche („directed search models“) z. B. auf Basis von Lohnofferten (Galenianos und Kircher 2009; Lang et al. 2005; Peters 2007; Shi 2009). Lang et al. (2005) können dem zuvor genannten Kritikpunkt eines hohen Anteils diskriminierender Arbeitgebenden begegnen und in ihrem Modell, unter Annahme geringer Abneigung, diskriminierende Effekte am Arbeitsmarkt beobachten (Lang et al. 2005:1340).

2.2.2.1.2 Arbeitnehmendendiskriminierung

Bei der Arbeitnehmendendiskriminierung wird die Diskriminierung zwischen Arbeitenden modelliert. In der Literatur wird diese Art von Diskriminierung daher auch „coworking discrimination“ genannt (Sasaki 1999). Männliche Arbeiter haben also eine Abneigung gegenüber weiblichen Arbeitern und versuchen ein Zusammenarbeiten mit diesen möglichst zu vermeiden, bzw. müssen, wie der Arbeitgebende im vorherigen Kapitel, für diesen Nutzenverlust entschädigt werden. Lässt sich dies durch Segregation nicht vermeiden, ist der Lohn der männlichen Arbeiter anstatt $w_m L_m$ nun $L_m(w_m - d)$. Die weiblichen Arbeiter erhalten den Lohn w_w und stören sich nicht an dem Geschlecht der anderen Mitarbeitenden.

Da die zwei Arbeitendotypen perfekte Substitute sind und das Unternehmen keine Präferenz bzgl. des Geschlechts von Arbeitenden hat, wird ein gewinnmaximierendes Unternehmen die günstigste Arbeitskraft nachfragen. Dies bedeutet, dass männliche Arbeiter einen Lohnaufschlag für die Zusammenarbeit mit weiblichen Arbeitern nicht am Markt durchsetzen können, da kein Unternehmen bereit sein wird diesen zu zahlen. Die weiteren Annahmen aus dem Basismodell bleiben bestehen (vgl. Abschnitt 2.2.2.1.1).

Im allgemeinen Gleichgewicht wird es somit, wie im Modell mit Arbeitgebendendiskriminierung, zu einer vollständigen Segregation der Arbeitenden in rein männliche und weibliche Unternehmen kommen. Dies impliziert weiterhin, dass es bei der Arbeitnehmendendiskriminierung nicht zu einer Lohndifferenz zwischen den beiden Typen von Arbeitenden kommt. D. h. auch in diesem theoretischen Rahmen gilt, dass die vollständige Segregation verhindert, dass Lohndifferenzen sichtbar werden.

Zusätzlich schlägt sich Arbeitnehmendendiskriminierung nicht in den Profiten der Unternehmen nieder, da alle Unternehmen den gleichen Lohn zahlen. Es hat also keinen Vor- oder Nachteil, wenn die Belegschaft nur aus männlichen oder weiblichen Arbeitern besteht. Einen marktbereinigenden Effekt, wie bei der Arbeitgebendendiskriminierung, gibt es nicht. Daher wird Arbeitnehmendendiskriminierung auch langfristig nicht aufgelöst.

Zusammenfassend lässt sich also festhalten, dass in diesem Modellrahmen (im Vergleich zur Arbeitgebendendiskriminierung) zwar ebenfalls die vollständige Segregation der Arbeitenden zu beobachten sein dürfte (Ergebnis 1), die Ergebnisse 2–3 aber nicht aus der Arbeitnehmendendiskriminierung hervorgehen.

Das Konzept der Arbeitnehmendendiskriminierung wird in der Literatur, auch aufgrund der Nähe zur Arbeitgebendendiskriminierung und ähnlicher Vorhersagen, nicht intensiv weiterverfolgt. Eine Erweiterung in Form eines Suchmodells hat Sasaki (1999) vorgenommen und kommt zu einem ähnlichen Ergebnis wie Black (1995), dass der Zusammenhang zwischen den Löhnen für weibliche Arbeiter und der Anzahl der weiblichen Arbeiter positiv ist.

2.2.2.1.3 Konsumierendendiskriminierung

Neben den zuvor beschriebenen Konzepten ist auch denkbar, dass Diskriminierung von Kund:innen des Unternehmens ausgeht. Im Fall von Geschlechterdiskriminierung würde dies bedeuten, dass diskriminierende Konsumierende weniger Nutzen erhalten, wenn sie Güter und Dienstleistungen von weiblichen Verkäufern kaufen, als wenn sie das gleiche Gut oder Dienstleistung von einem männlichen Verkäufer beziehen. Die weiteren Annahmen entsprechen denen des Basismodells der Arbeitgebendendiskriminierung.

Hat also ein:e Kunde:in eine Abneigung, Produkte bei weiblichen Verkäufern zu kaufen, so reduziert Diskriminierung die Nachfrage nach Produkten von weiblichen Verkäufern. Hat der:die diskriminierende Käufer:in hingegen keine Information über das Geschlecht des:der Verkäufer:in oder setzen Unternehmen gezielt für den Kundenkontakt männliche Verkäufer ein, kann diese Art der Diskriminierung umgangen werden (Cain 1986:711). Hieraus resultiert eine Segregation von weiblichen und männlichen Arbeitern innerhalb des Unternehmens. Männliche Personen werden vorwiegend im Verkauf arbeiten und weibliche Personen die

Tätigkeiten ohne direkten Kundenkontakt ausüben. Entlohnt werden beide Geschlechter anhand ihres GPA, weshalb per Annahme die Löhne beider Geschlechter gleich sind. Unternehmensgewinne wären somit nicht betroffen.

Die Begründung für diesen Ausweichmechanismus ist, dass diskriminierende Kundschaft für einen Kauf bei weiblichen Verkäufern von dem Unternehmen entschädigt werden müsste. Da weibliche Verkäufer damit geringere Umsätze generieren, wird der Lohn für diese niedriger ausfallen als für gleichqualifizierte männliche Arbeiter. Dies gibt Anreize zur Segregation. Weibliche Verkäufer werden nur an weibliche oder nichtdiskriminierende männliche Personen verkaufen oder lediglich Tätigkeiten ausüben, bei denen kein Kontakt zu diskriminierenden männlichen Käufern besteht.

Im Vergleich zum Modell mit Arbeitgebendendiskriminierung kommt es unter Konsumierendendiskriminierung somit ebenfalls zu einer Segregation des Arbeitsmarkts, jedoch nicht in verschiedene Unternehmen, sondern in bestimmte Berufe/Tätigkeiten innerhalb des Unternehmens. Dadurch, dass Konsumierendendiskriminierung keinen Effekt auf die Gewinne der Unternehmen hat, existiert kein Verdrängungsmechanismus am Markt und auch unter vollständiger Konkurrenz wird diese Form der Diskriminierung nicht aufgelöst (Borjas 2015:374 f.). Konsumierendendiskriminierung liefert damit Ergebnis eins in leicht veränderter Form. Ergebnisse 2–3 aus dem Arbeitgebendendiskriminierungsmodell treffen hingegen nicht zu.

Die Theorie der Konsumierendendiskriminierung wird aufgrund des Bezugs zum Gütermarkt vorwiegend im Kontext der Analyse von Selbstständigen verwendet und weiterentwickelt. Borjas und Bronars (1989) haben das Modell mit Suchkosten basierend auf dem von Black (1995) auf die Konsumierendendiskriminierung übertragen, um die empirisch beobachteten geringeren Selbstständigen Quoten von schwarzen Personen in den USA zu erklären.

Verkäufer:innen können in diesem Modell im Vorhinein nicht zwischen diskriminierenden und nichtdiskriminierenden Käufer:innen unterscheiden. Beide Verkäufer:innentypen setzen daher den gleichen Preis für alle Konsumierenden. Aufgrund zufälliger Matches von Käufer:innen und Verkäufer:innen kommt es dazu, dass diskriminierende männliche Käufer mit weiblichen Verkäufern gematcht

werden und somit kein Verkauf zustande kommt oder der Preis, den der:die Verkäufer:in erhält, geringer ist. Denn der:die diskriminierende Käufer:in kauft nur beim weiblichen Verkäufer, wenn ein niedriger Preis den Nutzenverlust kompensiert. Dadurch sind die Profite des weiblichen Verkäufers geringer als die vom männlichen Verkäufer. Borjas und Bronars (1989) kommen daher zum Schluss, dass es gerade für hoch qualifizierte weibliche Personen aufgrund der Konsumierendendiskriminierung weniger profitabel ist, selbstständig zu sein, als für männliche Personen und es deshalb zu einer Negativ-Selektion kommt.

Einen Ansatz mit zwei Sektoren verfolgt das allgemeine Gleichgewichtsmodell von Kahn (1991). Der Autor nimmt an, dass Konsumierendendiskriminierung nur im Sektor mit Kundenkontakt auftritt. Das Modell zeigt, dass im Gleichgewicht und unter perfektem Wettbewerb Konsumierendendiskriminierung im Gegensatz zur Arbeitgebendendiskriminierung nicht verschwindet. Zusätzlich kommt er zum Schluss, dass der Grad an Diskriminierung positiv abhängig ist von der relativen Größe der weiblichen Arbeiter und der Größe des Sektors mit Kundenkontakt.

Ein kombiniertes Modell aus Arbeitgebenden- und Konsumierendendiskriminierung haben Combes et al. (2016) entwickelt. Die Autor:innen kombinieren den Ansatz in einem Zwei-Sektor Modell, das unterschiedliche Abneigungen zulässt.

Zusammenfassend zeigt sich im Bereich der präferenzbasierten Diskriminierung, dass der stärkste Fokus der Literatur auf dem Modell der Arbeitgebendendiskriminierung liegt und in diesem Bereich am meisten geforscht wurde und wird. Auch wenn die Annahme einer Abneigung intuitiv sinnvoll erscheint, ist sie doch ökonomisch umstritten (Bertrand und Duflo 2017:311). Daher haben Ökonomen parallel begonnen, die statistische Diskriminierungstheorie als zweiten großen Literaturstrang in der Diskriminierungsforschung zu etablieren. Dieser wird im folgenden Abschnitt dargelegt.

2.2.2.2 Statistische Diskriminierung

Statistische Diskriminierungstheorien kommen im Gegensatz zu den präferenzbasierten Theorien ohne die Annahme diskriminierender Präferenzen aus und liefern daher eine marktbasiertere Erklärung für Diskriminierung (Arrow 1998:96). Informationsasymmetrie ist der zentrale Mechanismus, über der Diskriminierung in diesen Theorien wirkt. Um dieser Asymmetrie zu begegnen, nutzen Akteur:innen

beobachtbare Charakteristika, wie das Geschlecht, um die erwartete Produktivität von Arbeiter:innen bestimmter Gruppen abzuleiten. Dies bildet die Grundlage für die Theorie der statistischen Diskriminierung, die maßgeblich auf die Forschungsbeiträge von Phelps (1972) und Arrow (1971) zurückgeht, welche zugleich zwei Forschungsrichtungen etablierten.

Der Ansatz von Phelps (1972) beruht auf der Annahme, dass die Messung der Leistungsfähigkeit für bestimmte Gruppen schwieriger ist als für andere (Aigner und Cain 1977; Lundberg 1991; Lundberg und Startz 1983) und wird daher auch unter dem Begriff „screening discrimination“ zusammengefasst (Cornell und Welch 1996).

Arrow (1971) hingegen argumentiert, dass Stereotype eine wichtige Rolle spielen und selbsterfüllend sein können, wenn die Leistungsfähigkeit endogen ist (Coate und Loury 1993).

Die beiden Theoriestränge werden im Folgenden durch die Beschreibung der jeweiligen Basismodelle genauer betrachtet.

2.2.2.2.1 Screening Discrimination

Der dem Ansatz von Phelps (1972) folgende Literaturstrang nimmt an, dass es für Auftraggebende unterschiedlich schwierig ist, die wahre Fähigkeit²² (q) von weiblichen und männlichen Arbeitern einzuschätzen. Auftraggebende beobachten vor ihrer Einstellungsentscheidung das Produktivitätssignal (T), das die wahre Fähigkeit (q) misst. Es wird der folgende Zusammenhang angenommen, worin u einen normalverteilten Fehlerterm darstellt.

$$T = q + u, \text{ mit } q \sim N(\alpha, \tau) \text{ und } u \sim N(0, \sigma)$$

Auftraggebende sind an der erwarteten Fähigkeit, gegeben dem beobachteten Signal (T) interessiert. Dieser Erwartungswert lässt sich wie folgt darstellen und entspricht einem gewichteten Durchschnitt aus der durchschnittlichen Produktivität der Gruppe (\bar{T}) und dem beobachteten Signal (T):

$$E(q|T) = \gamma\bar{T} + (1 - \gamma)T, \text{ mit } \gamma = \frac{\text{Cov}(q, T)}{\text{Var}(T)}$$

²² Gemeint ist hierbei die angeborene Fähigkeit, im Englischen ability.

Der Parameter γ stellt in der Gleichung eine Art Genauigkeitsparameter bzgl. des Produktivitätssignals und der wahren Fähigkeit dar und dient als Gewichtungsfaktor. Statistische Diskriminierung kann also einerseits dahin gehend wirken, dass der Auftraggebende für bestimmte Gruppen ein unterschiedliches Gewicht (γ) nutzt, andererseits kann aber auch der Gruppendurchschnitt (\bar{T}) unterschiedlich sein. Somit kann es, selbst wenn das beobachtete Signal (T) bei allen Arbeitenden gleich ist, zur Diskriminierung kommen.

Das Basismodell von Phelps wurde maßgeblich von Aigner und Cain (1977) weiterentwickelt. Es wird angenommen, dass die Vorhersage der wahren Produktivität der Arbeitenden durch den Auftraggebenden, gegeben dem beobachteten Signal (T), z. B. für weibliche Arbeiter mit größerer Unsicherheit behaftet ist als für männliche Arbeiter (größere Varianz von q und u). Je größer diese Unsicherheit ist, desto mehr beruht die Vorhersage auf dem Gruppendurchschnitt (\bar{T}) (größeres γ).

Lundberg und Startz (1983) erweitern das Modell von Aigner und Cain (1977) um Investitionsentscheidungen in nichtbeobachtbare Fähigkeiten. Das Modell sagt voraus, dass Auftraggebende ihre Einstellungsentscheidung von weiblichen Arbeitern stärker auf dem Gruppendurchschnitt aufsetzen (höheres γ), da das Produktivitätssignal weiblicher Arbeiter weniger Informationen bereithält als jenes von männlichen Arbeitern. Dies hat zur Folge, dass weibliche Arbeiter geringere Investitionen in nichtbeobachtbare Fähigkeiten tätigen. Hieraus manifestiert sich letztlich eine geringere durchschnittliche Produktivität für weibliche Arbeiter und auch ein niedrigerer Lohn (Lundberg und Startz 1983).

Lang und Manove (2011) zeigen für den Fall, dass Investitionen für den Auftraggebenden sichtbar sind, dass die Gruppe mit der höheren Ungenauigkeit bzgl. des beobachteten Signals überinvestiert. Die Autor:innen nehmen an, dass es einen positiven Zusammenhang zwischen Bildung und der Prognosegenauigkeit (σ) gibt. Dies führt dazu, dass sich die Informationsasymmetrie zwischen Auftraggebenden und Arbeitenden²³ ab einem hinreichend hohen Level an Bildung

²³ In der Studie von Lang und Manove (2011) wird die Hautfarbe als Diskriminierungsvariable betrachtet.

auföst. Die Theorie sagt voraus, dass weibliche Arbeiter mit mittleren Fähigkeiten in Bildung überinvestieren. Dadurch versuchen sie die Ungenauigkeit in der Messung ihrer Fähigkeiten zu kompensieren und sich von denen mit geringen Fähigkeiten abzugrenzen. Innerhalb des Bildungsniveaus verdienen sie dann jedoch weniger als ihre männlichen Kollegen.

Abseits dieses Investitionsfokus zeigt Oettinger (1996), dass Informationsasymmetrie den Lohngewinn durch Arbeitsmarktmobilität für weibliche Arbeiter schmälert und dadurch Lohndifferenzen auftreten können. Milgrom und Oster (1987) zeigen, dass Unternehmen einen Anreiz haben, gezielt benachteiligte Arbeitende mit hoher Produktivität in unqualifizierten Tätigkeiten zu belassen („Invisibility Hypothesis“), was deren Anreiz in Humankapital zu investieren wiederum schmälert. Cornell und Welch (1996) modellieren die Einstellungsentscheidung in Abhängigkeit der Leistungsfähigkeit der anderen Arbeitenden des Bewerbendenpools. Lundberg und Startz (2007) entwickeln ein Modell statistischer Diskriminierung mit Suchkosten und Pinkston (2003, 2006) berücksichtigt, dass Arbeitgebende auf Basis vorheriger Erfahrungen dazulernen. Aufbauend auf der Erkenntnis, dass Informationsgewinnung Unternehmen Geld kostet, zeigen Bartos et al. (2016), dass Unternehmen Bewerbungen weniger genau anschauen und damit weniger in das Screening investieren, wenn die Namen stereotypbehaftet sind („attention discrimination“).

Die Grundintuition der skizzierten Modelle bleibt ähnlich. Informationsasymmetrie führt entweder zu ausbleibender bzw. geringer Investition in nichtbeobachtbare Fähigkeiten oder zu einer ineffizienten Überinvestition in beobachtbare Produktivitätssignale. Die Theorien können damit vor allem Lohndifferenzen erklären, eignen sich jedoch nicht für Vorhersagen zu Einstellungsentscheidungen oder Segregation.

2.2.2.2 Stereotype

Das Modell für Stereotype basiert auf der Ausarbeitung von Arrow (1971:25 ff.) und wird von Coate und Loury (1993:1223 ff.) weiter formalisiert. Es werden zwei Typen von Arbeitenden betrachtet, die individuell unterschiedliche Investitionskosten ($c \sim U[0,1]$) aufweisen. Nachdem Arbeitende ihre Investitionskosten kennen, treffen sie die Entscheidung, in Humankapital zu investieren, oder eine Investition zu

unterlassen. Im Resultat ergeben sich hieraus qualifizierte und nichtqualifizierte Arbeitende, wobei Arrow (1971:28) hierunter nicht zwingend nur formale Qualifikationen wie Schul- oder Studienabschlüsse versteht, die wiederum beobachtbar wären, sondern auch persönliche Qualifikationen, die die Arbeitenden befähigen gute Leistungen zu erbringen.

Die Auftraggebenden im Markt können nur die Gruppenzugehörigkeit der Arbeitenden beobachten, aber nicht die tatsächliche Qualifikation. Weiterhin ist für sie ein ungenaues Produktivitätssignal (θ) beobachtbar, das abhängig von der Investitionsentscheidung der Arbeitenden ist. Je eindeutiger das Signal (größeres θ), desto wahrscheinlicher ist es, dass der:die Arbeitende qualifiziert ist.

Nachdem das Signal und die Gruppenzugehörigkeit beobachtet wird, entscheidet der Auftraggebende, Arbeitende entweder für eine einfache oder eine kompliziertere Tätigkeit einzusetzen. Beide Tätigkeiten sind komplementär zueinander und die Auftraggebenden wissen, dass alle Arbeitenden die einfache Tätigkeit ausführen können. Optimal ist es demnach, dass nur qualifizierte Arbeitende die komplizierteren Tätigkeiten ausführen. Es herrscht also Unsicherheit über die wahre Produktivität der Arbeitenden und damit besteht die Gefahr eines Mismatches.

Zusätzlich haben die Auftraggebenden Vorvermutungen darüber, mit welcher Wahrscheinlichkeit weibliche und männliche Arbeitende qualifiziert sind ($\pi \in [0,1]$). Diese initiale Vorvermutung wird, gegeben dem beobachteten Produktivitätssignal (θ), aktualisiert. Hieraus folgt wiederum, dass es, gegeben der Vorvermutung (π), einen kritischen Wert für das Signal (θ) gibt, ab dem die Arbeitende der komplizierten Tätigkeit zugeordnet wird ($s = s^*(\pi)$). Die Funktion s ist hierbei fallend entlang der Vorvermutungen (π). D. h. je höher die Vorvermutung, dass die Arbeitende qualifiziert ist, desto geringer muss das Produktivitätssignal für eine Zuordnung zu komplexen Tätigkeiten sein. Demnach hätte im Extremfall ($\pi = 0$ oder 1) das Signal keinen Einfluss mehr auf die Zuordnung zu leichten oder komplexen Tätigkeiten.

Die Arbeitenden werden sich also nur für eine Investition in Humankapital entscheiden, wenn die daraus zu erwartende Lohndifferenz größer ist als die Investitionskosten.

$$w \left[F_q \left((s(\pi_g)) \right) - F_u \left((s(\pi_g)) \right) \right] > c, \text{ mit } g \in \{\text{Frau, Mann}\}$$

Der Parameter (w) stellt hierbei den Lohn dar, der für die komplexe Tätigkeit gezahlt wird. Die Gleichung zeigt, dass die zu erwartende Lohndifferenz zwischen qualifizierten (q) und unqualifizierten (u) Arbeitenden von den Vorvermutungen (π) der Auftraggebenden abhängig ist. Damit gilt: je niedriger die vermutete Wahrscheinlichkeit von Auftraggebenden ist, dass z. B. ein weiblicher Arbeiter qualifiziert ist, desto geringer sind die Erfolgsaussichten für weibliche Arbeiter komplizierte Aufgaben zu erhalten und desto eher werden weibliche Arbeiter sich nicht für die Investition entscheiden. Dieser Mechanismus führt dazu, dass Auftraggebende in ihren Vorvermutungen bestätigt werden und Stereotype sich manifestieren, obwohl die Arbeitenden zu Beginn die gleichen Fähigkeiten innehaben und der gleichen Investitionskostenverteilung gegenüberstehen (Lang und Lehmann 2012:48 ff.). Das Modell kann sowohl Unterschiede in der Beauftragungswahrscheinlichkeit als auch Löhne aufgrund von Stereotypen erklären. Gleichzeitig impliziert es auch, dass z. B. an weibliche Arbeiter höhere Anforderungen (größeres Produktivitätssignal) für eine Beauftragung gestellt werden als an männliche Arbeiter.

Erweiterungen der Modelle um Lerneffekte zeigen, dass der Lohn im Laufe der Zeit unabhängiger von beobachtbaren Charakteristika wie Bildung wird und zunehmend die wahre Produktivität des Arbeitenden eine Rolle spielt (Altonji 2005; Altonji und Pierret 2001; Farber und Gibbons 1996; Lange 2007). Fryer (2007) zeigt, dass sich die vorherigen Überzeugungen der Akteur:innen auch ändern können („belief flipping“) und dadurch Akteur:innen, die zu Beginn diskriminiert wurden, später davon profitieren. All diese Theorien gehen von einem rationalen Handeln der Akteur:innen aus (Bohren et al. 2019:2). Neuere Forschungen haben jedoch auch gezeigt, dass Stereotypen ebenso durch verzerrte Entscheidungen hervorgerufen werden können (Bordalo et al. 2016; Fryer und Jackson 2008; Schwartzstein 2014). Abseits der Theorie (selbsterfüllender) Stereotype von Coate und Loury, kann die Persistenz von Diskriminierung auch über die historische Entwicklung von Gruppenreputation („collective reputation“) erklärt werden (Levin 2009).

Zusammenfassend kann festgehalten werden, dass allen Modellen der statistischen Diskriminierung Informationsasymmetrie zugrunde liegt. Sie unterscheiden sich

hinsichtlich des Diskriminierungsmechanismus. Bei der Screening Discrimination wirkt dieser über die unterschiedlich sichere Verifikation von Produktivitätssignalen, wohingegen bei der Theorie der Stereotype Vorvermutungen für diskriminierendes Verhalten verantwortlich sind. Auch in den Vorhersagen unterscheiden sich die Modelle. Denn neben Lohndifferenzen kann die Theorie der Stereotype im Gegensatz zur Screening Discrimination auch horizontale Segregation erklären.

Ziel des nächsten Abschnittes ist es, die dargestellten Diskriminierungstheorien gegenüberzustellen und hieraus Unterschiede in den zentralen Annahmen und Vorhersagen herauszuarbeiten. Da die Plattformökonomie im Vergleich zu anderen Märkten spezifische Rahmenbedingungen aufweist (vgl. Abschnitt 2.1), wird diese Gegenüberstellung dann in Kapitel 3 genutzt, um die bestmögliche Kombination zwischen Untersuchungsgegenstand und Theorie für die Beantwortung der Forschungsfrage zu identifizieren.

2.2.3 Gegenüberstellung der Diskriminierungstheorien und Übertragbarkeit auf die Plattformökonomie

Die theoretischen Konzepte der präferenzbasierten und statistischen Diskriminierung unterscheiden sich im Diskriminierungsmechanismus, aber auch hinsichtlich der getroffenen Annahmen. Um die Vorhersagen der Theorien empirisch prüfen zu können, ist es wichtig, zunächst die zentralen Annahmen herauszuarbeiten.

Die Annahmen der präferenzbasierten Konzepte lassen sich unter dem ökonomischen Begriff der vollständigen Konkurrenz zusammenfassen. Hierunter fällt eine polypolistische Wettbewerbsstruktur, die Produktion homogener Güter, eine unendlich schnelle Reaktion der Akteur:innen, freier Marktzutritt und das Konzept der vollständigen Information. Die statistische Diskriminierung weicht hinsichtlich der vollkommenen Information hiervon ab und unterstellt Informationsasymmetrie. Weiter unterscheiden sich die beiden Diskriminierungskonzepte hinsichtlich des Diskriminierungsmechanismus. Bei den präferenzbasierten Modellen wird eine Abneigung gegenüber gewissen Gruppen per Annahme als Teil der Nutzenfunktion der diskriminierenden Akteur:innen angenommen. Diese Abneigung bleibt im Gegensatz zu den Modellen statistischer Diskriminierung auch bei vollkommener Information bestehen. Daher nimmt dieser

Theoriezweig vorwiegend die Folgen von Diskriminierung in den Blick und kann weniger auf die Frage über die zugrunde liegenden Ursachen der Abneigung eine Antwort geben. Im Ergebnis führen die Basismodelle der präferenzbasierten Theorien, aufgrund vollständiger Konkurrenz, alle zu einer Segregation der Arbeitenden/Käufer:innen in Unternehmen oder Berufe. Der Ausweichmechanismus über die vollständige Segregation führt dazu, dass es keine Lohndifferenzen zwischen diskriminierten und nichtdiskriminierten Arbeitenden gibt, weshalb diese Modelle nicht geeignet sind, Lohndifferenzen zu erklären.

Tabelle 1: Gegenüberstellung der Diskriminierungstheorien

		Präferenzbasierte Diskriminierung			Statistische Diskriminierung	
		Arbeitgebende (AG)	Arbeitnehmende (AN)	Konsumierende (KO)	Screening Discrimination	Stereotype
Initialautor:innen		Becker (1971)			Phelps (1972), Aigner und Cain (1977)	Arrow (1971), Coate und Loury (1993)
Zentrale Annahmen	Marktstruktur	2 Arbeitendentypen – perfekte Substitute		2 Käufer:innen- und Verkäufer:inentypen	2 Arbeitendentypen	2 Arbeitendentypen und zwei Jobarten
	Vollständige Konkurrenz (Polypol, homogene Güter, unendlich schnelle Reaktion, freier Marktzutritt, vollständige Information)	✓	✓	✓	(✓) Informationsasymmetrie zwischen AG und Arbeitenden	(✓) Informationsasymmetrie zwischen AG und Arbeitenden
Diskriminierungsmechanismus		per Annahme			Informationsunsicherheit – Gruppenschicht und Produktivitätssignal	Informationsunsicherheit - prior beliefs
Zentrale Ergebnisse	Vollständige Segregation	✓ (in UN)	✓ (in UN)	✓ (in Berufe)	✓ (in Berufe)	✓ (in Berufe)
	Diskriminierung kostet UN Geld	✓	×	×	×	×
	Marktkräfte verdrängen Diskriminierung	✓	×	×	×	×
	Beeinflussung von Investitionsentscheidungen	×	×	×	✓	✓
	Lohndiskriminierung	×	×	×	✓	✓

Quelle: Eigene Darstellung.

Bei den Theorien der statistischen Diskriminierung hingegen führt die Einführung von Informationsunsicherheit oder Vorvermutungen zu Beschäftigungs- und Lohndiskriminierung. Zentraler Unterschied zur Abneigung der präferenzbasierten Modelle besteht in der Möglichkeit, dass Akteur:innen ihre Vermutungen auf Basis neuer Informationen aktualisieren können. Unter vollständiger Information sollte

deshalb keine statistische Diskriminierung auftreten. Damit liefert dieser Theorienzweig Aussagen zu den Folgen der Diskriminierung und betrachtet auch die darauf basierenden Gründe.

Die Weiterentwicklungen der Theorien haben jeweils versucht, die Ansätze in gewisser Hinsicht realistischer zu machen. Dabei hat die Literaturrecherche gezeigt, dass der Großteil der ökonomischen Literatur sich auf die statistische Diskriminierung fokussiert. Die Erklärung von Lohndifferenzen im Gegensatz zu Beschäftigungseffekten nimmt dabei großen Raum ein (Charles und Guryan 2011:17). Auch wenn die einzelnen Theorien auf unterschiedlichen Diskriminierungsmechanismen beruhen, kommen sie zu ähnlichen Ergebnissen. Die zentrale Herausforderung der Forschung besteht daher in der Trennung der Ursachen von Diskriminierung (Charles und Guryan 2011:24).

Die Basismodelle der Diskriminierungstheorien (präferenzbasierte und statistische) sind in einer Zeit entwickelt worden, in der die Plattformökonomie noch in weiter Ferne war. Ein Großteil der Theorien beruht auf klassischen Märkten, z. B. Arbeits- und Gütermärkte. Daher stellt sich die Frage, inwiefern die Theorien auch für die Plattformökonomie Anwendung finden können und ob die geänderten Rahmenbedingungen zentrale Annahmen der Theorien verletzen und so die Übertragbarkeit einschränken könnten.

Die Theorien werden bereits auf unterschiedlichste Märkte angewendet. Die Betrachtung des Arbeitsmarkts ist dabei der gängigste Untersuchungsgegenstand. Daneben wird präferenzbasierte Diskriminierung aber auch auf anderen Märkten, wie Güter- und Dienstleistungsmärkten untersucht. So wird bspw. die Theorie der Konsumierendendiskriminierung bereits auf verschiedenste Marktformen wie dem Handel mit Baseball Sammelkarten (Nardinelli und Simon 1990), der Gewährung von Trinkgeldern in Restaurants (Parrett 2011) oder dem Bezug von Dienstleistungen (Bar und Zussman 2017) übertragen und liefert entsprechende Evidenz für Diskriminierungseffekte durch Konsumierende.

Ebenso werden statistische Diskriminierungsmodelle auch außerhalb des Arbeitsmarkts überprüft. Beispielsweise finden Ewens et al. (2013) Evidenz für die unterschiedliche Bewertung von Informationen von potenziellen Mietenden durch Vermietende auf Basis der Namensherkunft (typische Namen für Personen weißer

und dunkler Hautfarbe). Knowles et al. (2001) zeigt, dass die höhere Durchsuchungswahrscheinlichkeit von Autos durch die Polizei bei afroamerikanischen Bürger:innen in den USA eher auf statistische Diskriminierung zurückzuführen ist. Ayalew et al. (2021) finden heraus, dass Arbeitende Befehle von Männern so lange eher Folge leisten als von Frauen, bis den Experimentteilnehmer:innen mitgeteilt wird, dass die Frauen in ihrem Beruf (außerhalb des Experiments) erfolgreich sind. Die Autor:innen deuten dies als Evidenz für Vorvermutungen („prior beliefs“) im Gegensatz zu Abneigungen („distaste“), da sich das Verhalten der Arbeitenden durch die zusätzliche Information geändert hat, das im Falle von einer Abneigung nicht hätte passieren dürfen.

Die Beispiele zeigen, dass die Theorien grundsätzlich vielfältig anwendbar sind und nicht an Arbeitsmarktstrukturen wie dem Eingehen von langfristigen Arbeitsverhältnissen oder bestimmten Tätigkeiten gekoppelt sind. Zusätzlich kommt hinzu, dass die Plattformökonomie keine vollkommen neue Organisationsform begründet. Die oft beschriebene dreiseitige Plattformarchitektur ist ebenfalls nicht neu und lässt sich auch so z. B. in Arbeitsbeziehungen feststellen (vgl. Abschnitt 2.1.2).

Die aktive Teilnahme und Steuerung der Plattform am Marktgeschehen unter Nutzung großer Datenmengen und Algorithmen hebt die Plattformökonomie von den zuvor untersuchten Märkten jedoch ab. Hierdurch ergeben sich neue Anknüpfungspunkte für Diskriminierung, die auch von der Plattform und den genutzten Algorithmen ausgehen kann, was wiederum das Potenzial der Plattformökonomie als Untersuchungsgegenstand zeigt.

Die Plattformökonomie hat Märkte, die zuvor geografisch beschränkt waren, globalisiert. In Abhängigkeit der Plattform kann sich theoretisch jede Person der Welt mit einem Computer und Internetanschluss innerhalb von kurzer Zeit Zugang zu diesen neuen Märkten verschaffen. Hohe Marktzutrittsbarrieren wie der Wohnort sind dadurch weggefallen. Aber auch formale Zutrittsbarrieren wie Schul- oder Studienabschlüsse sind in der Plattformökonomie weniger relevant (Chan und Wang 2018:2983). Dadurch erhalten auch Personen Zugang, die womöglich auf dem klassischen Arbeitsmarkt keine Chance dazu haben. Auch die Kurzweiligkeit der vermittelten Aufträge schafft die Möglichkeit, zumindest aus theoretischer Sicht,

für Personen, die gewissen Zeitrestriktionen durch andere Verpflichtungen unterworfen sind (bspw. Sorgearbeit), die Möglichkeit am Erwerbsleben teilzunehmen. Aus Geschlechterperspektive würde dies vorrangig Frauen betreffen, da sie nach wie vor den Großteil der Sorgearbeit übernehmen (Lott et al. 2022:33 ff.). In den Daten zur Plattformökonomie lassen sich erste Hinweise ablesen, dass Frauen diese auch tatsächlich verstärkt nutzen. Von einem eindeutigen Trend kann aber bisher noch nicht gesprochen werden (vgl. Abschnitt 2.1.4.1).

Mit der Globalisierung von Märkten geht ein großer Wettbewerb unter den Marktteilnehmenden einher. Auch werden Marktakteur:innen vor die Aufgabe gestellt, unterschiedliche Bildungssysteme zu bewerten sowie Sprachen, Zeitzonen und kulturelle Unterschiede zu berücksichtigen (Hong und Pavlou 2014:3 ff.). Die Plattform selbst sammelt zwar enorme Datenmengen und nutzt diese für die Marktsteuerung, jedoch herrscht zwischen den Akteur:innen eine hohe Informations- und Machtasymmetrie (vgl. Abschnitt 2.1.2). Im Hinblick auf die zentralen Annahmen der Diskriminierungstheorien kann daher festgehalten werden, dass diese erfüllt sind, woraus sich eine grundsätzliche Übertragbarkeit der Theorien auf die Plattformökonomie ableitet.

Auch wenn die Forschung zur Plattformökonomie neu ist, gibt es bereits Studien, die diese als Untersuchungsgegenstand nutzen. Hierunter finden sich auch Arbeiten, die sich der Diskriminierung widmen. Im nächsten Abschnitt werden die bisherigen Ergebnisse dieser Literatur dargelegt und der aktuelle Forschungsstand zusammengefasst. Darauf aufbauend wird die Forschungslücke identifiziert und beschrieben.

2.3 Aktueller empirischer Forschungsstand zur Geschlechterdiskriminierung in der Plattformökonomie

Die empirische Forschungsliteratur zur Geschlechterdiskriminierung in der Plattformökonomie betrachtet hauptsächlich die Beauftragungswahrscheinlichkeit und die Preise²⁴ als zentrale abhängige Variablen. In diesem Abschnitt werden die Ergebnisse der hierzu einschlägigen Literatur diskutiert und damit der aktuelle

²⁴ Hierbei kann es sich, je nach Studie, um auftragsbezogene Angebotspreise handeln, aber auch um Preise die auftragsunspezifisch in den Profilen der Auftragnehmenden sichtbar sind oder um tatsächlich erzielte Auftragshöhen nach Abschluss der Tätigkeit.

Forschungsstand dargelegt. Im Hinblick auf die Forschungsfrage dieser Arbeit beschränkt sich die im Folgenden betrachtete Literatur auf die Diskriminierung anhand des Geschlechts. Literatur, die andere Diskriminierungsvariablen, z. B. die Herkunft (z. B. Ghani et al. 2014; Mill 2011), Ethnie (z. B. Cui et al. 2020; Edelman et al. 2017; Rhue 2018) oder sexuelle Orientierung (z. B. Ahuja und Lyons 2019) im Kontext der Plattformökonomie untersuchen, bleiben außen vor.

2.3.1 Diskriminierung bei Beauftragung

In der Diskriminierungsforschung auf klassischen Märkten wird die Beauftragungswahrscheinlichkeit hauptsächlich im Arbeitsmarktkontext untersucht. In diesem Kontext handelt es sich dann um die Einstellungswahrscheinlichkeit von Bewerbenden, die in sogenannten Korrespondenzstudien²⁵ typischerweise als sogenannte „callback rate“²⁶ gemessen wird. Die Minderheit der Studien betrachtet dabei das Geschlecht als diskriminierende Variable. Petit (2007) findet Diskriminierung bei der Einstellung, die sich gegen weibliche Bewerber zwischen 25 und 37 Jahren richtet und mutmaßlich auf eine potenzielle künftige Familienplanung der Bewerbenden zurückzuführen ist. Weiter gilt die Segregation²⁷ der Geschlechter in verschiedene Tätigkeitskategorien oder Berufe auf dem klassischen Arbeitsmarkt als ein maßgeblicher Einflussfaktor für die Ungleichheit zwischen Frauen und Männern (Blau und Kahn 2017:827; Busch 2013a). Die Untersuchungen finden tendenziell höhere „callback rates“ bei Frauen als bei Männern, insbesondere in frauendominierten Berufen (Booth und Leigh 2010; Carlsson 2011).

Die Segregation in verschiedene Tätigkeitskategorien zeigt sich auch in der Plattformökonomie, weshalb der Schluss naheliegt, dass dies auch dort eine Rolle

²⁵ Das Studiendesign von Korrespondenzstudien basiert dabei auf der paarweisen Versendung fiktiver Bewerbungen auf Stellenanzeigen, die sich lediglich hinsichtlich der interessierenden Variablen z. B. dem Geschlecht unterscheiden (Bertrand und Duflo 2017:319).

²⁶ Die „callback rate“ misst dabei die Häufigkeit der Einladung zum Gespräch bzw. der Rückruf, den das jeweilige Geschlecht auf die Bewerbung erhält.

²⁷ Die berufliche Segregation von Frauen und Männern ist auf dem klassischen Arbeitsmarkt sowohl in Deutschland (Beblo et al. 2008; Busch 2013b; Hausmann und Kleinert 2014) als auch International (Blau und Kahn 2017; Goldin 2014; Penner 2008) zu beobachten und gilt als ein maßgeblicher Einflussfaktor für die Ungleichheit zwischen Frauen und Männern (Blau und Kahn 2017:827; Busch 2013a). Gründe können bspw. kulturelle und institutionelle Einflüsse sein, die die Wahl der schulischen Ausbildung und des Berufs beeinflussen oder Geschlechterdiskriminierung seitens der Arbeit- oder Auftraggebenden (Galperin 2021:1089 f.). Letztlich sind diese aber noch nicht endgültig erforscht.

spielen könnte. Bspw. werden auf den Plattformen *Nubelo*²⁸ und *Elance*²⁹ Tätigkeiten wie Software- und Webentwicklung mehrheitlich von Männern und Schreib- und Übersetzertätigkeiten mehrheitlich von Frauen ausgeführt (Galperin 2021:1096; Leung und Koppman 2018:784).

Zur Messung möglicher Diskriminierung in der Plattformökonomie wird häufig die Beauftragungswahrscheinlichkeit berechnet. Hierbei lassen sich Unterschiede in Abhängigkeit des jeweiligen Geschlechteranteils der ausgeführten Tätigkeiten feststellen. Leung und Koppman (2018:797) finden heraus, dass die Beauftragungswahrscheinlichkeit von Frauen für frauentypische Tätigkeiten 10 Prozent höher liegt als für Männer. Dahingegen fällt sie bei männertypischen Tätigkeiten 6 Prozent niedriger aus.

Für den Bereich Software- und Webentwicklung, eine männerdominierte Tätigkeit, berechnet Galperin (2021:1099) eine um 56 Prozent geringere Beauftragungswahrscheinlichkeit für Frauen. Im Bereich der Texterstellung und Übersetzung hingegen werden Frauen mit einer um 54 Prozent höheren Wahrscheinlichkeit beauftragt. Als Kontrollgruppe ziehen die Autor:innen Tätigkeiten im Bereich von Grafik- und Multimediadesign heran, die ein ausgeglichenes Geschlechterverhältnis aufweisen. Hierfür wiederum lässt sich kein signifikanter Unterschied zwischen Frauen und Männern feststellen.

Die Rolle der Geschlechterverteilung über die Tätigkeitskategorien unterstreichen auch die Ergebnisse von Chan und Wang (2018). Sie finden eine höhere Beauftragungswahrscheinlichkeit für Frauen, sowohl innerhalb der Tätigkeitskategorie als auch auf Auftragsebene. Besonders groß ist der Unterschied in der Beauftragungswahrscheinlichkeit zu Männern bei frauentypischen Tätigkeiten. Zu dem gleichen Ergebnis kommen auch Cerqua und Urwin (2018). Männer hingegen profitieren nicht von männertypischen Tätigkeiten. Außerdem finden die Autor:innen heraus, dass weibliche Auftraggeber weibliche Auftragnehmer bevorzugt beauftragen.

²⁸ Die Plattform *Nubelo* wurde Ende 2016 von *freelancer.com* übernommen.

²⁹ Im April 2014 schlossen sich die Plattformen *Elance* und *oDesk* zu *Elance-oDesk* zusammen. Seit Mai 2015 lautet der Name der Plattform *upwork.com*.

Lassen sich bei einem Auftrag Abweichungen vom Geschlechterverhältnis des Bewerbendenpools zur Geschlechtersegregation in der Tätigkeitskategorie feststellen, zeigen Leung und Koppmann (2018), dass es tendenziell zur Nichtbeauftragung kommt und dies die Beauftragungswahrscheinlichkeit, insbesondere von Frauen, reduziert. Dies liegt daran, dass die Nichtbeauftragung primär bei männertypischen Aufträgen zum Tragen kommt. Auftraggebende geben an, dass die geschlechteruntypische Zusammensetzung des Bewerbendenpools für sie nicht ausreichende Fähigkeiten signalisieren und es daher zur Nichtbeauftragung kommt. Die Autorenschaft schlussfolgert, dass die Antizipation dieses Mechanismus im Kontext zur Reproduktion von Stereotypen auf den Plattformen steht (Leung und Koppman 2018:802 f.). Bohren et al. (2019:40 ff.) finden für Stereotype sogar empirische Hinweise und Galperin (2021:1102) schlussfolgert, dass die Rahmenbedingungen der Plattformökonomie, die durch kurzweilige Aufträge, geringem Auftragsvolumen und eingeschränkt verifizierbaren Informationen geprägt sind, die Nutzung von Stereotypen begünstigt.

Insbesondere bei der Bewertung neuer Auftragnehmer sind Stereotype relevant, denn sowohl in der Studie von Chan und Wang (2018) als auch in der von Galperin (2021) zeigt sich, dass der gefundene Zusammenhang zwischen geschlechtertypischen Tätigkeiten und Beauftragungswahrscheinlichkeiten mit zunehmender Plattformerfahrung der Auftraggebenden abnimmt und sich die Ungleichbehandlung der Geschlechter reduziert. Zusätzlich finden erstere Autor:innen heraus, dass der Zusammenhang schwächer wird, wenn nur Auftragnehmer aus entwickelten Ländern betrachtet werden. Dies deutet daraufhin, dass die Auftraggebenden Vorvermutungen nutzen, um ihr vermeintliches Risiko bei der Auswahl der Auftragnehmer zu reduzieren. Zunehmende Plattformerfahrung reduziert die Unsicherheit bei der Beauftragung und wirkt damit der Ungleichbehandlung entgegen. Dies liegt daran, dass mit größerer Erfahrung mehr plattformverifizierte Daten (z. B. die Anzahl an Bewertungen) einhergehen, was die Unsicherheit über die Leistung und Qualität der Auftragnehmer für die Auftraggebenden reduziert. Auftraggebende können durch die zusätzlichen Informationen ihre Vorvermutungen aktualisieren und die Ungleichbehandlung müsste theoretisch abnehmen. Der Effekt zunehmender Erfahrung auf die Beauftragungswahrscheinlichkeit ist nach Galperin (2021) jedoch

für Frauen und Männer ähnlich. Die anfängliche Ungleichbehandlung durch mehr Erfahrung aufzuholen, ist damit für Frauen nicht möglich und der Unterschied in der Beauftragungswahrscheinlichkeit bleibt bestehen.

Die hohe Bedeutung plattformverifizierter Daten lässt sich auch mit der internationalen Ausrichtung der Plattformen erklären. Diese erschwert es den Auftraggebenden, die Güte der vom Auftragnehmenden bereitgestellten Informationen zu beurteilen. Dies zeigen auch die Ergebnisse von Chan und Wang (2018). Ratings, die Anzahl absolvierter Tests und die letzten Aufträge auf der Plattform haben einen stets positiven Einfluss auf die Beauftragungswahrscheinlichkeit. Die Effekte für die vom Auftragnehmenden selbst bereitgestellten Informationen wie Bildung, Zertifikate, Arbeitserfahrung außerhalb der Plattform, Sprachkenntnisse und das dargelegte Portfolio hingegen weisen teils ambivalente oder insignifikante Einflüsse auf die Beauftragungswahrscheinlichkeit auf. Informationen, die der:die Auftragnehmende selbst bereitstellt, haben demnach bei der Einstellungsentscheidung eine geringere Bedeutung als solche, die durch die Plattform verifiziert werden (Chan und Wang 2018:2983).

Generell spielen Bewertungen und Ratings in der Plattformökonomie eine wichtige Rolle. Hannàk et al. (2017:9) haben die Geschlechtsunterschiede bei Bewertungsmechanismen der Plattform *Fiverr* genauer untersucht. Demnach erhalten Frauen auf der Plattform nicht grundsätzlich mehr oder weniger Bewertungen als Männer. Im Gegenteil, die Ratings von Frauen fallen sogar durchschnittlich besser aus als die von Männern. Die Autor:innen argumentieren, dass dies ein Indiz dafür sein könnte, dass Frauen in männerdominierten Tätigkeiten bessere Leistungen als Männer erbringen müssen, um im gleichen Maße erfolgreich zu sein. Je nach Tätigkeitskategorie lassen sich aber auch die entgegengesetzten Ergebnisse ablesen. Diese sind aber aufgrund geringer Fallzahlen nur bedingt belastbar (Hannàk et al. 2017:10). Hier gibt es demnach weiteren Forschungsbedarf.

Unter dem Gesichtspunkt, dass Auftraggebende Auftragnehmende mit Plattformerfahrung eher beauftragen als unerfahrenere (Chan und Wang 2018) und diese Erfahrung durch eine höhere Anzahl von Bewertungen signalisiert wird, könnte dies für ein Geschlecht zum Problem werden, sofern dieses systematisch

bei der Evaluation ihrer Arbeit benachteiligt wird. Auch dies gilt es in empirischen Untersuchungen zu berücksichtigen.

Weiterhin eröffnet die Nutzung dieser Evaluierungsergebnisse in algorithmischen Entscheidungssystemen das Potenzial zur Diskriminierung selbst dann, wenn der Algorithmus selbst diskriminierungsfrei ist. Dies ist ein wichtiges und bisher kaum erforschtes Feld. Hannák et al. (2017:13) finden auf Basis einer Korrelationsanalyse keine eindeutigen Hinweise auf die Nutzung des Geschlechts durch den Algorithmus der Plattform. Die Studie von Chen et al. (2018) zeigt hingegen, dass Algorithmen, die auf drei großen Jobportalen genutzt werden, um Bewerbende in eine Rangfolge zu bringen, Frauen systematisch benachteiligen und das, obwohl das Geschlecht als Variable nicht direkt genutzt wird. Dies zeigt, dass Algorithmen eine Diskriminierungsquelle darstellen können und dieser Umstand sowohl genauer erforscht als auch in der Analyse von Diskriminierungseffekten in der Plattformökonomie berücksichtigt werden muss.

2.3.2 Preisdiskriminierung

Der Lohnunterschied zwischen Frauen und Männern wird auch „Gender-Pay-Gap“ genannt. Es ist ein zentrales Maß der Verteilungsanalyse und wird in der Diskriminierungsforschung auf klassischen Märkten vorwiegend im Arbeitsmarktkontext regelmäßig herangezogen. In Deutschland lag dieser im Jahr 2020 unbereinigt bei 18 Prozent und bereinigt³⁰ im Jahr 2018 bei 6 Prozent (Statistisches Bundesamt 2022b). Die möglichen Gründe³¹ für die unterschiedlichen Verdienste von Frauen und Männern reichen von unterschiedlicher Erwerbsbeteiligung, Bildungsentscheidungen und geringerer Berufserfahrung (z. B. aufgrund von Sorgearbeit, die meist von Frauen übernommen wird (Hobler et al. 2017)), Segregation auf dem Arbeitsmarkt (Selektionsmechanismen) und höheren Flexibilitätsansprüchen bis zu Diskriminierung (Blau und Kahn 2017; Litman et al. 2020:2).

Dadurch, dass Faktoren wie Berufserfahrung, die außerhalb der Plattformwelt generiert wurden, weniger wichtig sind als die Erfolge auf der Plattform selbst (Chan

³⁰ Der bereinigte Gender-Pay-Gap „[...] misst [...] den Verdienstunterschied zwischen Männern und Frauen mit vergleichbaren Qualifikationen, Tätigkeiten und Erwerbsbiografien. Strukturbedingte Faktoren sind hier also weitgehend herausgerechnet.“ (Statistisches Bundesamt 2022b).

³¹ Der Überblicksartikel von Blau und Kahn (2017) bietet hierzu einen guten Überblick.

und Wang 2018:2983) und die Plattformen den höheren Flexibilitätsansprüchen von Frauen eher gerecht werden können, könnte hierin eine neue Chance bestehen, Ungleichheiten des klassischen Arbeitsmarkts zu überwinden (Hensel 2020:25 ff.; Pongratz und Bormann 2017:160 f.). Ob diese Chancen sich auch auf den Gender-Pay-Gap auswirken, steht im Fokus einiger Studien.

Für einen Freelancing-Marktplatz finden Dubey et al. (2017:16 f.) eine Ungleichheit in der Bezahlung von Frauen zwischen 11 Prozent (USA) und 38 Prozent (Bangladesch). Foong et al. (2018:9) stützen sich auf Angebotspreise aus den Freelancer:innen Profilen der Plattform *Upwork* und finden bei Frauen über alle Tätigkeitskategorien hinweg einen um 26 Prozent geringeren Medianlohn. Gomez-Herrera und Mueller-Langer (2019:25) berechnen einen deutlich geringeren Gender-Pay-Gap in Höhe von 4 Prozentpunkten zulasten von Frauen für die Plattform *PeoplePerHour.com*. In ähnlicher Höhe ermittelt Roussille (2022:85) für den Freelancing-Marktplatz *hired.com* einen Unterschied in den Angebotspreisen in Höhe von 3 Prozent.

Abseits der Arbeitsplattformen weisen Ge et al. (2016:18) nach, dass *UberX* Fahrer:innen bei weiblichen Mitfahrenden weitere Strecken zurücklegen als bei männlichen Mitfahrenden, das letztlich in einem höheren Fahrtpreis für Frauen resultiert. Beim Onlineverkauf von Baseball Karten über *Ebay* hingegen erzielen weibliche Verkäufer höhere Preise als männliche Verkäufer (Cotropia et al. 2018:15 ff.). In einem anschließenden Umfrageexperiment geben Befragte an, dass die Karten von weiblichen Verkäufern als höherwertig angesehen werden, ein schneller Versand und sorgsamer Umgang mit den Karten unterstellt wird und die persönliche Übergabe bei Frauen eher bevorzugt würde, ein Indiz für die Nutzung von Stereotypen.

Väter verdienen aufgrund längerer Plattformzugehörigkeit, höherer Aktivität sowie ihrer oft besseren Arbeitsmarktposition außerhalb der Plattformökonomie (z. B. weniger häufig arbeitslos oder in Teilzeit) mehr als Mütter und kinderlose Frauen und Männer (Abendroth 2021:72 ff.).

Trotz der hohen Heterogenität der Plattformen und der damit verbundenen eingeschränkten Vergleichbarkeit der Ergebnisse zeigt sich, dass der Gender-Pay-Gap sehr wohl auch in der Plattformökonomie auftritt und das, obwohl die

Rahmenbedingungen diesem entgegenwirken könnten (Hensel 2020:25 ff.). Nun stellt sich die Frage, was der Grund dafür ist.

Zunächst spielt die Segregation von Frauen und Männern in Tätigkeitskategorien auch bei der Erklärung des Gender-Pay-Gaps eine wichtige Rolle. Das unbereinigte Gender-Pay-Gap kann in der Studie von Aleksynska et al. (2018:25 ff.) fast vollständig auf die Ausführung unterschiedlicher Tätigkeiten und damit unterschiedlicher Lohnhöhen zurückgeführt werden. Nach Cullen et al. (2019:4 f.) sortieren sich Frauen gezielt in niedriger entlohnte Tätigkeitskategorien. Laut den Autor:innen können weder Leistungsunterschiede, Ausweichverhalten aufgrund erwarteter Diskriminierung noch unterschiedliche Flexibilitätsansprüche diese Selbstselektion erklären. Sie argumentieren, dass der Gender-Pay-Gap des klassischen Arbeitsmarkts sich auf die Plattformwelt überträgt, da Frauen im Vergleich zu Männern die Außenoptionen (z. B. das Anbieten der Arbeitskraft auf dem klassischen Arbeitsmarkt) fehlen (Cullen et al. 2019:4 f.). Litman et al. (2020:16 f.) argumentieren ähnlich und vermuten niedrigere Reservationslöhne von Frauen, woraus sich die Bereitschaft ableitet, geringer entlohnte Tätigkeiten auszuüben. Ursächlich für die niedrigeren Reservationslöhne könnte die Antizipation von geringeren Erfolgsaussichten z. B. aufgrund von Geschlechterdiskriminierung sein. Dies würde bedeuten, dass es zu Spillover-Effekten kommt und sich Erfahrungen, die außerhalb der Plattformökonomie gemacht werden, auf die Plattformarbeit übertragen (Litman et al. 2020:16 f.). Barzilay und Ben-David (2017:420 f.) finden in ihrer Untersuchung, dass Frauen mehr auf den Plattformen arbeiten als Männer und gleichzeitig weniger pro Auftrag verdienen. Sie führen die Unterschätzung der eigenen Fähigkeiten von Frauen als möglichen Grund hierfür an. Auch die Art der Entlohnung von Frauen und Männern kann durch die Segregation beeinflusst werden. Silberzahn et al. (2014) finden für geschlechteratypische Tätigkeiten bei Frauen häufiger eine Entlohnung pro Stunde anstatt per Festpreis. Die Autor:innen führen dies auf Risikoaversion der Auftraggebenden zurück, da ein Auftrag, der pro Stunde bezahlt wird, bei Minderleistung einfacher beendet werden kann.

Roussille (2022:20 f.) zeigt, dass der Lohnunterschied in Höhe von rund 3 Prozent vollständig durch das sogenannte „ask-gap“, also dem Unterschied in Angebotspreisen von Frauen und Männern, erklärt werden kann. Foong et al. (2018:14 f.) finden heraus, dass Frauen auch innerhalb von Tätigkeitskategorien

systematisch geringere Angebotspreise verlangen. Gleichzeitig zeigt sich, dass die Wahrscheinlichkeit, den Zuschlag zu erhalten, für Frauen auf der Plattform höher ist. Die Autor:innen vermuten daher, dass Frauen gezielt geringere Stundenlöhne als Männer ansetzen, um den Zuschlag zu erlangen. Eine Auswertung der Arbeitsstunden zeigt, dass diese bei Frauen höher ausfallen als bei Männern, was wiederum in einem höheren Gesamtertrag resultiert. Zu einem ähnlichen Ergebnis kommen auch Gomez-Herrera und Mueller-Langer (2019:35). Der niedrigere Angebotspreis bei Frauen könnte auch Ausdruck einer geringeren Wertschätzung der eigenen Fähigkeiten (Foong et al. 2018:15), antizipierter Diskriminierung oder verzerrter Erwartungen über Löhne sein (Roussille 2022:35 ff.).

Dass Frauen weniger häufig bereit sind, in Lohnverhandlungen einzutreten oder, sofern sie eintreten, geringere Löhne erzielen, ist als weiterer Grund für die Lohnungleichheit denkbar. Dubey et al. (2017) beobachten sowohl die Angebotspreise zu Beginn als auch die Lohnsumme am Ende des Auftrags. Sie finden heraus, dass die tatsächlichen Zahlungen an Frauen im Vergleich zu Männern geringer ausfallen. Die Autor:innen deuten dies als mangelnde Fähigkeit zur Lohnverhandlung (Dubey et al. 2017:17). Weiter zeigt sich in der Studie von Dubey et al. (2017:17), dass sich die anfängliche Lohndifferenz zwischen Frauen und Männern für Design- und Softwareentwicklungstätigkeiten indischer Auftragnehmenden im Zeitverlauf ausweitet. Zunehmende Erfahrung wird somit je nach Geschlecht auf der Plattform unterschiedlich honoriert.

Das Geschlecht des Auftraggebenden spielt ebenfalls eine Rolle für die Höhe der verlangten Löhne. Galperin et al. (2017:36) finden heraus, dass Frauen und Männer bis zu 22 Prozent geringere Lohnforderungen für die gleiche Tätigkeit stellen, wenn der Auftraggebende ein Mann ist. In dem Experiment zeigt sich weiterhin, dass Männer eher in Preisverhandlungen treten als Frauen, auch wenn der Auftrag einen Festpreis verspricht (Galperin et al. 2017:36). Gründe liegen laut den Autor:innen eher im Bereich der statistischen als präferenzbasierten Diskriminierung, da sie keine signifikante Differenz zwischen den Angebotspreisen messen, die weibliche und genderneutrale Auftraggebende erhalten.

2.3.3 Kernergebnisse der Literatur und Forschungslücke

Zusammenfassend lassen sich aus den bisherigen Ergebnissen der empirischen Literatur die folgenden Kernergebnisse extrahieren:

1. In der Plattformökonomie zeigt sich, dass Frauen und Männer unterschiedliche Beauftragungswahrscheinlichkeiten aufweisen und sich die größten Unterschiede bei geschlechertypischen Tätigkeitsfeldern messen lassen.
2. Erste Ergebnisse zum Gender-Pay-Gap in der Plattformökonomie zeigen teils beachtliche Preisdifferenzen zwischen Frauen und Männern, auch innerhalb von Tätigkeitsfeldern und unter Berücksichtigung von Kontrollvariablen.
3. Sowohl die Unterschiede in der Beauftragungswahrscheinlichkeit als auch im Preis zwischen Frauen und Männern hängen zum Teil mit der auf den Plattformen zu beobachtenden Segregation in Tätigkeitskategorien zusammen. Es zeichnet sich ab, dass Auftraggebende Stereotype des klassischen Arbeitsmarkts nutzen, um die Unsicherheit bei Beauftragung zu reduzieren. Die Antizipation dieser Nutzung führt beim atypischen Geschlecht der Tätigkeitskategorie zu einem Unterbietungswettbewerb, um doch an den Auftrag zu kommen, was Teile der beobachteten Preisdifferenz erklären kann.
4. Zunehmende Plattformerfahrung lässt die Rolle der Stereotypen bei der Beauftragungsentscheidung absinken. Geschlechterunterschiede lassen sich jedoch bisher bei dieser Abnahme nicht feststellen.
5. Plattformverifizierte Daten (z. B. Ratings) spielen bei der Einstellungsentscheidung eine größere Rolle als solche, die von den Auftragnehmenden selbstberichtet sind und außerhalb von der Plattformökonomie stammen (z. B. Bildung).
6. Selbstdiskriminierung von Frauen erklärt Teile des Preisunterschieds von Frauen und Männern. Neben dem Versuch, durch Unterbietung eine höhere Beauftragungswahrscheinlichkeit zu erlangen, werden auch geringere Wertschätzung der eigenen Fähigkeiten, Antizipationseffekte oder verzerrte Lohnerwartungen hinter dieser Beobachtung vermutet.

Diese Zusammenstellung an Ergebnissen zeigt, dass sich einige Beobachtungen aus dem klassischen Arbeitsmarkt auch in der Plattformökonomie belegen lassen. Indizien deuten darauf hin, dass Stereotype als erklärender Mechanismus für die beobachteten Differenzen plausibel erscheinen. Die Forschung ist noch nicht in der Lage, dies zweifelsfrei zu belegen. Insbesondere Aspekte, die für die eigentliche Neuerung der Plattformökonomie gegenüber bestehenden Organisationsformen stehen, z. B. algorithmisches Management und deren Einfluss auf die beobachteten Ungleichheiten, sind noch nicht ausreichend erforscht (vgl. Abschnitt 2.1.2). Das Ziel dieser Arbeit ist es, einen Beitrag zur Schließung dieser Forschungslücke zu leisten. Dazu werden im Folgenden zunächst die Ergebnisse der letzten Abschnitte dieses Kapitels zusammengefasst und hieraus die Forschungsfrage abgeleitet.

2.4 Zwischenfazit und Ableitung der Forschungsfrage

Die Plattformökonomie weist derzeit noch eine geringe Verbreitung auf. Das Wachstumspotenzial ist jedoch enorm und die COVID-19-Pandemie hat dieses noch weiter beschleunigt (vgl. Abschnitt 2.1.3). Daher ist von einer steigenden Relevanz auszugehen. Die eigentliche Neuerung der Plattformökonomie liegt nicht, wie oft vermutet, in der Dreiseitigkeit des Marktes, sondern in der aktiven Rolle der Plattform als Intermediär durch die Sammlung und Kommerzialisierung von großen Datenmengen sowie der Nutzung dieser durch Algorithmen zur Marktsteuerung. Hieraus ergeben sich für Diskriminierung neue Anknüpfungspunkte, die bisher in der Forschung noch nicht ausreichend betrachtet werden und aus der sich gleichstellungspolitische Probleme ergeben und Handlungsnotwendigkeiten ableiten können (Bundesregierung 2021:21 f.; Hensel 2020:71 ff.).

Um dies zu beurteilen, ist es zunächst wichtig zu verstehen, wer in der Plattformökonomie aktiv ist und ob sich hieraus überhaupt gleichstellungspolitisch relevante Sachverhalte ergeben. Dazu wird in Abschnitt 2.1.4 Literatur zu verschiedenen Charakteristika der Plattformarbeitenden zusammengestellt. Zusammenfassend kann festgehalten werden, dass es hinsichtlich der unterschiedlichen Charakteristika eine hohe Heterogenität zwischen den einzelnen Plattfortmtypen gibt, die oft auch mit den dort vermittelten Tätigkeiten korreliert. Allgemeingültige Aussagen über die Plattformökonomie als Ganzes zu treffen, fällt daher für die meisten Charakteristika schwer. Dennoch lassen sich zwei auffällige

Unterschiede zwischen Plattformen des Microtaskings und Freelancing-Marktplätzen feststellen.

Erstere vermitteln kurzweilige Aufträge mit geringen Anforderungen an den Auftragnehmenden und werden daher häufiger als Zuverdienstmöglichkeit neben einer abhängigen Beschäftigung oder von Personen in Ausbildung genutzt. Dementsprechend sind Arbeitende im Microtask Bereich auch tendenziell jünger, weisen ein geringeres Bildungsniveau auf, arbeiten nur wenige Stunden pro Woche und generieren lediglich geringe Einkünfte über die Plattformen. Das Geschlechterverhältnis schwankt zwischen den Ländern. Frauen aus Entwicklungsländern und den USA sind im Vergleich zur jeweils örtlichen Erwerbsbevölkerung und/oder Gesamtbevölkerung auf diesen Plattformen überrepräsentiert. Für Deutschland zeichnet sich das Gegenteil ab.

Auf Freelancing Marktplätzen werden komplexere Aufgaben vermittelt und der Anteil jener, die Plattformarbeit als Hauptverdienst nachgehen, ist höher. Entsprechend sind die Auftragnehmenden auf diesen Plattformen älter, weisen mehrheitlich ein Hochschulstudium, Arbeitsstunden nahe einer Vollzeitbeschäftigung auf und generieren entsprechend höhere Einkünfte, die auch als Haupteinkommen genügen. Je nach Tätigkeitsschwerpunkt der Plattform lassen sich verschiedene Geschlechterverhältnisse feststellen. Plattformen, die eine Vielzahl von Tätigkeiten vermitteln, weisen dementsprechend unterschiedliche Geschlechterverhältnisse zwischen den Tätigkeiten auf. Dabei kristallisieren sich typische Frauen- (z. B. Texterstellung) und Männertätigkeiten (z. B. Softwareentwicklung) heraus, die so auch auf dem klassischen Arbeitsmarkt zu beobachten sind. Die steigende Bedeutung von frauendominierten Tätigkeitskategorien in der Plattformökonomie erhöht zunehmend die Relevanz dieser Beschäftigungsform für Frauen (Pesole et al. 2018:39; Urzi Brancati et al. 2020:30).

Die bereits vorherrschende Geschlechtersegregation in Tätigkeitskategorien lässt vermuten, dass sich Stereotype aus dem klassischen Arbeitsmarkt auf die Plattformökonomie übertragen. Erste Studien finden für diese These auch bereits empirische Hinweise (Bohren et al. 2019:40 ff.; Cotropia et al. 2018:15 ff.; Galperin 2021:1102; Leung und Koppman 2018:802 f.). Die Rahmenbedingungen der

Plattformökonomie begünstigen die Nutzung von Stereotypen (Galperin 2021:1102). Auch der fehlende physische Kontakt macht es Auftraggebenden schwieriger, die wahren Fähigkeiten der Auftragnehmenden zu bewerten. Aus ökonomischen Gesichtspunkten ist es daher einfacher und kostengünstiger, auf bestehende Vorvermutungen zurückzugreifen. Diese können sowohl auf Erfahrungen zurückgehen, die innerhalb der Plattformwelt als auch außerhalb gesammelt werden. All dies macht eine Übertragung von Stereotypen des klassischen Arbeitsmarkts auf die Plattformökonomie wahrscheinlich und spricht für die Untersuchung der Plattformökonomie im Sinne der Theorie der statistischen Diskriminierung auf Basis von Stereotypen nach Arrow (1971:25 ff.) und Coate und Loury (1993:1223 ff.) (vgl. Abschnitt 2.2.2.2).

Weiter sprechen die in der Literatur gefundenen Verhaltensänderungen der Akteur:innen bei Rückgang der Informationsasymmetrie gegen eine präferenzbasierte Diskriminierung im Sinne der Theorien von Becker (1971) (vgl. Abschnitt 2.3). In Bezug auf die zweite Theorie der statistischen Diskriminierung (Screening Discrimination) ist unklar, wie sich die zentrale Annahme einer unterschiedlichen Prognosegenauigkeit der Produktivitätssignale zwischen weiblichen und männlichen Auftragnehmenden in einer so standardisierten Welt wie der Plattformökonomie darstellen soll. Insbesondere gilt dies für die wichtigen, durch die Plattformen verifizierten Informationen, wie Bewertungen, Ratings und Performancemaße. Hierbei handelt es sich um eindeutige Maßzahlen, denen eine hohe Bedeutung zukommt und für die es schwer vorstellbar ist, dass sie für ein bestimmtes Geschlecht eine geringere Verlässlichkeit haben könnten.

Welche Rolle Geschlechterstereotype für die gefundenen Unterschiede in Beauftragungswahrscheinlichkeiten und Preisen zwischen Frauen und Männern spielen, wurde in der bisherigen Forschung nicht ausreichend betrachtet. Noch viel wichtiger ist es, dabei die Elemente der Plattformen in der Analyse zu berücksichtigen, die diese hybriden Konstrukte so besonders machen. Das ist bisher in den Studien kaum geschehen. Das Ziel dieser Arbeit ist es, einen Beitrag zur Schließung dieser Forschungslücke zu leisten. Dazu wird folgende Fragestellung formuliert:

Welche Rolle spielen Geschlechterstereotype für die Beauftragungsentscheidung von Auftraggebern und die Preissetzung von Auftragnehmern unter Berücksichtigung des Einflusses eines Algorithmus?

Aufbauend auf dieser Hauptforschungsfrage sollen folgende Unterfragen beantwortet werden:

- 1. Welche Rolle spielen Geschlechterstereotype in der Beauftragungsentscheidung von Auftraggebern?*
- 2. Welchen Einfluss haben Geschlechterstereotype auf die Angebotspreise der Auftragnehmern?*
- 3. Welche Rolle spielt das Ranking bei der Beauftragungsentscheidung?*
- 4. Welchen Einfluss nimmt das Ranking auf den Geschlechtsunterschied in der Beauftragungswahrscheinlichkeit?*

Die Forschungsarbeit leistet damit einen Beitrag zum besseren Verständnis, in welchem Ausmaß Auftraggeber auf Stereotype zurückgreifen und welche Rolle hierbei den plattformeigenen Algorithmen zukommt.

Die Vielzahl an Plattformen und deren unterschiedliche Ausgestaltung hinsichtlich der Weboberfläche, den Geschäftsmodellen, dem Marktmechanismus und den genutzten Algorithmen macht es nötig, die Auswahl des Untersuchungsgegenstands hinreichend zu begründen. Dazu wird im nächsten Kapitel der zur Beantwortung der Forschungsfrage geeignetste Untersuchungsgegenstand hergeleitet und beschrieben.

3 Plattformauswahl und Identifizierung von Diskriminierungspotenzialen

Wie in Abschnitt 2.1 beschrieben, besteht die Plattformökonomie aus einer Vielzahl an Plattformen, die eine hohe Heterogenität in der Funktionsweise und Struktur aufweisen. Im Hinblick auf die Vereinbarkeit mit den ökonomischen Diskriminierungsmodellen macht das eine weitere Strukturierung der Plattformen nötig, die in diesem Kapitel vorgenommen wird. Als Ergebnis dieser Strukturierung wird der Untersuchungsgegenstand zur Beantwortung der im vorherigen Abschnitt definierten Forschungsfrage hervorgehen. Im Anschluss wird dieser näher beschrieben und zum Schluss ein Fazit gezogen sowie Hypothesen für die empirische Analyse abgeleitet.

3.1 Auswahl des Untersuchungsgegenstandes

Dieser Abschnitt widmet sich der Auswahl des Untersuchungsgegenstandes. Die Analyse beschränkt sich dabei fortan auf kommerzielle digitale Arbeitsplattformen. Zunächst werden die wesentlichsten Unterschiede zwischen den einzelnen Plattformkategorien hervorgehoben und hinsichtlich des potenziellen Auftretens von Geschlechterdiskriminierung bewertet. Im Anschluss werden die Plattformen hinsichtlich der Annahmen der Diskriminierungstheorie untersucht. Zusammen mit weiteren plattformspezifischen Charakteristika wird hieraus der Untersuchungsgegenstand für diese Arbeit abgeleitet.

3.1.1 Einschränkung auf eine Plattformkategorie

Auf Basis der in Abschnitt 2.1.1 eingeführten Typisierung der Plattformökonomie nach Schmitt (2016) soll zunächst die Menge der potenziellen Untersuchungsgegenstände aus dem Pool der kommerziellen digitalen Arbeitsplattformen auf eine bestimmte Kategorie eingegrenzt werden. Hierzu stellt Tabelle 2 die Gemeinsamkeiten und Unterschiede anhand der Ortsunabhängigkeit und dem Personenbezug der vermittelten Aufträge der einzelnen Plattfortmtypen dar.

Tabelle 2: Tabellarische Darstellung der Typisierung nach Schmidt (2016) von Arbeitsplattformen zur Vermittlung von bezahlten Dienstleistungen

	Abgrenzungskategorie	Ortsunabhängig	Personenbezogen
Cloudwork	Freelancing-Marktplätze	✓	✓
	Microtasking	✓	X
	Kreativwettbewerbe	✓	X
Gigwork	Gastgewerbe	X	✓
	Personenbeförderung	X	✓
	Logistikdienste	X	✓
	Haushalts- und persönliche Dienste	X	✓
	Lokales Microtasking	X	X

Quelle: Eigene Darstellung in Anlehnung an die Typisierung von Schmidt (2016:7).

Allen Plattfortmtypen gemein ist, dass sie eine dreiseitige Architektur aufweisen und sie, durch die Nutzung plattformgenerierter Daten durch Algorithmen, aktiv in das Geschehen auf der Plattform eingreifen. Cloud- und Gigworking unterscheiden sich maßgeblich durch die ortsgebundene oder -ungebundene Ausführung von Tätigkeiten. Cloudworking Plattformen haben den Markt für bezahlte Dienstleistungen globalisiert und ermöglichen prinzipiell jedem mit Zugang zum Internet den Zugriff. Neben dem vereinfachten Marktzugang geht die ortsunabhängige Ausübung von Tätigkeiten auch häufig mit einer zeitunabhängigen Ausübung einher. Es ist zwar üblich, dass ein Lieferzeitpunkt für den Auftrag vereinbart wird, zu welchen Uhrzeiten die Dienstleistung erbracht wird, ist aber nebensächlich. Bei Cloudworking Plattformen steht also hauptsächlich das Ergebnis der Dienstleistung im Vordergrund und weniger die Zeit, die für die Erbringung der Dienstleistung aufgewendet wird. Hieraus entstehen Partizipationschancen für Personengruppen, denen bspw. der Zugang zum klassischen Arbeitsmarkt verwehrt bleibt. Dies können bspw. Menschen mit körperlichen Beeinträchtigungen sein (Ding et al. 2017), aber auch Personengruppen, die häufig Sorgeverpflichtungen wahrnehmen und dadurch entweder gar nicht oder nur in verringertem Umfang erwerbstätig sein können. Eine bessere Vereinbarkeit von Arbeit und Sorgeverpflichtungen oder anderen nichtmarktlichen Tätigkeiten ist also insbesondere auf Cloudworking Plattformen gegeben. Daneben bedeutet Ortsunabhängigkeit fehlender physischer Kontakt und damit auch eine höhere Anonymität für die Akteur:innen. Ob hieraus mehr oder

weniger Diskriminierung resultiert, ist unklar. Diese neuen Chancen einerseits und die Gefahr einer möglichen bisher unbekanntem Diskriminierung durch Auftraggebende oder Algorithmen andererseits, machen Plattformen des Cloudworkings zu einer für die Forschungsfrage interessanten Kategorie. Im Vergleich dazu bleibt bei Gigworking Plattformen die Ortsabhängigkeit bestehen, weshalb auf ihnen keine zu den Cloudworking Plattformen vergleichbare Partizipationschancen gegeben sind. Daher werden Gigworking Plattformen im Folgenden nicht weiter betrachtet.

Die Cloudworking Plattformen lassen sich anhand der personenbezogenen Selektion weiter differenzieren. Diese ist zentral für Diskriminierung von Auftraggebenden gegenüber Auftragnehmenden und hierbei unterscheiden sich die crowdbasierten Plattformen (Microtasking, Kreativwettbewerbe) von denen der Freelancing-Marktplätze. Durch den offenen Aufruf an eine undefinierte Masse von Menschen (Crowd) und die Selbstselektion der Auftragnehmenden fehlt der Personenbezug beim Microtasking und Kreativwettbewerben. Diskriminierung im Sinne der Forschungsfrage kann dadurch nicht auftreten. Dem Auftraggebenden bliebe die Möglichkeit zur Diskriminierung bei der Annahme oder dem Ablehnen der erbrachten Arbeitsergebnisse. Jedoch sind Informationen, die einen Rückschluss auf das Geschlecht des Auftragnehmenden zulassen, gerade auf Crowdworking Plattformen sehr rar. Dadurch ergibt sich für den Auftraggebenden kaum eine Möglichkeit zur direkten Geschlechterdiskriminierung auf diesen Plattformen, weshalb diese für die Beantwortung der Forschungsfrage ungeeignet sind.

Auf Freelancing-Marktplätzen hingegen erfolgt die Selektion der Auftragnehmenden durch die Auftraggebenden. Freelancer:innen bewerben sich gezielt auf Aufträge, die von Auftraggebenden aus aller Welt ausgeschrieben werden. Auftraggebende können sich bei ihrer Auswahl sowohl auf plattformgenerierte Informationen (z. B. Ratings, Plattformzertifikate und Performancemaße) als auch Informationen von außerhalb (z. B. Herkunft und Bildung) stützen. Zusätzlich beinhalten die Profile der Freelancer:innen Fotos und teilweise sogar Klarnamen, anhand derer Auftraggebende auf das Geschlecht schließen können. Dadurch besteht die Gefahr, dass Auftraggebende bei der Auswahl der Freelancer:innen bspw. Geschlechterstereotype nutzen und Diskriminierung auftritt. Dies spricht für die Nutzung von Freelancing-Marktplätzen zur Beantwortung der Forschungsfrage.

Daneben gibt es auch noch ein Datenargument. Freelancing-Marktplätze bieten einen großen Pool an standardisierten Informationen, der für die Diskriminierungsforschung einen neuen Zugang ermöglicht. So kann bspw. bei der Betrachtung von Diskriminierung bei Beauftragung oder Preisen zwischen Frauen und Männern sowohl für das Geschlecht als auch für viele weitere Merkmale wie Bildung, Herkunft, Tätigkeit, Hautfarbe in der Analyse kontrolliert werden. Dies ist insbesondere bei Microtasking Plattformen in dieser Form nicht möglich, da Auftragnehmende auf diesen Plattformen typischerweise keine so vollumfänglichen Profile unterhalten. Ein weiterer Vorteil liegt darin, dass Angebotspreise beobachtet werden können und nicht nur Gleichgewichtspreise. Hieraus lassen sich auch Erkenntnisse über nicht zustande gekommene Aufträge gewinnen, ein Detail, dass sich in der Literatur bereits als erkenntnisreich erwiesen hat (Leung und Koppman 2018). Zusätzlich bieten einige Freelancing-Marktplätze für Forschende die Möglichkeit, Teile des algorithmischen Managements durch öffentliche Daten nachvollziehen zu können und so die Rolle und den Einfluss von Algorithmen auf mögliche Diskriminierungseffekte zu bestimmen.

Zusammenfassend lässt sich für den nächsten Abschnitt festhalten, dass die Forschungsfrage durch die Analyse eines Freelancing-Marktplatzes erfolgen soll. Die Plattformen dieser Kategorie weisen jedoch ebenfalls eine hohe Heterogenität auf. Daher werden im folgenden Abschnitt ausgewählte Freelancing-Marktplätze genauer analysiert.

3.1.2 Vorauswahl von Freelancing-Marktplätzen

Von den im Januar 2021 mindestens 777 aktiven Plattformen weltweit entfallen laut der ILO (2021:46) 283 auf vollständig onlinebasierte Plattformen. Um aus dieser Vielzahl von Plattformen einen geeigneten Untersuchungsgegenstand abzugrenzen, wird in einem ersten Schritt durch eine Literaturrecherche eine Liste von Plattformen erstellt. Die Forschungsbeiträge von Kuek et al. (2015) und Codagnone et al. (2016) dienen hierzu als Ausgangspunkt. Zusätzlich wird diese Auswahl um weitere in Europa aktive Plattformen ergänzt. Fabo et al. (2017) listet 200 Plattformen, die entweder ihren Sitz in Europa haben oder in Europa aktiv sind. Aus dieser Liste werden alle die extrahiert, die dem Sektor „Online-Services“ zuzuordnen sind. Um der hohen Fluktuation am Plattformmarkt gerecht zu werden, werden weitere aktuellere Forschungsbeiträge gesichtet und die dort genannten

Plattformen, die sich noch nicht in der Liste befinden, zusätzlich erfasst (z. B. Baethge et al. 2019; Serfling 2018; Urzi Brancati et al. 2020).

Aus diesen Literaturquellen ergibt sich als Basis für die weitere Untersuchung eine Liste von 60 Plattformen, die potenziell als Untersuchungsgegenstand infrage kommen (vgl. Anhang Tabelle 1). Aufgrund der in der Literatur ungenauen Abgrenzung von Plattformen (vgl. Abschnitt 2.1.1), ist es möglich, dass sich unter den 60 Plattformen noch solche befinden, die nach der Typisierung von Schmidt (2016) nicht als Freelancing-Marktplatz eingestuft werden. Daher ist es zunächst notwendig, die 60 Plattformen hinsichtlich der Kriterien eines Freelancing-Marktplatzes nach Schmidt (2016) zu untersuchen (Schritt 1). So befindet sich z. B. die Plattform *joboto.com* noch in der Aufzählung, die jedoch nach Schmidt (2016) den Kreativwettbewerben zuzuordnen ist. Überhaupt finden sich mehrere Plattformen, bei denen die Auftragsvergabe nicht personenbezogen stattfindet. In Summe bleiben für die nächsten Schritte noch 44 Freelancing-Marktplätze erhalten.

Um sicherzugehen, dass alle Plattformen noch aktiv sind, werden sämtliche 44 Plattformen auf Aktivität überprüft (Schritt 2). Hierzu erfolgt ein Aufruf der jeweiligen Internetseite.³² Sieben Plattformen erweisen sich als inaktiv und werden nicht weiter berücksichtigt. Davon ist in sechs Fällen die Internetseite nicht erreichbar und in einem Fall enthält diese nur Blindtext, was auf eine Inaktivität oder kürzlichen Neuaufbau der Seite hinweist.

Die Diskriminierungstheorie beruht u. a. auf der Annahme von freiem Marktzutritt (vgl. Abschnitt 2.2.3). Die geografische Beschränkung von Plattformen auf bestimmte Länder grenzt diesen Marktzutritt für Personen außerhalb der Länder ein (Schritt 3). Dies ist bei 15 der verbleibenden 37 Plattformen der Fall, die nicht weiter berücksichtigt werden. Zusätzlich werden, aufgrund der erschwerten Auswertung, Plattformen, die nicht auch auf Deutsch oder Englisch aufrufbar sind, aus der Liste entfernt. Dies betrifft aus den 22 Plattformen die rein spanischsprachige Plattform *freelas.com*.

Als letzter Schritt wird das Tätigkeitsspektrum der jeweiligen Plattform betrachtet. Zur Beantwortung der Forschungsfrage ist ein Vergleich verschiedener Tätigkeitskategorien mit unterschiedlichen Geschlechteranteilen vorgesehen.

³² Die Überprüfung auf Aktivität erfolgte im April 2021.

Daher werden Plattformen von der weiteren Untersuchung ausgeschlossen, die sich auf die Vermittlung von nur einer oder wenigen Tätigkeiten beschränken (Schritt 4). Dies betrifft 14 der 21 Plattformen. So befinden sich bspw. Plattformen, die sich auf Designaufträge wie Logo- oder Websitedesign spezialisiert haben (z. B. *99designs.de*, *designhill.com*, *crowdspring.com* oder *eYeka.com*), oder ausschließlich Dienstleistungen im Bereich der Texterstellung (*writeraccess.com*), Audioaufnahmen (*voices.com*) oder gar medizinischer Beratung (*diagnose.me*) anbieten, in der Liste und werden von der weiteren Betrachtung ausgeschlossen.

Nach den vier Filterschritten bleiben die folgenden sieben Plattformen für die weitere Untersuchung erhalten:

- [Fiverr.com](https://www.fiverr.com)
- [Fivesquid.com](https://www.fivesquid.com)³³
- [Freelancer.com](https://www.freelancer.com)
- [Guru.com](https://www.guru.com)
- [Peopleperhour.com](https://www.peopleperhour.com)
- [Toptal.com](https://www.toptal.com)
- [Upwork.com](https://www.upwork.com)

3.1.3 Gültigkeit der Annahmen auf den Freelancing-Marktplätzen mit Fokus auf die Informations(a)symmetrie

Die theoretische Fundierung der Forschungsfrage beruht auf dem Modell statistischer Diskriminierung anhand von Stereotypen (vgl. Abschnitt 2.4). Die Theorie trifft dabei die Annahmen homogener Güter, einer unendlich schnellen Reaktion der Marktteilnehmenden, einer polypolistischen Marktstruktur, einem freien Marktzutritt und Informationsasymmetrie. In diesem Abschnitt werden zur Identifizierung eines zur Beantwortung der Forschungsfrage geeigneten Freelancing-Marktplatzes, die wichtigsten dieser Annahmen im Kontext der einzelnen Plattformen diskutiert.

Die Annahme homogener Güter und der unendlich schnellen Reaktion der Marktteilnehmenden sind eher theoretischer Natur und in der Realität von kaum einem Markt erfüllt.³⁴ So gestaltet sich dies auch auf onlinebasierten

³³ Die Plattform *fivesquid.com* wurde im Laufe des Dissertationsverfahrens eingestellt und ist unter der ursprünglichen URL nicht mehr erreichbar.

³⁴ Als Beispiel für einen Markt unter vollständiger Konkurrenz, der auch näherungsweise die Homogenitätsbedingung erfüllt, wird in Lehrbüchern häufig der Markt für landwirtschaftliche Erzeugnisse wie z. B. Milch angeführt (Mankiw und Taylor 2018:61).

Arbeitsplattformen anders. Die auftragsbezogene Vermittlung von Dienstleistungen macht Auftragnehmende jederzeit austauschbar (Schmidt 2016:13). Am Ende zählt das Arbeitsergebnis und nicht, wer die Dienstleistung erbracht hat. Der fehlende physische Kontakt macht Faktoren wie Sympathie oder Aussehen in der Interaktion der Akteur:innen weniger relevant als auf klassischen Arbeitsmärkten. In Bezug auf die Homogenitätsbedingung bedeutet dies, dass diese auf Plattformen sogar eher erfüllt sein dürfte.

Mit der Austauschbarkeit geht zugleich eine hohe Flexibilität auf den Freelancing-Marktplätzen einher. Dienstleistungsverträge können innerhalb von Sekunden geschlossen und auch wieder aufgelöst werden. Dies ermöglicht den Akteur:innen auf den Plattformen eine sehr hohe und schnelle Reaktionsfähigkeit auf Marktveränderungen, die in dieser Form nur durch die Digitalisierung ermöglicht werden konnte. Sowohl die Argumente für die Homogenitätsbedingung als auch der schnellen Reaktionsfähigkeit der Akteur:innen gelten für alle sieben Plattformen.

In der Literatur finden sich nur wenige Studien, die sich der Wettbewerbsstruktur auf Plattformen gewidmet haben (z. B. Dube et al. 2020; Kingsley et al. 2015). Typisch für die Online-Community ist, dass einige wenige Auftragnehmende und Auftraggebende viele Aufträge oder eine große Summe der abgewickelten Auftragsvolumen auf sich vereinen (Ipeirotis 2010a:17). In der Literatur werden diese oft auch als „Power-User“ bezeichnet (Schmidt 2016:14). Abgesehen von *fivesquid.com*, geben alle Plattformen Zahlen zu ihren Nutzenden heraus. Auch wenn diese Zahlen kritisch betrachtet werden müssen (vgl. Abschnitt 2.1.3), können Sie einen Eindruck über die Größenverhältnisse geben und zur Approximation der Wettbewerbssituation dienen (vgl. Anhang Tabelle 4). Auf allen Plattformen, abgesehen von *fiverr.com*, lässt sich eine deutlich höhere Anzahl an Freelancer:innen gegenüber Auftraggebenden feststellen. Die Verhältniszahlen zwischen Auftraggebenden und Freelancer:innen schwanken zwischen 0,4 (*freelancer.com*) und nahe null (*Toptal.com*). Hieraus leitet sich der Schluss ab, dass auf diesen Plattformen eher von einem Oligopson oder Monopson auszugehen ist: ein Ergebnis, das durch ausführliche Analysen der Wettbewerbssituation für AMT bereits empirisch bestätigt wird (Dube et al. 2020). Auch wenn es dadurch zu einer Abweichung von der Annahme einer polypolistischen Marktstruktur kommt, ist davon auszugehen, dass Diskriminierung auch unter diesen Marktstrukturen

auftreten kann. Auftraggebende befinden sich in der Position aus einer Vielzahl an Freelancer:innen wählen zu können, wohingegen Freelancer:innen nur wenigen Auftraggebenden gegenüberstehen. Dies stärkt die Position von Auftraggebenden und es besteht die Gefahr, dass diskriminierende Auftraggebende diese Ungleichheit ausnutzen könnten. Daher könnten Diskriminierungstendenzen durch Oligopsone oder Monopsone sogar verstärkt werden.

Fiverr.com bildet mit einem Verhältnis von Auftraggebenden zu Freelancer:innen von 6,6 unter den Plattformen die Ausnahme. Mit durchschnittlich 60 Aufträgen sind die Freelancer:innen auf dieser Plattform zudem deutlich aktiver als auf den anderen. Die Plattform liegt damit eher im Bereich eines Oligopols.

Die nächste Annahme ist die des freien Marktzutritts. Theoretisch kann sich jede Person von überall auf der Welt mit Zugang zu einem Computer und Internetanschluss Zutritt zu den Plattformen verschaffen (Maier und Viète 2017:10). Dementsprechend erscheinen die Zugangsbeschränkungen auf den weltweit operierenden Freelancing-Marktplätzen zunächst gering. Trotzdem können bspw. langwierige Registrierungsprozesse oder eine hohe Kostenstruktur für gewisse Akteur:innen zugangsbeschränkend wirken. Bei fünf der sieben Freelancing-Marktplätze ist der Anmeldeprozess innerhalb weniger Minuten erledigt (vgl. Anhang Tabelle 5). Bei den Freelancing-Marktplätzen *peopleperhour.com* (*PPH*) und *toptal.com* hingegen ist der Registrierungsprozess mit Pflichtangaben, die von der Plattform geprüft werden (*PPH*), oder einem fünfstufigen intensiven Bewerbungsverfahren verknüpft (*Toptal*). Hinsichtlich der Kostenstruktur haben alle Plattformen gemein, dass sie Provisionen in Abhängigkeit des Auftragswertes sowohl von dem:der Freelancer:in als auch vom Auftraggebenden erheben (vgl. Anhang Tabelle 5). Je nach Plattform und in Abhängigkeit des kumulierten Umsatzes, schwankt der Prozentsatz zwischen 3,5 Prozent³⁵ (*peopleperhour.com*) und 20 Prozent (*fiverr.com*, *fivesquid.com*, *peopleperhour.com*, *upwork.com*). Die Plattform *guru.com* verlangt mit 5–9 Prozent vom Auftragswert die durchschnittlich geringste Provision. Besonders Aufträge mit kleinen Volumina werden meist mit den maximalen 20 Prozent belastet. Daneben besteht für Freelancer:innen auf allen Plattformen, außer auf *fiverr.com*, die Möglichkeit, kostenpflichtige Mitgliedschaften

³⁵ *Peopleperhour.com* weist zwar mit 3,5 Prozent noch niedrigere Provisionen auf, diese gelten aber erst ab einem kumulierten Umsatz von 6.000€ des jeweiligen Auftraggebenden.

abzuschließen, die bspw. den Zugang zu höher dotierten Projekten ermöglichen oder eine bessere Sichtbarkeit auf der Plattform schaffen. Die Preise hierfür liegen zwischen 4,95 \$ und 69,95 \$ pro Monat (*freelancer.com*). Um sicherzustellen, dass genügend Aufträge auf der Plattform verfügbar sind, belastet die Plattform Auftraggebende mit geringeren Provisionen. Die Provisionen liegen im Bereich zwischen 2,7 Prozent (*fivesquid.com*) und 10 Prozent (*peopleperhour.com*). Anhand des Registrierungsprozesses und der Kostenstruktur lässt sich schlussfolgern, dass bei den Plattformen *freelancer.com*, *guru.com* und *upwork.com* am ehesten von einem freien Marktzutritt gesprochen werden kann. *PPH* und *toptal.com* weisen die höchsten Zutrittsbarrieren auf und *fiverr.com* sowie *fivesquid.com* haben eine recht hohe Kostenstruktur, die hemmend auf gewisse Personengruppen wirken kann.

Die wichtigste Annahme für die statistische Diskriminierungstheorie der Stereotype ist die Informationsasymmetrie (vgl. Abschnitt 2.2.2.2). Daher wird diese Annahme ausführlicher diskutiert. Hierbei wird sowohl die Fülle an Informationen, die den Akteur:innen auf den Plattformen zur Verfügung stehen, als auch ihre (a)symmetrischen Verteilung betrachtet. Je nach Freelancing-Marktplatz gibt es große Unterschiede hinsichtlich der Informationen, die Auftragnehmenden, -gebenden und der Plattformen zur Verfügung stehen. Dies hängt mit den unterschiedlichen Weboberflächen und Funktionsweisen der Freelancing-Marktplätze zusammen. Neben der Plattform, welche die Datenhoheit über alle Akteur:innen hat, haben Auftraggebende häufig gegenüber Auftragnehmenden Informationsvorteile. Zugleich stehen Auftragnehmenden kaum Informationen über Auftraggebende zur Verfügung (vgl. Abschnitt 2.1.2). Es herrscht also neben der Plattform, primär zwischen Auftragnehmenden und -gebenden, eine hohe Informationsasymmetrie. Weiterhin ist wichtig, ob auf den jeweiligen Plattformen das Geschlecht des jeweiligen Gegenübers als Diskriminierungsvariable direkt beobachtet oder indirekt antizipiert werden kann. Diese Aspekte werden für die sieben ausgewählten Plattformen untersucht.

Die zuvor beschriebenen Informationsvorteile für Auftraggebende gegenüber Auftragnehmenden bestätigen sich auch bei den hier untersuchten Plattformen.³⁶

³⁶ Die Plattform *toptal.com* bietet keinen öffentlich einsehbaren Bereich, sodass dieses Kriterium nicht untersucht wird.

Der Auftraggebende hat direkten Zugriff auf die jeweiligen Profile der Freelancer:innen. Diese umfassen auf allen Plattformen detaillierte Informationen über die Person wie das Profilbild³⁷, Namen³⁸, Herkunft (Stadt, Land), ein Freitextfeld, die Anzahl an Bewertungen, die der:die Freelancer:in erhalten hat und die durchschnittliche Bewertung sowie eine Auflistung der Einzelbewertungen mit Freitextfeld des Auftraggebenden. Des Weiteren sind Informationen zur Entlohnung (Stundenlohn oder Fixpreis) einsehbar. Abgesehen von der Plattform *fivesquid.com*, werden in den Profilen besondere Fähigkeiten (sog. „Skills“) hervorgehoben. Um die Aktivität der Freelancer:innen darzustellen, machen die Plattformen, abgesehen von *guru.com*, Angaben zur letzten Auftragslieferung oder zum letzten Log-in. Die Erfahrung der Freelancer:innen wird bei *freelancer.com*, *guru.com*, *peopleperhour.com* und *upwork.com* über die Angabe der kumulierten Projekte oder des Auftragsvolumens signalisiert. Insbesondere *freelancer.com* bietet hinsichtlich der Bewertung der Zuverlässigkeit von Freelancer:innen weitergehende Informationen wie die Auftragsabschlussrate (Jobs Completed), zeitgerechte Lieferung der Projekte (On Time), Lieferung innerhalb des vorgegebenen Budgets (On Budget) und die Wiederbeauftragungquote (Repeat Hire Rate) (vgl. Abschnitt 3.2.4). Weiter wird auch der Beitrittszeitpunkt und die beherrschten Sprachen teilweise genannt sowie Angaben zu externen Bildungsabschlüssen gemacht (vgl. Anhang Tabelle 2). Um ihre Attraktivität und Beauftragungswahrscheinlichkeit zu steigern, haben Freelancer:innen einen Anreiz, ihre Profile möglichst vollständig und so detailliert wie möglich auszufüllen (z. B. Agrawal et al. 2016; Kässi und Lehdonvirta 2019; Pallais 2014; Stanton und Thomas 2016). Dies wird von den Plattformen, z. B. durch Erinnerungen an die Vervollständigung, Fortschrittsbalken oder Mindestanforderungen, aktiv gefördert.

Dem:Der Freelancer:in hingegen stehen auf den Plattformen deutlich weniger Informationen über den Auftraggebenden zur Verfügung. Alle Plattformen, bis auf *fivesquid.com*, sehen für die Auftraggebenden keine Profilseiten vor. Damit entfallen

³⁷ Nach Hannák et al. (2017:5) haben rund 29 Prozent der Freelancer:innen auf *fiverr.com* ein Profilfoto, das keine Person zeigt und 12 Prozent haben überhaupt keines. Grundsätzlich ist aber davon auszugehen, dass die Freelancer:innen einen Anreiz haben, das Profil möglichst vollständig auszufüllen. Dies wird von den Plattformen auch gefördert.

³⁸ Der Name muss nicht zwingend Vor- und Nachname sein, sondern der:die Freelancer:in kann auch ein Pseudonym wählen. In der Literatur finden sich Studien, die den Namen für die Identifikation von z. B. Ethnien (Ghani et al. 2014), aber auch dem Geschlecht (Chan und Wang 2018), erfolgreich nutzen.

die bei Freelancer:innen Profilen typischen Freitexte und detaillierten Angaben (z. B. Sprachen, Bildung). Die Herkunft (Stadt & Land) des Auftraggebenden ist die einzige Variable, die auf allen Plattformen für den:die Freelancer:in einsehbar ist. Auf nur vier der sechs Plattformen kann der:die Freelancer:in ein Profilbild und einen Namen einsehen. Bei *freelancer.com* und *upwork.com* bleiben diese Informationen im Verborgenen. Am umfangreichsten informiert *guru.com* den:die Freelancer:in über den:die Auftraggebenden und gibt zusätzlich detaillierte Informationen über deren Zahlungsmoral (Anzahl offener Rechnungen, durchschnittliche Zahlungsdauer, Beauftragungsquote) (vgl. Anhang Tabelle 3). Damit ist die Menge an Informationen für Freelancer:innen und Auftraggebende auf *fivesquid.com* und *guru.com* recht ausgeglichen. Die anderen Plattformen (*fiverr.com*, *freelancer.com*, *peopleperhour.com* und *upwork.com*) hingegen weisen eine stärkere Asymmetrie auf. Insbesondere *freelancer.com* und *upwork.com* fallen unter diesen auf, da sie weder einen Namen noch ein Profilbild des Auftraggebenden zeigen. Die Auftragsannahme erfolgt auf diesen Plattformen somit weitestgehend ohne Kenntnisse über den Auftraggebenden. Weitere Informationen über den Auftraggebenden sind, im Vergleich zu den anderen beiden Plattformen, auf ein Minimum reduziert, sodass die Asymmetrie bei diesen beiden Plattformen am stärksten ist.

Auf keinen Plattformen lässt sich das Geschlecht im Sinne einer binären Variable ablesen und ist damit nicht direkt beobachtbar. Indirekt können Auftraggebende das Geschlecht aber über Profilfotos, den Namen oder gar die Beschreibung bestimmen. Auftragnehmende hingegen haben in der Regel keine Kenntnis über das Geschlecht des Auftraggebenden. Festzuhalten ist daher, dass grundsätzlich auf allen Plattformen die Möglichkeit zur Geschlechterdiskriminierung durch Auftraggebende besteht.

3.1.4 Zusammenfassung der Plattformauswahl




Insgesamt zeigt sich, dass lediglich auf den Plattformen *freelancer.com* und *upwork.com* die Annahmen der statistischen Diskriminierungstheorie näherungsweise erfüllt sein dürften (vgl. Tabelle 3). Insbesondere bei dem Kriterium der Informationsasymmetrie zwischen Auftraggebenden und Freelancer:innen weisen beide Plattformen aufgrund ihrer Weboberflächen die größte Asymmetrie

auf. Damit qualifizieren sich grundsätzlich beide Plattformen als Untersuchungsgegenstand.

Tabelle 3: Zusammenfassende Darstellung der Gültigkeit der Annahmen

Plattform	Wettbewerbsstruktur	Marktzutrittsbeschränkungen	Informations-(a)symmetrie
Fiverr.com	eher Oligopol	freier Marktzutritt (aber hohe Provisionen)	asymmetrisch
Fivesquid.com	-	freier Marktzutritt (aber hohe Provisionen)	symmetrisch
Freelancer.com	Oligopson/Monopson	freier Marktzutritt	asymmetrisch
Guru.com	Oligopson/Monopson	freier Marktzutritt	symmetrisch
Peopleperhour.com	Oligopson/Monopson	hohe Marktzutrittsbeschränkungen	asymmetrisch
Toptal.com	Oligopson/Monopson	hohe Marktzutrittsbeschränkungen	-
Upwork.com	Oligopson/Monopson	freier Marktzutritt	asymmetrisch

Legende

-  zur Theorie konform
-  eingeschränkte Passung zur Theorie
-  zur Theorie konträr

Quelle: Eigene Darstellung.

Die Plattform *freelancer.com* weist einen entscheidenden Informationsvorteil zur Beantwortung der Forschungsfrage auf. Auf der Plattform sind sowohl alle Freelancer:innen öffentlich einsehbar, die ein Angebot für einen Auftrag abgegeben haben (Bewerbendenpool) als auch derjenige:diejenige, die den Auftrag erhält (vgl. Anhang Abbildung 1). Damit kann in der Berechnung von möglichen Diskriminierungseffekten die Geschlechterzusammensetzung des Auftrags und der Tätigkeitskategorien berücksichtigt werden, was im Kontext der Untersuchung von Stereotypen wichtig ist. Weiter gibt die Rangposition der Freelancer:innen im Bewerbendenpool Auskunft über die Bewertung des:der Freelancer:in durch den plattforminternen Rankingalgorithmus, dessen Einfluss auf die Beauftragungsentscheidung dadurch in der Analyse quantifiziert werden kann (vgl. Abschnitt 3.2.5). Auch die Einbeziehung von gängigen Kontrollvariablen in der Analyse ist über den Zugriff auf die Profile der mitbietenden Freelancer:innen möglich. Damit bietet die Plattform gegenüber allen anderen untersuchten Plattformen einen erheblichen Informationsvorteil, weshalb zur Beantwortung der Forschungsfrage die Plattform *freelancer.com* als Untersuchungsgegenstand herangezogen wird.

3.2 Funktionsweise des Freelancing-Marktplatzes *freelancer.com*

Nachdem nun der Untersuchungsgegenstand hergeleitet ist, werden in diesem Abschnitt die Besonderheiten der Plattform *freelancer.com* dargestellt. Hierzu wird das Geschäftsmodell beschrieben und die Rolle der Plattform und deren Instrumente zur Marktsteuerung diskutiert. Dieser Abschnitt deckt auf, an welchen Stellen der Plattform potenziell Geschlechterdiskriminierung auftreten kann und begründet damit das spätere gewählte empirische Vorgehen.

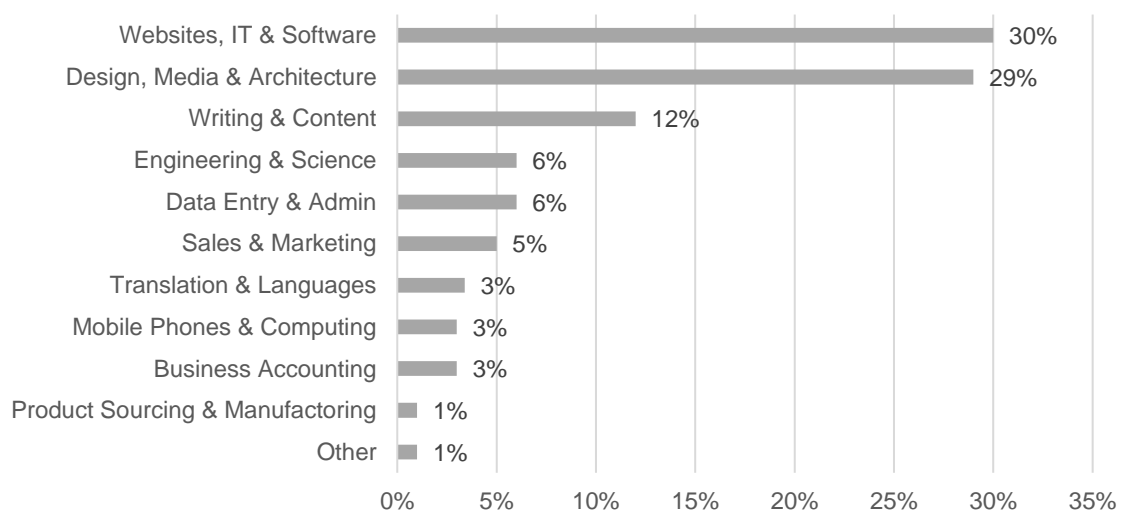
3.2.1 Grundlegende Informationen

Die Plattform *freelancer.com* wurde 2009 gegründet und hat ihren Hauptsitz in der australischen Hauptstadt Sydney. Von dort aus operiert sie weltweit, bietet ihren Service auf 53 regionalen Webseiten in 34 Sprachen an und ermöglicht die Zahlung in 39 Währungen (Freelancer.com 2022h:22). Nach Plattformangaben wurden seit Gründung rund 21 Mio. Aufträge abgewickelt und 58,2 Mio. Freelancer:innen registrierten sich auf der Plattform. Davon entfallen auf das Jahr 2021 rund 1,8 Mio. neue Aufträge und 7,6 Mio. neue Freelancer:innen (Freelancer.com 2022g:4). Rückschlüsse auf die tatsächliche Aktivität auf der Plattform lassen sich auf dieser Basis jedoch nicht tätigen. De Groen et al. (2016) hat bspw. für eine Plattform aus dem Bereich des Gigworkings gezeigt, dass der Anteil der aktiven Auftragnehmer:innen an allen registrierten Auftragnehmer:innen mit nur 5,4 Prozent gering sein kann. Die bisher in der Literatur recht übereinstimmend gefundenen „Power-User“-Effekte, also die Bearbeitung vieler Aufträge von nur einer geringen Anzahl von Auftragnehmer:innen, bestätigen dieses Ergebnis (Codagnone et al. 2016:7; Schmidt 2016:14). Es ist daher eher von einer Überschätzung der Zahlen auszugehen, da die Plattformen diese auch für Marketingzwecke nutzen und demnach ein Anreiz besteht, diese möglichst groß darzustellen (Schmidt 2016:14). Dennoch kann geschlussfolgert werden, dass auf Basis dieser Zahlen, *freelancer.com* neben den direkten Konkurrenten *upwork.com* und *fiverr.com*, einer der größten Freelancing-Marktplätze weltweit ist.³⁹

³⁹ Aufgrund des starken Wachstums der Plattformen ist die bisherige Literatur, die die absolute Größe der Plattformen in den Blick nimmt, nicht aktuell (z. B. Codagnone et al. 2016:23). Die Aussage basiert auf Basis eigenrecherchierter Zahlen zu den bekanntesten Freelancing-Marktplätzen.

Die Plattform bedient ein breit gefächertes Aufgabenspektrum von mehr als 1.800 verschiedenen Skills⁴⁰. Abbildung 3 stellt auf Basis der Projektvolumen die bedeutendsten Tätigkeitskategorien im Jahr 2021 dar. Rund 60 Prozent entfallen auf Aufträge aus den Tätigkeitskategorien „Websites, IT & Software“ sowie „Design, Media & Architecture“. Die nächsten drei Kategorien sind „Writing & Content“ (12 %), „Data Entry & Admin“ (6 %) sowie „Engineering & Science“ (5 %). Es zeigt sich, dass auf der Plattform sowohl hochkomplexe als auch einfache Tätigkeiten eine relevante Größenordnung aufweisen. Neben dem Spektrum an Komplexität der Tätigkeiten unterscheiden sich die Kategorien auch hinsichtlich des Anspruchs an Kreativität, technischen Verständnisses, Sprachfähigkeiten etc. Also mit Fähigkeiten, die durchaus bestimmten Geschlechterstereotypen zugeschrieben werden können, was das grundsätzliche Potenzial der Nutzung von Stereotypen auf der Plattform darlegt.

Abbildung 3: Projektkategorien der Plattform *freelancer.com* nach dem Auftragsvolumen abgeschlossener Projekte im Jahr 2021



Quelle: Eigene Darstellung in Anlehnung an Freelancer.com (2022h:24), Abweichungen rundungsbedingt.

Das durchschnittliche Volumen je Projekt befand sich im vierten Quartal 2021 bei rund 224 USD und ist seit Gründung kontinuierlich angestiegen (Freelancer.com 2022h:24). Durchschnittlich erhält ein Auftrag auf der Plattform 26 Angebote und innerhalb von 60 Sekunden erhalten 62 Prozent der Aufträge mindestens ein Angebot (Freelancer.com 2022h:23). Insbesondere die letzten Zahlen zeigen, dass

⁴⁰ Skills stellen auf der Plattform die niedrigste Ebene dar und sind als Untergruppen der Tätigkeitskategorien zu verstehen. Eine Tätigkeit kann demnach mehrere Skills erfordern und ein:e Freelancer:in kann mehrere verschiedene Skills auf der Plattform anbieten.

auf der Plattform ein hoher Wettbewerb zwischen den Freelancer:innen herrscht und der Markt insgesamt sehr schnelllebig ist.

Auch *freelancer.com* weist eine für die Plattformökonomie charakteristische Organisationsform auf (vgl. Abschnitt 2.1.2). D. h. neben der technischen Bereitstellung des Marktplatzes und der Vermittlung zwischen Auftragnehmenden und –gebenden kommt der Plattform als Akteur:in eine zentrale Rolle zu. Denn sie hat Zugriff auf sämtliche Daten und ist dem direkten Kontakt zwischen Auftragnehmenden und -gebenden zunächst zwischengeschaltet. Ob und wie die beiden Akteure zusammenkommen, ist abhängig von der Plattform und deren AGB sowie Marktmechanismen (vgl. Abschnitt 3.2.5). Die Auftragnehmenden haben dabei ein doppeltes Abhängigkeitsverhältnis, denn neben der Beziehung zur Plattform, haben Sie auch nur beschränkt Einfluss auf die Auftragsausgestaltung, die Höhe der Bezahlung und die Abnahme des Arbeitsergebnisses (Greef et al. 2017:17 f.). Grundsätzlich ist damit Geschlechterdiskriminierung möglich, ausgehend von der Plattform gegenüber Auftraggebern und Auftragnehmenden, sowie Geschlechterdiskriminierung von Auftraggebern gegenüber Auftragnehmenden.

3.2.2 Auftragsarten und Vergabeverfahren

Hauptsächlich vermittelt die digitale Arbeitsplattform Aufträge, die ortsunabhängig (Cloudwork) ausgeführt werden können. Diese lassen sich in sogenannte „Fixed Price Projects“, „Hourly Projects“ und „Contests“ unterscheiden. Die ersten beiden unterscheiden sich lediglich hinsichtlich der Bezahlung (Festpreis vs. pro Stunde). Auftraggebende veröffentlichen das Projekt mit einer Projektbeschreibung, die den Arbeitsumfang und das Arbeitsergebnis skizziert und die benötigten Skills sowie die Budgetvorgabe angibt (vgl. Anhang Abbildung 1). Anschließend ist es sämtlichen Freelancer:innen der Plattform gestattet, Angebote abzugeben. Diese Angebote sind im Normalfall⁴¹ öffentlich einsehbar, d. h. andere Freelancer:innen können auch die Konkurrenzsituation beobachten, was zu einem gesteigerten Wettbewerb zwischen den Freelancer:innen beiträgt. Das Projekt bleibt so lange für Gebote

⁴¹ Es gibt auf der Plattform die Möglichkeit, dass Freelancer:innen ihre Angebotspreise und Lieferfristen nicht für andere Freelancer:innen öffentlich machen (Sealed). Auftraggebende können dies auch bei Auftragsveröffentlichung für alle Freelancer:innen verpflichtend machen (vgl. Abschnitt 3.2.3).

offen, bis der Auftraggebende das für sich beste Angebot auswählt und eine:r Freelancer:in den Zuschlag erteilt oder er das Projekt aus anderen Gründen schließt und keiner den Zuschlag erhält.

Bei den sogenannten „Contests“ beschreibt der Auftraggebende ebenfalls die Aufgabe in einem kurzen Text, führt dafür benötigte Skills auf und gibt das Budget vor (vgl. Anhang Abbildung 2). Zentraler Unterschied zu dem zuvor beschriebenen Vergabeverfahren ist, dass die Freelancer:innen in Vorleistung gehen, in dem sie dem Auftraggebenden erste Arbeitsentwürfe zur Verfügung stellen. Dieser hat dann die Möglichkeit, die eingereichten Arbeitsergebnisse mit einer Sternebewertung zwischen eins und fünf Sternen zu versehen und ggf. um Nachbesserung über eine Chatfunktion zu bitten. Weiter hat der Auftraggebende auch die Möglichkeit, eine Einreichung abzulehnen (Rejection) und diese so aus dem Contest zu entfernen. Eine Begründung für eine Ablehnung muss nicht verpflichtend gegeben werden. Weiter ermöglicht das „Public Clarification Board“ einen öffentlichen Austausch zwischen Freelancer:innen und Auftraggebenden, um z. B. den Arbeitsauftrag zu konkretisieren (Freelancer.com 2016a). Sofern ein zufriedenstellendes Arbeitsergebnis eingereicht wird, wählt der Auftraggebende dieses aus und nur jene Freelancer:in wird auch entlohnt („the-winner-takes-it-all“). Alle anderen Teilnehmenden erhalten keine monetäre Kompensation für die erbrachte Vorarbeit. Diese Vergabeform findet vorrangig im Bereich von Design-tätigkeiten Anwendung.

Seit 2015 vermittelt die Plattform auch Aufträge, die ortsgebunden ausgeführt werden (Gigwork). Beispiele für solche Aufträge sind Abholungen und Lieferungen aller Art, Umzugshilfen oder etwa die Suche nach Fotografen (Freelancer.com 2022i). Der Vergabeprozess ist, bis auf die genaue Ortsangabe, gleich zu den „Fixed Price Projects“ und „Hourly Projects“ (vgl. Anhang Abbildung 3).

Eine weitere Möglichkeit, seine Dienstleistungen über die Plattform anzubieten, ist das Produkt „Freelancer Services“, das von der Plattform 2017 eingeführt wurde. Die Auswahl eines:r geeigneten Freelancer:in übernimmt bei diesem Produkt ein von der Plattform entwickelter Algorithmus auf Basis der jeweiligen Reputation der Freelancer:innen (z. B. Bewertungen, Onlinestatus, Reaktionsgeschwindigkeit). Der Auftraggebende definiert die Aufgabe und den Preis, hat aber selbst keinen Einfluss auf die Vergabe und ist an die Freelancer:innenwahl des Algorithmus

gebunden. Sofern Freelancer:innen sich dazu entscheiden, den ihnen zugewiesenen Auftrag anzunehmen, sind sie verpflichtet, diesen zu dem vordefinierten Preis zu erledigen. Damit haben Freelancer:innen keinerlei Einfluss auf die Vertragsbestandteile und sind vollständig abhängig vom Algorithmus und den Bedingungen des Auftraggebenden. Sofern Freelancer:innen dazu nicht bereit sind, haben sie jedoch die Möglichkeit, in ihren Einstellungen den Service abzuwählen (Freelancer.com 2017b).

Die Relevanz der einzelnen Auftragsarten und Vergabeverfahren auf der Plattform ist sehr unterschiedlich. Um einen ersten Eindruck über die Größenordnungen zu gewinnen, wird die Liste offener Projekte auf der Plattform ausgewertet. Insgesamt sind zum Betrachtungszeitpunkt 12.578 Aufträge offen. Davon entfallen 9.388 Aufträge auf „Fixed Price Projects“, 2.263 Aufträge auf „Hourly Projects“ und 927 Aufträge auf „Contests“. Von den 12.578 Aufträgen sind 192 solche, die ortsgebunden ausgeführt werden sollten. Die Zahlen verdeutlichen, dass der Großteil der Aufträge auf der Plattform ortsungebunden sind und sowohl „Contests“ als auch „Local Jobs“ eine untergeordnete Rolle spielen. Aussagen zu den „Freelancer Services“ können nicht getroffen werden, da sich dieser Markt nicht öffentlich beobachten lässt. Aufgrund der geringen Relevanz werden daher sowohl „Contests“ als auch „Local Jobs“ in den nächsten Analyseschritten nicht weiter betrachtet. Auch die „Freelancer Services“ werden nicht weiter betrachtet, da es sich hierbei um einen internen Markt der Plattform handelt und hierüber keinerlei Informationen, abgesehen von der grundsätzlichen Funktionsweise, vorliegen.

3.2.3 Geschäftsmodell

Die Plattform generiert ihren Umsatz aus Provisionen, die sie für die Vermittlung der Aufträge zwischen Freelancer:innen und Auftraggebenden erhält. Sowohl die Registrierung und Angebotsabgabe von Freelancer:innen als auch die Registrierung und Veröffentlichung von Aufträgen durch Auftraggebende ist auf der Plattform zunächst kostenfrei (vgl. Tabelle 4). Kommt es zu einem Vertragsschluss („Awarded“), erhebt die Plattform eine Provision von 10 Prozent oder mind. 5 USD bei „Fixed Price“ Aufträgen vom Freelancer:in. Der Auftraggebende wird mit 3 Prozent oder mind. 3 USD bei „Fixed Price“ Aufträgen geringer belastet. Beide Akteur:innen haben die Möglichkeit, über Zusatzangebote ihre Chancen im Angebotsprozess oder bei der Akquirierung von Freelancer:innen zu erhöhen.

Hierunter zählt bspw. die Möglichkeit für Freelancer:innen, einen sogenannten „Sponsored Bid“ abzugeben und dadurch das Ranking zu umgehen und an erster Stelle gelistet zu sein. Über einen „Sealed Bid“ können Freelancer:innen ihre Angebotspreise vor anderen Freelancer:innen verbergen oder ihr Gebot über einen „Highlight Bid“ optisch von anderen Geboten abheben. Freelancer:innen haben somit gegen Entgelt die Möglichkeit, aktiven Einfluss in den Vergabeprozess zu nehmen und somit ihre Chancen auf Erhalt des Auftrags zu erhöhen.

Limitierend wirkt hingegen der Umstand, dass im Rahmen des kostenfreien Accounts die Anzahl an Geboten, die ein:e Freelancer:in innerhalb eines Monats abgeben kann, auf sechs begrenzt ist (Freelancer.com 2022b). Sofern ein:e Freelancer:in darüber hinaus auf Aufträge bieten will, müssen weitere Bids (1 \$ pro 5 Bids) erworben oder eine kostenpflichtige Mitgliedschaft in Anspruch genommen werden (vgl. Tabelle 5). Damit stellen die Bids auf der Plattform eine Art digitale Währung dar und schränken die Akquise neuer Projekte, insbesondere für neue Freelancer:innen, ein. Denn es ist davon auszugehen, dass gerade neue Freelancer:innen ohne entsprechende Reputation mehr Angebote abgeben müssen, um einen Auftrag zu erhalten.

Weiter haben Freelancer:innen die Möglichkeit, sich über das „Preferred Freelancer Program“ von anderen Freelancer:innen abzuheben. Als Kriterien dienen hierbei das Ranking der Freelancer:in, das unter den Top drei innerhalb der Skill-Kategorie liegen muss, die Verifizierung der Identität und E-Mail-Adresse, der Abschluss einer der vier Mitgliedschaften und das Absolvieren des gleichnamigen Tests (Exam) (Freelancer.com 2022a). Bei Erfüllung dieser Kriterien erhalten die Freelancer:innen Einladungen der Plattform zu höher dotierten Projekten, eine verzögerte Zahlung der Gebühren erst bei Zahlung durch den Auftraggebenden, Tipps zur Verbesserung des Profils, besseren Support durch die Plattform und einen Badge im Profil, der die Zugehörigkeit zum Programm anzeigt (Freelancer.com 2022o). Gleichzeitig steigt die Projektgebühr auf 15 Prozent des Auftragsvolumens.

Tabelle 4: Übersicht zu den Gebühren und Entgelten auf freelancer.com (1/2)

Personenkreis	Gebühren und Entgelte	Höhe
Freelancer:innen	Registrierung	Kostenfrei
	Angebotsabgabe (Bid)	Kostenfrei
	5 Bids	1 USD
	Sponsored Bid	0,75 % des Angebotspreises (min. 5 USD, max. 20 USD)
	Highlight Bid	1 USD
	Sealed Bid	0,10 USD
	Projektgebühr „Fixed Price“	10 % vom Projektvolumen, mind. 5 USD
	Projektgebühr „Hourly Project“	10 % vom Projektvolumen
	Preferred Freelancer Program	15 % vom Projektvolumen
Auftraggebende	Registrierung	Kostenfrei
	Auftragsvergabe (Posting)	Kostenfrei
	Featured	9 USD
	Urgent	9 USD
	Private	19 USD
	Full Time	199 USD
	Recruiter	9,50 USD
	Non-Disclosure Agreement (NDA)	19 USD
	IP Agreement	19 USD
	Sealed	9 USD
	Priority	5 USD
	Extend	9 USD
	Projektgebühr „Fixed Price“	3 % vom Projektvolumen (min. 3 USD)
	Projektgebühr „Hourly Project“	3 % vom Projektvolumen
Stornogebühr bis 7 Tage nach Awarding	Kostenfrei inkl. Rückerstattung der Projektgebühr	

Quelle: Freelancer.com (2022f)

Auch Auftraggebende können über die Zusatzangebote der Plattform den Vergabeprozess bis zu einem gewissen Grad steuern. Gegen die Zahlung von 9 USD werden bspw. Angebote von besonders qualifizierten Freelancer:innen versprochen („Featured“). Soll der Auftrag besonders schnell begonnen werden, hat der Auftraggebende die Möglichkeit diesen als „Urgent“ zu markieren und hierüber schneller Angebote von Freelancer:innen einzuholen. Gegen eine Gebühr von

9,50 USD kann der Auswahlprozess einer Freelancer:in vollständig an die Plattform abgegeben werden („Recruiter“). Ferner gestattet die Plattform dem Auftraggebenden, sein Projekt bis zu sieben Tage nach Beauftragung kostenfrei und gegen Rückerstattung der erhobenen Gebühren zu stornieren.

Eine weitere Einnahmequelle stellen Mitgliedschaften („Memberships“) dar. Freelancer:innen und Auftraggebende haben darüber die Möglichkeit, gegen eine monatliche oder jährliche Gebühr z. B. ihre Sichtbarkeit auf der Plattform zu erhöhen (vgl. Tabelle 5). Die Mitgliedschaft bündelt⁴² dabei Teile der zuvor dargestellten Zusatzangebote (vgl. Tabelle 4). Weiter kann das Listen von Projekten oder Freelancer:innen an oberster Position der Skill Kategorie gegen Zahlung von mind. 50 USD „Directory Fee“ erwirkt werden. Weitere Gebühren umfassen die Eröffnung von Schlichtungsverfahren, Transaktionsgebühren für Zahlungen, Guthabenabhebungen (abhängig vom Zahlungsmittel) oder eine Wartungsgebühr („Maintenance Fee“) für inaktive Accounts.

Tabelle 5: Übersicht zu den Gebühren und Entgelten auf freelancer.com (2/2)

Personenkreis	Gebühren und Entgelte	Höhe
Alle Akteure	Monatsgebühr Mitgliedschaften	
	Basic	4,95 USD
	Plus	9,95 USD
	Professional	29,95 USD
	Premier	59,95 USD
	Directory Fee	Min. 50 USD
	Schlichtungsgebühr bei Milestone-Payments	5 %, min. 5 USD
	Wartungsgebühr (Maintenance)	10 USD pro Monat
	Transaktionskosten für Kreditkarten, Paypal, Skrill	0,30 USD + 2,3 % vom Zahlbetrag
	Lokale Bankeinzahlung	Kostenfrei
	Internationale Überweisung	15 USD
	Guthabenabhebung (Express, Paypal, Skrill, Payoneer Debit Card)	Kostenfrei
Internationale Überweisung	25 USD	

Quelle: Freelancer.com (2022f)

⁴² Für die einzelnen Leistungen der Mitgliedschaften wird auf die dazugehörige Webseite verwiesen (Freelancer.com 2022j).

Zusammenfassend zeigt sich, dass die Plattform selbst nicht unerheblich an den vermittelten Aufträgen verdient und durch die Preisgestaltung indirekten Einfluss auf das Marktgeschehen nehmen kann. Aus der Börsennotierung von *freelancer.com* an der Australian Securities Exchange (ASX) und dem damit verbundenen Gewinninteresse im Sinne der Anteilseigner:innen leitet sich ab, dass es im Interesse der Plattform ist, sowohl möglichst viele Transaktionen abzuwickeln als auch möglichst großvolumige Projekte anzuziehen. Dies spiegelt sich auch in der Preisstruktur wider, die sich durch die prozentuale Provision anteilig am Auftragsvolumen bemisst und ein Gefälle zwischen dem, was Freelancer:innen und dem, was Auftraggebende zu zahlen haben, aufweist. Die Plattform ist sowohl darauf angewiesen, dass genügend qualifizierte Freelancer:innen ihre Dienstleistungen anbieten (Angebotsseite) als auch dass genügend Auftraggebende ihre Aufträge über die Plattform abwickeln wollen (Nachfrageseite). Die stärkere Provisionsbelastung von Freelancer:innen legt nahe, dass die Attraktivität der Plattform primär von der Nachfrageseite abhängt (Anzahl an verfügbaren Aufträgen) und die Angebotsseite (Anzahl der Freelancer:innen) für die Plattform kein limitierender Faktor ist. Auch die Stornierungsbedingungen von abgegebenen Geboten oder veröffentlichten Aufträgen sind zugunsten der Auftraggebenden ausgelegt. Denn diese erhalten bei Stornierung innerhalb von sieben Tagen nach Auftragserteilung alle Gebühren zurück. Dahingegen erhalten die Freelancer:innen nach Stornierung des Angebots nicht den verbrauchten Bid zurück und bei Zuteilung haben sie nicht ohne Nachteile die Möglichkeit, ihr Angebot zurückzuziehen.

3.2.4 Informationen zur Beurteilung der Plattformakteur:innen

Die weltweite Reichweite der Plattform und das damit einhergehende Aufeinandertreffen von Marktteilnehmenden aus zahlreichen Ländern mit den unterschiedlichsten Bildungssystemen und Kulturen erzeugt Unsicherheit bei der Beurteilung von Auftraggebenden und Freelancer:innen. Damit die Plattform selbst, aber auch alle anderen Akteur:innen auf *freelancer.com*, die Gegenseite besser bewerten und einschätzen können, erhebt die Plattform verschiedene

Informationen. Ausgehend von einer intensiven Recherche⁴³ lassen sich diese in fünf verschiedene Kategorien einsortieren. Dabei handelt es sich um Informationen, die Vertrauen vermitteln und motivieren sollen oder solchen, die zur Einschätzung der Arbeitsqualität, Aktivität oder des Umfangs der Nutzung der Plattformstrukturen dienen. Nicht alle der in Tabelle 6 bis Tabelle 8 dargestellten Informationen sind öffentlich. Einige werden lediglich intern von der Plattform zu Bewertungs- und Rankingzwecken genutzt (vgl. Abschnitt 3.2.5) und umfassen auch die Überwachung von Handlungen der Auftraggebenden und Freelancer:innen. Die letzten drei Spalten der Tabellen geben an, welche Informationen für welche Akteur:in zur Beurteilung der Gegenseite zur Verfügung stehen. Hierbei fällt die bereits zuvor beschriebene Informationsmacht der Plattform selbst auf (vgl. Abschnitt 3.2.1). Diese ist die einzige Akteur:in, die sämtliche Informationen über Auftraggebende und Freelancer:innen hat und deren Aktivitäten und Arbeitsweise vollumfänglich überwachen kann. Dabei beschränkt sie sich nicht nur auf Ratings und die Anzahl an Bewertungen, die Auftraggebende und Freelancer:innen erhalten, sondern analysiert bspw. zur Vermeidung von Offsiting⁴⁴ ebenfalls stichprobenartig die Kommunikation zwischen den Akteur:innen auf verdächtige Stichwörter. Damit greift die Plattform tief in die Geschäftsbeziehungen der Akteur:innen ein, um sicherzustellen, dass sämtliche Aktivität auf der Plattform verbleibt und ihr keine Provisionen verloren gehen.

⁴³ Die in diesem Abschnitt dargestellten Indikatoren wurden sowohl über eine Recherche der Blogeinträge auf der Community Webseite der Plattform als auch über das Einsehen von diversen Freelancer:innen Profile erhoben (Freelancer.com 2022e).

⁴⁴ Hierbei handelt es sich um ein Ausweichverhalten der Akteur:innen auf Kommunikation oder die Auftragsvergabe außerhalb der Plattform.

Tabelle 6: Plattformerhobene Informationen zur Beurteilung der Plattformeakteur:innen (1/3)

Kategorie	Information	Bedeutung	Veröffent- lichung	Plattform	Auftraggebende	Freelancer:innen
Vertrauen	Verifications (Trust Score)	Know Your Customer (KYC) Programm dient der Verifizierung der Akteur:innen auf der Plattform: Identität, Zahlung, Telefon, E-Mail, Facebook, Made a Deposit	Öffentlich	X	X	X
	Spamming employers	Prüfung, ob Freelancer:innen Nachrichten an Auftraggebende versenden, zu denen keine aktive Projektbeziehung besteht	Intern	X		
	Offsiting	Prüfung, ob Akteur:innen dazu auffordern, außerhalb der Plattform zu kommunizieren	Intern	X		
	Profile Marks	Bewertung der Freelancer:innen Profile durch die Plattform	Intern	X		
	Freelancer Verified Program	Aufbauend auf dem KYC Programm Verifizierung der Identität durch ein Videotelefonat mit der Plattform	Öffentlich	X	X	
	Membership Badge	Signalisiert kostenpflichtige Mitgliedschaft im Profil der Freelancer:innen	Öffentlich	X	X	
	Jobs Completed	Anteil der abgeschlossenen Aufträge an allen angenommenen Aufträgen	Öffentlich	X	X	
	On Time	Anteil der innerhalb der Lieferfrist abgeschlossenen Aufträge an allen angenommenen Aufträgen	Öffentlich	X	X	
	On Budget	Anteil der innerhalb des Budgets abgeschlossenen Aufträge an allen angenommenen Aufträgen	Öffentlich	X	X	
	Repeat Hire Rate	Anteil der Auftraggebenden, die den Freelancer:in mehrfach beauftragt haben, an allen Auftraggebenden	Öffentlich	X	X	
	Joined at	Zeitpunkt der Registrierung auf der Plattform	Öffentlich	X	X	

Quelle: Freelancer.com (2016b, 2017a, 2021a, 2021c, 2022f)

Tabelle 7: Plattformerhobene Informationen zur Beurteilung der Plattformakteur:innen (2/3)

Kategorie	Information	Bedeutung	Veröffent- lichung	Plattform	Auftraggebende	Freelancer:innen
Vertrauen	Profilfoto	Plattform empfiehlt ein Foto auf der die Freelancer:in als Person zu erkennen ist	Öffentlich	X	X	
	Profilname	Klarname und Pseudonym	Öffentlich	X	X	
	Ortsangabe	Stadt, Land	Öffentlich	X	X	X
Qualität	Quality of Work	Bewertung Skala 1–5 durch Auftraggebenden	Intern	X		
	Communication	Bewertung Skala 1–5 durch Auftraggebenden	Intern	X		
	Expertise	Bewertung Skala 1–5 durch Auftraggebenden	Intern	X		
	Professionalism	Bewertung Skala 1–5 durch Auftraggebenden	Intern	X		
	Repeat Hire	Bewertung Skala 1–5 durch Auftraggebenden	Intern	X		
	Qualität Auftraggebender	Bewertungen erfahrener Auftraggebenden sind wichtiger	Intern	X		X
	Beschwerden von Auftraggebenden	Fehlverhalten der Freelancer:in wird von der Plattform negativ bewertet	Intern	X		
	Rating	Mittelwert aus Bewertung von Quality of Work, Communication, Expertise, Professionalism, Repeat Hire	Öffentlich	X	X	X
	Exams im Skill-Lab	Freelancer:innen können Prüfungen im plattformeigenen Skill-Lab ablegen	Öffentlich	X	X	
	Recommendations	Absolute Anzahl an Auftraggebenden, die Freelancer:in weiterempfehlen	Öffentlich	X	X	
	Freiwillige Angaben	Bildung, Berufserfahrung, Zertifikate, Publikationen	Öffentlich	X	X	

Quelle: Freelancer.com (2016b, 2017a, 2021a, 2021c, 2022f)

Tabelle 8: Plattformerhobene Informationen zur Beurteilung der Plattformakteur:innen (3/3)

Kategorie	Information	Bedeutung	Veröffent- lichung	Plattform	Auftraggebende	Freelancer:innen
Motivation	Experience Points	Durch die Erreichung von Zielen (Badges) erhält die Freelancer:in Experience Points (XP)	Intern	X		
	Reward Levels	Mit zunehmenden Experience Points können höhere Reward Levels erreicht werden	Intern	X		
	Credits	Digitale Währung, die die Freelancer:innen für das Erreichen von Zielen und Aktionen erhalten.	Intern	X		
Aktivität	Accept Rate	Annahmequote von Aufträgen	Intern	X		
	Respon-siveness	Zeitnahe Reaktion auf Nachrichten von Auftraggebenden	Intern	X		
	Screenshots	Erstellung automatischer Screenshots in Desktop-App zur Arbeitskontrolle	Intern	X		
	Anzahl an Bewertungen (Reviews)	Absolute Anzahl an erhaltenen Bewertungen	Öffentlich	X	X	X
	Projekt-volumen	Kumuliertes Projektvolumen abgeschlossener Projekte	Öffentlich	X	X	
Plattform-strukturen	Milestone Payments	Häufigkeit der Nutzung und Volumen der Milestone Payments	Intern	X		
	Desktop-App	Anzahl erfasster und Volumen bezahlter Arbeitsstunden über die Desktop-App	Intern	X		

Quelle: Freelancer.com (2016b, 2022d)

Ein weiteres Beispiel für diese Art von Kontrolle stellt die Nutzung der Desktop-App dar. Die Plattform bewirbt diese mit zahlreichen Vorteilen für Auftraggebende und Freelancer:innen. Die Nutzung der App soll den Auftraggebenden Vertrauen signalisieren, da darüber der Auftraggebende die Arbeit engmaschiger kontrollieren kann. Sie wirbt mit direkteren Kommunikationstools und gesteigerten Einkommen für Freelancer:innen. Vor allem ermöglicht die App jedoch eine strikte Arbeitskontrolle durch die Plattform und den Auftraggebenden. Freelancer:innen

können darüber ihre Arbeitszeit sekundengenau erfassen und sind einem Automatismus ausgesetzt, der in regelmäßigen Abständen Screenshots vom Desktop erstellt, die sowohl die Plattform als auch der:die Auftraggebende einsehen kann (Freelancer.com 2022d). Um auf der Plattform erfolgreich zu sein, sind Freelancer:innen de facto gezwungen, solche Tools zu nutzen und damit der Kontrolle von Plattform und Auftraggebenden ausgeliefert (vgl. Abschnitt 3.2.5). Diese engmaschige Überwachung ist unter Freelancing-Marktplätzen verbreitet (z. B. Upwork.com 2020b), sodass Freelancer:innen kaum Außenoptionen bleiben (Schmidt 2016:14).

Alle Informationen, die öffentlich einsehbar sind, betreffen Freelancer:innen und geben den Auftraggebenden eine detaillierte Möglichkeit zur Einschätzung der Zuverlässigkeit, Qualität, Aktivität und allem voran auch des Geschlechts. Neben dem Rating, der Anzahl an Bewertungen und dem bisherigen Projektvolumen, stehen den Auftraggebenden Informationen über die Leistungen der Freelancer:in aus vergangenen Projekten zur Verfügung. Hierunter z. B., ob die Freelancer:in innerhalb des vorgegebenen Zeitrahmens (On Time) und Budgets (On Budget) die Dienstleistung erbracht hat. Weiter ist ersichtlich, wie lange die Freelancer:in auf der Plattform registriert ist (Joined at), ob sie von anderen Auftraggebenden weiterempfohlen werden (Recommendations) und bspw., welche Prüfungen auf der Plattform abgelegt wurden (Exams). Freiwillig können die Freelancer:innen auch weitere Angaben zu Erfahrungen außerhalb der Plattform tätigen, z. B. zum Bildungsstatus oder anderen Qualifikationen, Berufserfahrung oder Veröffentlichungen. Auftraggebenden ist es möglich indirekt über das Profilfoto oder über den Profilnamen, das Geschlecht der Freelancer:in zu bestimmen.

Freelancer:innen stehen auf der Plattform die wenigsten Informationen zur Beurteilung der Auftraggebenden zur Verfügung. Die einzige Möglichkeit, diese einzuschätzen, besteht darin, das Rating, die Anzahl der Bewertungen, den Ort des Auftraggebenden und die Verifizierungen der Plattform heranzuziehen. Das Geschlecht des Auftraggebenden bleibt unbekannt.

Die vorgenannten Punkte verdeutlichen die bereits in Abschnitt 3.1.3 beschriebene hohe Informationsasymmetrie auf der Plattform. Damit gehen Unsicherheiten in der Beziehung zwischen den Akteur:innen einher, die ungleich verteilt sind. So können

sich Auftraggebende ein genaues Bild über die Person inkl. dem Geschlecht machen, die ihren Auftrag ausführen soll. Freelancer:innen hingegen können sich nur auf wenige Angaben stützen, um auszumachen, ob der Auftraggebende verlässlich ist und am Ende auch die erbrachte Dienstleistung bezahlt. Gleichzeitig kann die Plattform sämtliche Informationen zur Marktsteuerung nutzen. Hieraus ergibt sich ein Machtungleichgewicht zulasten der Freelancer:innen.

3.2.5 Algorithmisches Management

Die Nutzung von Algorithmen zur Organisation und Steuerung des Marktgeschehens ist elementarer Bestandteil von Plattformen im Allgemeinen. Denn erst die Analyse großer Datenmengen und die Orchestrierung der Handlungen der Akteur:innen durch Algorithmen machen die Geschäftsmodelle der Plattformen skalierbar und profitabel (Schmidt 2016:11). Auch auf der Plattform *freelancer.com* kommen Algorithmen zum Einsatz. Freelancer:innen werden bspw. bei dem Produkt „Freelancer Services“ mithilfe eines Algorithmus Aufträgen zugewiesen oder erhalten Vorschläge für Aufträge in Abhängigkeit der im Profil angegebenen Skills.

Der Algorithmus mit dem mutmaßlich größten Einfluss auf die Beauftragungsentscheidung der Auftraggebenden ist der Rankingalgorithmus. Dieser berechnet für jede Freelancer:in anhand von bestimmten öffentlichen und internen Kriterien einen Score. Dieser hat direkten Einfluss auf die Reihenfolge der Freelancer:innen in der „Bidlist“ eines Projektes. Diese listet sämtliche Angebote der Freelancer:innen auf und ist standardmäßig anhand des Scores sortiert (Freelancer.com 2014). Weiter werden dem Auftraggebenden lediglich acht Gebote pro Seite angezeigt, d. h. es besteht ein Anreiz für Freelancer:innen auf dieser ersten Seite und damit unter den Top acht Freelancer:innen pro Auftrag zu landen (Freelancer.com 2016b). Auch sind die Auflistungen von Freelancer:innen bei der freien Suche und bei der Suche anhand spezifischer Skills ebenfalls anhand des Scores sortiert. Damit kommt dem Rankingalgorithmus eine bedeutende Rolle auf der Plattform zu.

Der Rankingalgorithmus bezieht Informationen aus vier Kategorien in seine Berechnung mit ein (vgl. Tabelle 9). Der Algorithmus honoriert die Anzahl an Bewertungen und die Ratinghöhe positiv und legt dabei ein besonderes Gewicht auf

die aktuellen Bewertungen und solche, die von erfahreneren Auftraggebern stammen. Ein nicht linearer, aber positiver Zusammenhang besteht zwischen dem Volumen von positiv bewerteten Aufträgen und dem jeweiligen Score der Freelancer:innen. Auch einzelne Plattformbestandteile, wie die Nutzung von Milestone Zahlungen und der Desktop-App zur Erfassung der geleisteten Stunden, wirken sich positiv auf den Score aus. Beschwerden von Auftraggebern hingegen können negativen Einfluss nehmen. Auch das wiederholte Ablehnen von Aufträgen (bei abgegebenem Gebot) und das wiederholte Anschreiben von Auftraggebern ohne eine aktive Auftragsbeziehung (Spamming) wird negativ gewertet, genauso wie der Versuch außerhalb der Plattform, mit Auftraggebern zu kommunizieren (Offsiting), das sogar in einem Plattformausschluss enden kann.

Tabelle 9: Einflussfaktoren des Rankingalgorithmus

Kategorie	Ranking Faktor	Wirkungsrichtung
Bewertungen und Feedback	Aktualität der Bewertungen	+
	Anzahl an Bewertungen	+
	Volumen vergangener Projekte	+
	Erfahrung des Bewertenden	+
Nutzung von Milestone Zahlungen	Gesamtbetrag der über Milestone Zahlungen generiert wurde	+
	Durchschnittliche Nutzung von Milestone Zahlungen	+
	Anzahl erfasster und bezahlter Stunden über die Desktop-App	+
	Durchschnittliche Anzahl erfasster und bezahlter Stunden über die Desktop-App je Projekt	+
	Beschwerden von Auftraggebern	-
Reaktionsvermögen	Akzeptanzrate	+
	Reaktionsvermögen	+
	Spamming employers	-
	Offsiting	-
Qualität des Profils	Exams	+
	Profile Marks (u. a. Verifications)	+

Quelle: Freelancer.com (2016b)

Reagiert die Freelancer:in hingegen schnell auf Nachrichten, hat viele Exams im Skilllab erfolgreich absolviert und weist ein qualitativ gutes Profil auf, hat das positiven Einfluss auf den Score. Die Plattform berechnet den Score skillspezifisch. Dies bedeutet, dass z. B. der Erhalt einer 5-Sterne-Bewertung für den Skill

Webdesign den skillspezifischen Score stärker positiv beeinflusst als den Score einer anderen Skill Kategorie.

Trotz der Offenlegung der Einflussfaktoren auf den Score bleibt unklar, inwiefern die Plattform die einzelnen Kategorien und Faktoren gewichtet. Zuletzt wird im Jahr 2020 über eine Anpassung des Algorithmus informiert (Freelancer.com 2020). Hierbei wird die Gewichtung so verändert, dass das Projektvolumen ein höheres Gewicht und sich der Einfluss auf den Score proportional zum Projektvolumen verhält. Auch in der Beschreibung, was z. B. ein qualitativ gutes Profil ist, bleibt die Plattform vage und behält sich damit Interpretationsspielraum. Alle Akteur:innen auf der Plattform sind dem Algorithmus und den Spielräumen der Plattform ausgeliefert, ohne dass sie hierauf Einfluss nehmen könnten.

3.3 Zwischenfazit und Ableitung von Hypothesen

Die vorangegangenen Abschnitte haben einen Eindruck vermittelt, wie die Plattform funktioniert, welche Interessen die Plattform verfolgt, welche Informationen den jeweiligen Akteur:innen zur Verfügung stehen und welche weiteren plattformspezifischen Mechanismen wirken. In Kombination mit der Informationsasymmetrie zwischen Plattform, Auftraggebenden und Auftragnehmenden ergeben sich hieraus verschiedene Diskriminierungspotenziale anhand des Geschlechts. Diese können sowohl bei der Beauftragung durch die Auftraggebenden als auch durch die Plattform selbst auftreten. Beide Aspekte werden in den nächsten Abschnitten genauer beschrieben und hieraus Hypothesen für den empirischen Teil dieser Arbeit abgeleitet.

3.3.1 Geschlechterstereotype in Beauftragung und Angebotspreisen

Eine Möglichkeit zur direkten Geschlechterdiskriminierung bietet sich für die Auftraggebenden bei der Selektion der Freelancer:innen. Freelancer:innen bewerben sich auf Projektausschreibungen unter Angabe von Preis, Lieferzeit und einem kurzen beschreibenden Text. Gleichzeitig hat der Auftraggebende die Möglichkeit, Ratings, die Anzahl an Bewertungen und sämtliche Informationen über die Freelancer:in in ihrem Profil einzusehen und auf dieser Basis den Auftrag zu vergeben. Daher gilt es zunächst zu prüfen, ob sich Unterschiede in den Beauftragungswahrscheinlichkeiten von weiblichen und männlichen Freelancern feststellen lassen:

H1 Die Beauftragungswahrscheinlichkeit von Freelancer:innen unterscheidet sich nach dem Geschlecht.

Die Antizipation unterschiedlicher Beauftragungswahrscheinlichkeiten durch die Freelancer:innen kann Auswirkungen auf die Angebotspreise haben. So ist bspw. denkbar, dass Freelancer:innen bewusst niedrigere Preise ansetzen, um ihre Chancen auf den Auftrag zu erhöhen (Foong et al. 2018; Gomez-Herrera und Mueller-Langer 2019; Roussille 2022). Daher wird weiter geprüft, ob sich die Angebotspreise nach dem Geschlecht der Freelancer:innen unterscheiden:

H2 Der Angebotspreis von Freelancer:innen unterscheidet sich nach dem Geschlecht.

In der bisherigen Forschung hat sich gezeigt, dass die Geschlechterunterschiede insbesondere abhängig von den betrachteten Tätigkeitskategorien sind (Chan und Wang 2018; Dubey et al. 2017; Galperin 2021:1099; Leung und Koppman 2018:797). Dabei zeigen sich die größten Unterschiede zwischen den Geschlechtern in geschlechtstypischen Tätigkeitskategorien. In einem ersten Schritt soll daher bestimmt werden, ob sich Unterschiede in den Geschlechterverhältnissen in den jeweiligen Tätigkeitskategorien auf der Plattform feststellen und ob sich hieraus geschlechtstypische Tätigkeitskategorien identifizieren lassen:

H3 Die Tätigkeitskategorien der Plattform weisen unterschiedliche Geschlechterverhältnisse auf.

Anschließend sollen Hinweise dafür gefunden werden, ob Auftraggebende Geschlechterstereotype in ihrer Beauftragungsentscheidung nutzen. Ein Indiz dafür wäre, wenn die Beauftragungswahrscheinlichkeit eines Geschlechts gegenüber dem anderen in den geschlechtstypischen Tätigkeitskategorien anders ausfallen. Daher wird für die Tätigkeitskategorien folgende Hypothese überprüft:

H4 Weibliche und männliche Freelancer weisen unterschiedliche Beauftragungswahrscheinlichkeiten in geschlechtstypischen Tätigkeitskategorien auf.

Sofern Freelancer:innen antizipieren, dass Auftraggebende in bestimmten Tätigkeitskategorien ein bestimmtes Geschlecht bevorzugt beauftragen, wäre es für das jeweils atypische Geschlecht unter Umständen sinnvoll, einen niedrigeren

Angebotspreis anzusetzen, um darüber seine Beauftragungswahrscheinlichkeit für den Auftrag zu erhöhen (Foong et al. 2018; Gomez-Herrera und Mueller-Langer 2019; Roussille 2022). Ist der Preisnachlass hinreichend groß, dürfte der Auftraggebende gewillt sein, das atypische Geschlecht zu beauftragen, da er für die damit verbundene Unsicherheit entschädigt wird. Ob ein solches Verhalten in den Tätigkeitskategorien beobachtet werden kann, soll durch folgende Hypothese überprüft werden:

H5 Weibliche und männliche Freelancer verlangen unterschiedliche Angebotspreise in geschlechtstypischen Tätigkeitskategorien.

3.3.2 Einfluss des Rankingalgorithmus auf die Beauftragungswahrscheinlichkeit

Die Plattform selbst hat als Intermediär eine besondere Rolle, da sie über sämtliche Informationen aller Akteur:innen verfügt. Direkte Diskriminierung ihrerseits wäre daher denkbar, indem sie bspw. ein Geschlecht besonders intensiv überwacht (z. B. bei Spamming oder Offsiting control), Freelancer:innen Profile eines bestimmten Geschlechts schlechter bewertet (Profile marks) oder aber den Marktzugang für bestimmte Geschlechter ganz oder in Abhängigkeit der Tätigkeitskategorie oder Marktsituation verwehrt. Dagegen spricht, dass Plattformen von ihren Netzwerkeffekten profitieren und generell ein großes Interesse an hohen Nutzendenzahlen und damit höheren Marktanteilen haben (vgl. Abschnitt 2.1.2 und 3.2.3). Es kann daher davon ausgegangen werden, dass eine direkte Diskriminierung von potenziellen Marktteilnehmenden anhand des Geschlechts nicht im Interesse der Plattform liegt.

Dennoch ist indirekte Diskriminierung denkbar, die über die Marktstrukturen und -mechanismen der Plattform auftreten kann. Eine besondere Rolle spielt dabei der plattformeigene Rankingalgorithmus. Die ersten acht Freelancer:innen, die Auftraggebenden auf der ersten Seite der Bidlist⁴⁵ vorgeschlagen werden, sind standardmäßig anhand ihres Scores absteigend sortiert (vgl. Abschnitt 3.2.5). Die Berechnung des Scores beruht auf dem plattformeigenen Rankingalgorithmus. Laut Plattform bezieht dieser zwar das Geschlecht als Inputfaktor der Scoreberechnung

⁴⁵ Bidlist wird auf der Plattform jene Liste genannt, die alle Angebote der Freelancer:innen für einen Auftrag absteigend nach deren Score auflistet (vgl. Abschnitt 3.2.5).

nicht explizit mit ein, es besteht jedoch die Gefahr, dass er über indirekte Diskriminierung dazu beitragen kann, dass sich Geschlechterstereotype manifestieren.

Grundsätzlich führt der Rankingalgorithmus dazu, dass besonders erfolgreiche (z. B. hohe Ratings) und aktive Freelancer:innen (z. B. abgeschlossene Projektvolumen oder Reaktionsvermögen) einen hohen skillspezifischen Score und damit ein besseres (niedrigeres) Ranking erhalten. Geht damit eine höhere Beauftragungswahrscheinlichkeit einher, ist anzunehmen, dass Freelancer:innen mit besserem Ranking noch mehr Aufträge absolvieren können. Das ist dem Geschäftsmodell der Plattform (vgl. Abschnitt 3.2.3) zuträglich, denn die höchsten Kosten entstehen bei Gründung. Die Grenzkosten je Nutzenden wiederum müssen so niedrig wie möglich sein, sodass die Plattform exponentiell wachsen kann, ohne dass entsprechende Ressourcen proportional dafür bereitgestellt werden müssen (vgl. Abschnitt 2.1.2) (Schmidt 2016:11). Es ist daher anzunehmen, dass jede:jeder zusätzliche Nutzende zwar gewisse Kosten bei der Registrierung und dem Durchlauf der Verifizierungsprozesse erzeugt, die anschließenden Aufwendungen durch die Nutzung der Plattform aber aufgrund der vollständigen Automatisierung vernachlässigbar gering sind. Dies bedeutet, dass die Plattform von jeder weiteren Transaktion, welche die Freelancer:in über die Plattform absolviert, profitiert. Besonders aktive Freelancer:innen tragen damit überproportional zum Geschäftserfolg der Plattform bei und genau diese werden durch den Rankingalgorithmus gefördert. Neuen Freelancer:innen wird es damit erschwert, sich auf der Plattform zu etablieren. Aus Geschlechterperspektive ist dies dann problematisch, wenn die Bevorzugung zulasten eines Geschlechts geht und sich dadurch eine Chancenungleichheit auf der Plattform verfestigt. Aufgrund der skillspezifischen Scoreberechnung besteht die Gefahr, dass der Rankingalgorithmus zur Manifestierung von Geschlechterstereotypen beiträgt. In einem ersten Schritt ist daher zu klären, ob sich die Ränge zwischen weiblichen und männlichen Freelancern in den jeweiligen Tätigkeitskategorien unterscheiden und ob der Rang einen Einfluss auf die Beauftragungswahrscheinlichkeit hat:

H6 Weibliche und männliche Freelancer weisen unterschiedliche Ränge in geschlechtstypischen Tätigkeitskategorien auf.

***H7 Ein besserer Rang geht mit einer höheren
Beauftragungswahrscheinlichkeit einher.***

Unter der Annahme, dass sich Indizien für die Nutzung von Geschlechterstereotypen bei der Beauftragung von Freelancer:innen durch Auftraggebende (vgl. H4) gefunden haben, wäre weiter zu erwarten, dass sich der Effekt eines besseren Rankings auf die Beauftragungswahrscheinlichkeit zwischen den Geschlechtern in Abhängigkeit der Tätigkeitskategorie unterscheidet.

***H8 Der Effekt eines besseren Rangs auf die
Beauftragungswahrscheinlichkeit ist für weibliche und männliche
Freelancer in geschlechtstypischen Tätigkeitskategorien unterschiedlich.***

Anders ausgedrückt muss das für die Tätigkeitskategorie atypische Geschlecht einen deutlich besseren Rang im Vergleich zum typischen Geschlecht aufweisen, um vergleichbare Beauftragungswahrscheinlichkeiten zu haben. Dies würde darauf hindeuten, dass der Auftraggebende nur bereit ist, atypische Freelancer:innen zu beauftragen, wenn sie einen hinreichend besseren Rang aufweisen als typische Freelancer:innen. Atypische Freelancer:innen hätten es damit ungleich schwerer, an Aufträge außerhalb ihrer typischen Tätigkeitskategorien zu kommen. Dadurch würde der Rankingalgorithmus bestehende Geschlechterstereotype weiter verfestigen.

4 Methodisches Vorgehen

Die zuvor hergeleiteten Hypothesen sollen im Rahmen dieser Arbeit einer empirischen Überprüfung unterzogen werden. In diesem Kapitel werden die dafür genutzte Datenerhebung, die durchgeführte Datenbereinigung sowie die Methoden, anhand derer die Daten analysiert werden, beschrieben.

4.1 Datenerhebung

Zunächst werden mögliche Erhebungsverfahren diskutiert und die Wahl des hier genutzten Verfahrens begründet. Anschließend erfolgt eine kurze Beschreibung des Erhebungsverfahrens und es werden ethische Punkte dieser Datenerhebung diskutiert.

4.1.1 Wahl des Erhebungsverfahrens

Die systematische statistische Erfassung der Plattformökonomie steht noch am Anfang. In der amtlichen Statistik bspw. ist ein Ausweis der Plattformökonomie bisher noch nicht gängig. Auf EU-Ebene gibt es jedoch erste Bestrebungen, dies für den Tourismusbereich zu ändern (Eurostat 2022). Der in dieser Arbeit betrachtete Teil der Plattformökonomie wird bisher von amtlicher Seite noch nicht explizit erfasst. Zur Datenerhebung haben sich daher in bisherigen Studien drei Herangehensweisen etabliert. Einige Studien haben die Möglichkeit auf die Datenbanken der Plattformen selbst zuzugreifen (z. B. Chan und Wang 2018; Dubey et al. 2017; Galperin 2021; Gomez-Herrera und Mueller-Langer 2019; Leung und Koppman 2018; Litman et al. 2020; Mill 2011; Roussille 2022)., andere führen Befragungen unter Plattformarbeitenden durch (z. B. Abendroth 2021; Aleksynska et al. 2018; Bohren et al. 2019; Leung et al. 2020) und ein weiterer Teil nutzt die Methode des Web-Scrapings zur Datenerhebung (z. B. Cui et al. 2020; Dube et al. 2020; Edelman et al. 2017; Foong et al. 2018; Hannàk et al. 2017; Jinnai 2016; Kässi und Lehdonvirta 2018). Jede der Erhebungsmethoden weist Vor- und Nachteile auf.

So bietet der vollständige Datenzugriff auf die Prozessdaten der Plattformen, z. B. über eine Programmierschnittstelle (Application Programming Interface (API)) oder Datenüberlassung, den Vorteil, dass eine sehr hohe Abdeckung für diese Plattform

erreicht wird. Überdies können diese Datensätze auch plattforminterne Daten (z. B. Metadaten) enthalten, die über die anderen beiden Erhebungsmethoden nicht beobachtbar sind. Die Datenbereitstellung kann für die Plattform hingegen aufwendig und mit Kosten verbunden sein. Zusätzlich besteht die Ungewissheit, dass die aus den Daten resultierenden Forschungsergebnisse auch Negatives der Plattform hervorbringen und das negative Effekte auf deren Kundenbeziehungen haben kann (Horton und Tambe 2015:11 f.). Dies hat zur Folge, dass Plattformen mit der Bereitstellung ihrer Daten sehr restriktiv umgehen und diese der Forschung kaum zur Verfügung stehen. Eine für diese Dissertation gestellte Datenanfrage blieb von der Plattform aus nicht weiter bekannten Gründen unbeantwortet.

Befragungen haben den Vorteil, dass sowohl quantitative als auch qualitative Daten gewonnen werden können. Hierdurch können Aspekte in der Analyse berücksichtigt werden, welche über die einer quantitativen Analyse hinausgehen. Diesem Vorteil gegenübersteht die herausfordernde Rekrutierung von Befragungsteilnehmer:innen. In der Literatur werden hierzu oftmals Aufträge auf den Plattformen veröffentlicht (z. B. Cotropia et al. 2018; Difallah et al. 2018; Leung et al. 2020). Plattformarbeitende können sich dann bewerben und werden nach erfolgreicher Durchführung der Umfrage auch entlohnt. Dies setzt zum einen voraus, dass die Plattform solche Aufträge veröffentlicht und zum anderen, dass dem Forschenden ein gewisses Budget zur Entlohnung der Plattformarbeitenden zur Verfügung steht. Der Freelancing-Marktplatz *freelancer.com* weist in der Liste der Tätigkeitskategorien keine explizite Kategorie für Umfragen aus (Freelancer.com 2022c). Es ist unklar und mit einem gewissen Risiko behaftet, ob sich ein solches Projekt auf der Plattform platzieren lässt. Neben den nicht gegebenen finanziellen Ressourcen kommt hinzu, dass die Generierung einer hinreichend großen Stichprobe für den in dieser Arbeit gewählten quantitativen Analyseansatz nur unter erheblichem Einsatz von zeitlichen Ressourcen möglich wäre. Aus diesen Gründen wird diese Erhebungsmethode nicht genutzt.

Eine weitere Möglichkeit Daten zu erheben, ist das sogenannte Web-Scraping. Hierbei handelt es sich um das automatisierte Auslesen von Webseiten. Diese Erhebungsmethode hat den Vorteil, dass Daten in Echtzeit, in großem Umfang, wenn nötig über einen längeren Zeitraum und nahezu kostenneutral erhoben werden können. Die Methode findet daher auch zunehmend in den amtlichen

Statistiken Anwendung (Kühnemann 2021). Anders als bei einem Vollzugriff auf die Datenbank, können jedoch nur jene Daten erhoben werden, die auch für jeden Webseitenbesucher ersichtlich sind, sowie, aufgrund begrenzter Rechen- und Serverkapazitäten, immer nur Stichproben der Webseiten.

Der Untersuchungsgegenstand dieser Dissertation ist ein vollständig onlinebasierter Freelancing-Marktplatz, der Informationen über die vermittelten Aufträge, Auftraggebende und Freelancer:innen in großen Mengen über die Webseite öffentlich zugänglich bereithält. Hinzukommt, dass die Geschwindigkeit, in der Transaktionen auf der Plattform abgewickelt werden, enorm ist und eine sehr zeitnahe Erfassung der Daten damit notwendig ist. Diese Erfordernisse überwiegen mögliche Nachteile dieses Erhebungsverfahrens, weshalb im Rahmen dieser Dissertation ein Web-Scraper für den Freelancing-Marktplatz *freelancer.com* programmiert wurde.

4.1.2 Datenerhebung mittels Web-Scraping

Der in der Programmiersprache Python entwickelte Web-Scraper basiert auf dem freien Open Source Framework mit dem Namen Scrapy (Scrapy Developers 2022). Die Entscheidung für dieses Framework beruht auf ihren Eigenschaften, die für die angedachte Datenerhebung vorteilhaft sind. Das Framework basiert auf einer asynchronen Netzwerkprogrammierung (Twisted) und ist dadurch in der Lage, z. B. die Webanfrage auf Basis des Uniform Resource Locators (URL) als auch das Auslesen des daraus resultierenden HTML-Quellcodes (sog. Parsing) unabhängig voneinander vorzunehmen, woraus ein enormer Leistungsvorteil gegenüber anderen Frameworks resultiert. Überdies bietet Scrapy eine Reihe nützlicher Konfigurationsmöglichkeiten für die Performancesteuering (z. B. eine automatische Geschwindigkeitskontrolle sog. Autothrottling), Datenaufbereitung (sog. Item Pipelines) und ermöglicht die komfortable Speicherung der extrahierten Daten in einer auswertbaren Form in einer Datenbank.

Die Datenerhebung fand ganztägig über sechs Monate im Zeitraum von Dezember 2021 bis Ende Mai 2022 statt. Der Scraper hat in diesem Zeitraum Informationen zu den Freelancer:innen, Angebotspreise, Lieferfristen, Rankings je Auftrag, Herkunftsinformationen, Bewertungs- und Performancekennzahlen und weitere Angaben der Freelancer:in wie Bildung, Berufserfahrung und weitere

Qualifikationen gesammelt. Im Erhebungszeitraum konnten insgesamt 544.076 Angebote von Freelancer:innen, die auf 33.510 Aufträge und 78.201 Profile entfallen, erfasst werden. Für insgesamt 3.556 Aufträge konnte ebenfalls der:die beauftragte Freelancer:in beobachtet werden. Die Diskrepanz zwischen den insgesamt beobachteten Aufträgen und solchen, für die die Beauftragung beobachtet werden konnte, begründet sich maßgeblich darin, dass eine große Anzahl an Aufträgen entweder gelöscht oder vorzeitig beendet wurde, ohne dass es zu einer Beauftragung über die Plattform kam. Ein weiterer Grund ist, dass der Scraper den:die beauftragten Freelancer:in nicht erfasst hat. Dieser Fall kann eintreten, wenn sich ein:e Freelancer:in zwischen zwei Durchläufen (Dauer ca. 30 Minuten) sowohl beworben als auch den Zuschlag erhalten hat. Diese Performancelimitation wurde bewusst hingenommen, um einerseits genügend Aufträge gleichzeitig beobachten zu können und andererseits die Serverauslastung der Webseite zu schonen.

Die kontinuierliche Erhebung über sechs Monate und der Abruf neu eingestellter Aufträge von unterschiedlichsten Auftraggebern und Tätigkeitskategorien approximiert eine zufällige Auswahl von Aufträgen. Hierdurch werden Selektionseffekte minimiert, die durch eine gezielte Auswahl von bestimmten Aufträgen oder die Beschränkung auf nur bestimmte Auftraggebende entstehen könnten. Die so gewonnene Datenbank bildet die Grundlage für die empirische Untersuchung der in Kapitel 3.3 aufgestellten Hypothesen.

4.1.3 Rechtliche und ethische Aspekte des Web-Scraping

Neben der technischen Machbarkeit der Datenerhebung durch Web-Scraping gibt es auch rechtliche und ethische Aspekte zu beachten. Die Datenerhebung im Rahmen dieser Dissertation erfolgt unter Berücksichtigung rechtlicher und forschungsethischer Grundsätze⁴⁶.

Die rechtlichen Grundsätze werden über die Orientierung an den Kriterien aus dem im Auftrag des Wissenschaftszentrums Berlin für Sozialforschung gGmbH (WZB) – Rat für Sozial- und Wirtschaftsdaten (RatSWD) erstellten Gutachten für den rechtskonformen Einsatz von Web-Scraping in der Forschung erfüllt (Vogel und

⁴⁶ Eine Übersicht von fachübergreifenden und fachspezifischen Ethik-Leitlinien kann auf der Internetseite des Rats für Sozial- und Wirtschaftsdaten entnommen werden (RatSWD 2022).

Hilgendorf 2019:45 f.). Diese besagen, dass die auszuwertenden Informationen allgemein zugänglich sein und zur Erfassung keine technischen Schutzvorrichtungen überwunden werden müssen. Weiter führt das Gutachten die vom Gesetzgeber zum 01.03.2018 neu eingeführte Schrankenregelung im §60d UrhG „Text und Data Mining für Zwecke der wissenschaftlichen Forschung“ an, unter der der Datenzugriff unter Einhaltung der in § 60d UrhG genannten Voraussetzungen, auch ohne die Zustimmung der Plattformnutzenden, erlaubt ist. Hierzu zählen, dass die wissenschaftliche Forschung nicht kommerziellen Zwecken dient und die entstandene Datensammlung nach Abschluss des Forschungsprojektes gelöscht wird. Eine Übermittlung der Daten an privilegierte Institutionen, z. B. Bibliotheken zur Aufbewahrung oder zur Überprüfung wissenschaftlicher Standards, bleibt explizit erlaubt. Die vierte Bedingung verlangt, dass der Einsatz des Scrapers zu keinen technischen Einschränkungen der Webseite führt (Vogel und Hilgendorf 2019:45 f.).

Eine Bewertung dieser vier Kriterien für die vorliegende Dissertation fällt durchweg positiv aus. Die im Rahmen dieser Dissertation erfassten Daten sind alle öffentlich auf der Plattformwebseite einsehbar und unterliegen keinen technischen Schutzvorrichtungen (z. B. Log-in-Bereichen). In ihren Nutzungsbedingungen widerspricht die Plattform zwar dem massenweisen Sammeln von Daten ohne die Zustimmung der Nutzenden, jedoch ist zur Ansicht der Daten auf der Webseite keine explizite Zustimmung zu den Nutzungsbedingungen erforderlich. Aus rechtlicher Sicht kommen die Nutzungsbedingungen damit nicht zum Tragen, denn das alleinige Aufrufen der Webseite kann nicht als Zustimmung zu den Nutzungsbedingungen gewertet werden (Deutsch 2009:1027 f.). Ferner verfolgt die vorliegende Dissertation keinerlei kommerzielle Zwecke und nach Abschluss des Forschungsvorhabens werden die Daten ordnungsgemäß gelöscht. Die Zugriffshäufigkeit des Web-Scrapers wurde durch die Nutzung der automatisierten Geschwindigkeitskontrolle des Scrapy Frameworks (Autothrottle) beschränkt, um mögliche Schädigungen des Webseitenbetreibers und der Webseite zu verhindern.

Über die rechtlichen Voraussetzungen hinaus gibt es auch forschungsethische Aspekte, die es bei der Verwendung dieser Datenerhebungsmethode zu berücksichtigen gilt. Im Rahmen der Dissertation werden allgemeingültige forschungsethische Grundsätze berücksichtigt. Personenbezogene Daten (z. B.

Profilnamen oder Fotos) werden nur insoweit verarbeitet, wie es für den Forschungszweck erforderlich ist. Die Datenspeicherung und -verarbeitung erfolgt ausschließlich auf lokalen Datenträgern und die Veröffentlichung der Forschungsergebnisse wird ausschließlich in aggregierter Form vorgenommen, sodass keine Rückschlüsse auf einzelne Nutzende möglich sind.

4.2 Datenaufbereitung

Zur Durchführung der empirischen Analyse ist es zunächst nötig, die vom Web-Scraper gesammelten Daten in eine auswertbare Form zu bringen (sog. Data Preprocessing). Dieser Abschnitt beschreibt die dafür genutzten Methoden und die gewählte Vorgehensweise.

4.2.1 Aufbereitung und Operationalisierung der abhängigen Variablen

Zur Untersuchung der in Abschnitt 3.3 aufgestellten Hypothesen werden zwei verschiedene Modelle geschätzt (vgl. Abschnitt 4.3). Als abhängige Variable dient dabei im ersten Modell die Beauftragung und im zweiten Modell die Angebotspreise der Freelancer:innen.

Beauftragung: Die untersuchten Aufträge auf der Plattform werden immer nur einem:r Freelancer:in zugewiesen. Der Web-Scraper hat die Aufträge in wiederkehrenden Abständen aktualisiert und bei erfolgreicher Zuteilung des Auftrags den:die beauftragte Freelancer:in erfasst. Ob ein:e Freelancer:in den Zuschlag erhalten hat oder nicht, wird über eine binäre Dummyvariable (Y_{ij}) operationalisiert. Dabei bedeutet die Ausprägung eins, dass der:die Freelancer:in (i) den Zuschlag für den Auftrag (j) erhalten hat.

$$Y_{ij} \begin{cases} 0 = \text{keine Beauftragung für Auftrag } j \\ 1 = \text{beauftragt für Auftrag } j \end{cases}$$

Für die Analyse der Beauftragungswahrscheinlichkeit ist es notwendig, dass für den jeweiligen Auftrag auch eine Beauftragung beobachtet wurde. Dies war bei 3.556 Aufträgen der Fall, d. h. für rund 10,6 Prozent der insgesamt beobachteten Aufträge (33.510) konnte der:die ausführende Freelancer:in erfasst werden.

Angebotspreis: Die im zweiten Modell genutzte abhängige Variable ist der Angebotspreis der Freelancer:innen (p_{ij}). Dabei handelt es sich um jenen Preis, den die Freelancer:innen in der Bidlist öffentlich machen. Die Aufträge notieren in

den meisten Fällen in US-Dollar (USD) oder australischen Dollar (AUD), einige aber auch in indischer Rupie (INR) oder in Euro (EUR). Um den Datensatz zu vereinheitlichen, wird in einem vorgelagerten Schritt deshalb zunächst eine Währungsumrechnung in Euro vorgenommen. Dazu wird das Python-Paket `quickforex` verwendet, über das tagesgenaue Wechselkurse auch für zurückliegende Zeitpunkte abgerufen werden können (Boulangier 2021). Für die Umrechnung wird der am Tag der Angebotsabgabe jeweils gültige Stichtagskurs der entsprechenden Währung zum Euro herangezogen.

Freelancer:innen haben die Möglichkeit, gegen Zahlung einer Gebühr den Angebotspreis und die Lieferzeit in der öffentlichen Bidlist zu verbergen (sog. „Sealed Bids“, vgl. Abschnitt 3.2.3). In rund 30 Prozent der abgegebenen Angebote wird hiervon Gebrauch gemacht. Die versteckten Angebote sind über nahezu alle Aufträge verteilt, sodass es nicht möglich ist den Datensatz auf nur vollständige Aufträge zu beschränken. Daher wird ein Imputationsverfahren genutzt, um die fehlenden Preis- und Lieferzeitangaben zu schätzen.

Dazu ist es zunächst wichtig zu verstehen, weshalb die fehlenden Daten auftreten. Bestimmte Freelancer:innen entscheiden sich durch Zahlung der Gebühr aktiv für einen „Sealed Bid“. Nun stellt sich die Frage, ob bestimmte Charakteristika der Freelancer:innen diese Entscheidung begünstigen. In der Tat zeigt die Analyse der fehlenden Daten, dass diese systematisch hauptsächlich bei erfahreneren⁴⁷ und erfolgreicheren⁴⁸ Freelancer:innen auftreten. D. h. die Wahrscheinlichkeit, dass der Datenpunkt der Variable fehlt, korreliert mit anderen Charakteristika des:der Freelancer:in. Es handelt sich nach Rubin (1976) somit um den Fall *missing at random* (MAR)⁴⁹, unter dem der Einsatz von Imputationsverfahren möglich ist.

Als Imputationsverfahren wird eine multivariate iterative Imputation genutzt. Diese hat gegenüber einer einfachen univariaten Imputation den Vorteil, dass sie die zuvor erwähnten Zusammenhänge zwischen den Variablen ausnutzt, um die fehlenden Werte zu schätzen. Beide lückenhaften Variablen sind numerisch und stetig

⁴⁷ Erfahrung in Bezug auf die erhaltene Anzahl an Bewertungen und das kumulierte Einkommen auf der Plattform.

⁴⁸ Erfolgreich in Bezug auf höheres durchschnittliches Rating und bessere Performancemaße (Auftragsabschlussrate, Lieferfristeinhaltung, Budgeteinhaltung und Wiederbeauftragungsquote).

⁴⁹ Die beiden anderen Fälle wären gegeben, sofern keinerlei Zusammenhang zwischen fehlenden Daten und den anderen Daten bestünde (*missing completely at random* (MCAR)) und zusätzlich der Grund dafür unklar ist (*missing not at random* (MNAR)) (van Buuren 2018:8 f.).

ausgeprägt. Neben der einfachen Ersetzung fehlender Werte durch null, den Mittelwert oder den Median, werden auch Modelle des maschinellen überwachten Lernens⁵⁰ herangezogen. Diese werden auf Basis einer zehnpromzentigen Stichprobe aller vollständigen Daten trainiert und deren Performance anschließend, in Anlehnung an Jäger et al. (2021), auf Basis der mittleren quadratischen Abweichung (Mean squared error (MSE)) bewertet. Das RandomForest Verfahren liefert den niedrigsten und damit besten MSE, sodass dieses Verfahren für die Imputation der Angebotspreise und Lieferzeiten genutzt wird. Ein Ergebnis, das sich auch in der Simulationsstudie von Jäger et al. (2021:9) für MAR fehlende Daten bestätigt.

Zu berücksichtigen ist, dass im Rahmen dieser Arbeit der Angebotspreis beobachtet wird. Nachdem der:die Freelancer:in den Zuschlag für den Auftrag erhalten hat, kann es zu einer genaueren Abstimmung des Auftragsumfangs zwischen Freelancer:in und Auftraggebenden kommen. In diesem Rahmen ist denkbar, dass gerade bei größeren Aufträgen die Angebotspreise von den tatsächlich realisierten Preisen abweichen, z. B. aufgrund einer Erweiterung des Auftragsumfangs. Der vorliegende Datensatz ermöglicht eine Analyse der tatsächlich gezahlten Preise nicht. In der Literatur finden sich Forschungsbeiträge, die den Unterschied zwischen Angebots- und finalem Preis untersucht haben. Roussille (2022) hat auf Basis von Prozessdaten einer auf Ingenieure spezialisierten Plattform diesen theoretischen Unterschied empirisch untersucht und festgestellt, dass der letztlich gezahlte Preis in 64 Prozent der Fälle vom angebotenen Preis abweicht. Über die untersuchte Plattform werden jedoch hauptsächlich hochqualifizierte Vollzeitstätigkeiten vermittelt und nicht wie auf *freelancer.com* einzelne Aufgaben für kurze Zeit. Zudem sind Freelancer:innen auf *freelancer.com*, im Gegensatz zu der von Roussille (2022) untersuchten Plattform, an ihr abgegebenes Angebot zunächst gebunden, sodass eine Abweichung vom Angebotspreis eher die Ausnahme, z. B. bei großen Aufträgen, als die Regel sein dürfte. Daher ist die hier durchgeführte Auswertung auf Basis der Angebotspreise ausreichend.

⁵⁰ Hierzu werden die Verfahren des k-nächsten Nachbarns (k-NN), BayesianRidge und RandomForest getestet. Für die Hyperparameter der Verfahren werden jeweils verschiedene Parameterkonstellationen getestet (sog. GridSearch), 5-fach kreuzvalidiert und in Bezug auf die mittlere quadratische Abweichung (MSE) optimiert.

4.2.2 Aufbereitung und Operationalisierung der zentralen unabhängigen Variablen

Die wichtigste erklärende Variable in der Analyse ist das Geschlecht der Freelancer:innen. Die Plattform stellt jedoch keine expliziten Informationen zum Geschlecht bereit, z. B. in Form einer Anrede oder eines Feldes im Profil der Freelancer:innen. Dennoch bieten sich sowohl für den:die Auftraggebende als auch für den:die Forschende Wege, das Geschlecht der Freelancer:innen zu ermitteln. Diese werden im nächsten Abschnitt diskutiert und das gewählte Vorgehen detailliert beschrieben.

Neben dem Geschlecht steht auch der Rang der Freelancer:innen als zentraler Einflussfaktor auf die Beauftragungswahrscheinlichkeit im Fokus, deren Operationalisierung im zweiten Abschnitt beschrieben wird.

4.2.2.1 Geschlechtsbestimmung in zwei Stufen

Ausgehend von den für die Plattform zur Verfügung stehenden Daten ergeben sich mit dem Namen und dem Profilfoto der Freelancer:innen zwei Ansatzpunkte zur Geschlechtsbestimmung. Beide Vorgehensweisen sind in der Forschungsliteratur bereits etabliert. Hierunter finden sich sowohl Beiträge, die ausschließlich den Namen zur Geschlechtsbestimmung nutzen (z. B. Dubey et al. 2017; Foong et al. 2018; Galperin 2021; Gomez-Herrera und Mueller-Langer 2019; Roussille 2022) als auch solche, die auf Fotos zurückgreifen oder beides kombinieren (z. B. Chan und Wang 2018; Leung und Koppman 2018).

Die Angebote der Freelancer:innen werden in der Bidlist des jeweiligen Auftrags unter deren Alias (z. B. codeguru124) geführt. Durch diesen allein lässt sich das Geschlecht in der Regel nicht bestimmen. Im jeweiligen Profil der Freelancer:innen wird jedoch auch der Klurname in Form des Vornamens und des ersten Buchstabens des Nachnamens angezeigt (z. B. Michael H.), über den eine Geschlechtsbestimmung eher möglich ist. In vereinzelt Fällen stimmt der Alias auch mit dem Klarnamen überein. Unabhängig ob Klurname oder Alias, setzt grundsätzlich die Geschlechtsbestimmung über den Namen voraus, dass dieser auch geschlechtsidentifizierend genutzt werden kann. Da es auch geschlechtsneutrale Namen wie Kim oder Kurzformen wie Alex gibt, die sowohl für Alexander als auch Alexandra stehen können, ist die alleinige Bestimmung des

Geschlechts über den Vornamen mit einer gewissen Unschärfe behaftet. Hinzukommt, dass sich das für einen Namen typische Geschlecht auch zwischen verschiedenen Ländern unterscheiden kann. So ist z. B. der Name Andrea in Deutschland ein weiblicher Vorname, in Italien hingegen ein männlicher. Die internationale Ausrichtung der zu untersuchenden Plattform stellt daher diese Methode vor Herausforderungen oder würde zu größeren Unschärfen und womöglich einem hohen Datenverlust führen, sofern sie die alleinige Basis für die Bestimmung des Geschlechts ist.

Das Profilfoto der Freelancer:innen ist ebenfalls Bestandteil der Bidlist. Die Plattform animiert Freelancer:innen zur Hinterlegung eines solchen Fotos. Als Empfehlung gibt die Plattform an, dass auf diesem eine Person erkennbar sein soll. Dadurch, dass dies bei der Bewertung der Qualität und Vollständigkeit des Profils (Profile Marks) mitberücksichtigt wird, hat die Hinterlegung eines Profilfotos auch einen indirekten Einfluss auf den Rankingalgorithmus (vgl. Abschnitt 3.2.4 f.). Daher besteht für Freelancer:innen der Anreiz, ein möglichst gutes Profilfoto hochzuladen, was darin mündet, dass nahezu alle aktiven Profile ein Foto aufweisen. Zusätzlich setzt die Plattform ein zum Geschlecht passendes Standardbild ein, sofern kein Foto hinterlegt wird. Die Profilfotos bieten damit einen hohen geschlechtsidentifizierenden Informationsgehalt. Daher ist es naheliegend, dass der Auftraggebende diese zur bewussten oder unbewussten Bestimmung des Geschlechts der Anbietenden nutzt, zudem der Alias typischerweise kaum dazu geeignet ist, sofern er nicht mit dem Klarnamen übereinstimmt. Die vorgenannten Punkte machen damit die Profilfotos zu einem guten Ausgangspunkt zur Bestimmung des Geschlechts. Sofern das Profilfoto kein eindeutiges Ergebnis hervorbringt, wird in Stufe 2 der Name des:r Freelancer:in hinzugezogen. Die dafür verwendeten Methoden werden in den nächsten beiden Abschnitten beschrieben.

4.2.2.1.1 Stufe 1: Geschlechtsbestimmung auf Basis der Profilfotos

Die Aufgabe, das Geschlecht von Personen auf der Basis von Fotos zu bestimmen, ist für Menschen einfach und intuitiv. Dies wird in der Forschung rege genutzt, indem Personen (sog. Annotatoren) z. B. über Crowdfunding Plattformen rekrutiert werden, um den Personen auf den Fotos das entsprechende Geschlecht zuzuordnen (sog. Annotation) (z. B. Leung und Koppman 2018). Das Problem dieses Vorgehens besteht darin, dass insbesondere bei großen Datenmengen ein

nicht zu vernachlässigender Einsatz zeitlicher und finanzieller Ressourcen erforderlich ist.

Computer hingegen können diese Aufgabe mittlerweile mit geringerem Ressourceneinsatz und einer mindestens zum Menschen vergleichbaren Qualität erledigen. Hierzu eignen sich Algorithmen aus dem Bereich des maschinellen Lernens (Machine Learning). Maschinelles Lernen verfolgt das Ziel, Wissen aus Daten zu extrahieren (Müller und Guido 2017:1). „Ein Algorithmus ist [dabei] eine Folge von Anweisungen, die auszuführen sind, um die Eingabe in eine Ausgabe zu transformieren.“ (Alpaydin 2022:1). Diese Machine Learning Algorithmen lassen sich grob in drei Bereiche einteilen: überwachtes Lernen (Supervised Learning), unüberwachtes Lernen (Unsupervised Learning) und bestärkendes Lernen (Reinforcement Learning).

Algorithmen, die von Ein- und Ausgabepaaren lernen, werden als überwachte Lernalgorithmen bezeichnet. Denn sie kennen sowohl die Eingabe- als auch Ausgabedaten und leiten hieraus einen funktionalen Zusammenhang ab. Bei unüberwachtem Lernen kennt der Algorithmus lediglich die Eingabedaten und versucht Strukturen in den ungelabelten Daten zu finden. Das bestärkende Lernen hingegen beschreibt einen agentenbasierten Ansatz. Dabei kennt der Agent die gewünschten Ausgabedaten und lernt über Belohnung und Bestrafung einen möglichst effizienten Weg zu finden, um die Ausgabedaten zu erzielen (Frochte 2018:20 ff.).

Die vorliegende Aufgabenstellung, die Zuordnung von Profilfotos (Eingabedaten) zu einem Geschlecht (binäre Ausgabedaten), ist dem Bereich des überwachten Lernens zuzuordnen und stellt ein sog. Klassifikationsproblem dar. Ein Algorithmus muss demnach, auf Basis von gelabelten Trainingsdaten, einen funktionalen Zusammenhang zwischen Merkmalen von Personen und dem Geschlecht schätzen. Im Kontext der hier zu untersuchenden Plattform liegt eine große Herausforderung zunächst darin, dass von der Plattform nicht kontrolliert wird, was auf den Profilfotos zu sehen ist. Der vorliegende Datensatz weist diesbezüglich eine hohe Heterogenität der auf den Fotos abgebildeten Informationen auf.

Neben einer oder mehrerer Personen finden sich auf den Fotos Objekte wie Notebooks, Stühle, Autos oder lediglich Firmenlogos und Landschaften. Zusätzlich

sind die Fotos hinsichtlich ihrer Größe, Auflösung, des Aufnahmewinkels, der Aufnahmeentfernung und der Belichtung unterschiedlich. Neben diesen technischen Herausforderungen sind Menschen im Allgemeinen hinsichtlich ihres Erscheinungsbildes sehr heterogen. Manche Personen tragen Brillen, Masken, Kopftücher oder anderen Körperschmuck, haben unterschiedliche Frisuren, Hautfarben und sind dicker oder dünner. All das verdeutlicht, wie schwierig eine Geschlechtsbestimmung auf Basis echter Fotos für einen Computer sein kann – eine Aufgabe, die wir als Mensch unbewusst jeden Tag unzählige Male lösen.

So unstrukturiert Fotos von Personen auf den ersten Blick wirken, sind sie aber nicht. Personen haben Gesichter und diese Gesichter weisen eine gewisse wiederkehrende symmetrische Struktur auf. Alle Personen haben Augen, eine Nase und einen Mund. Ein Gesicht definiert sich über eine bestimmte Kombination dieser Komponenten (Alpaydin 2022:3). Zur Identifikation eines Gesichts können Algorithmen durch Trainingsdaten diese bestimmten Kombinationen erlernen und so Gesichter und damit auch Personen auf Fotos identifizieren. Werden diese Trainingsdaten mit den Ausgabedaten des Geschlechts kombiniert, ist es dem Algorithmus möglich, geschlechtsspezifische Merkmale in Gesichtern zu identifizieren und diesen gelernten Zusammenhang auf neue, ihm unbekannte Fotos zu übertragen und Vorhersagen zu treffen.

Grundsätzlich muss der Algorithmus also in der Lage sein, drei Schritte vorzunehmen. Erstens die Erkennung von Gesichtern auf den Profifotos (Detection). Zweitens eine mathematische Beschreibung dieser Gesichter vorzunehmen (Extraction) und drittens strukturelle Gemeinsamkeiten zwischen der Beschreibung und dem Geschlecht zu erkennen (Classification). Wie gut ein Algorithmus die Klassifikationsaufgabe erledigt, kann über verschiedene Gütemaße ermittelt werden. Im Falle einer binären Klassifikation⁵¹ wird hierzu die Konfusionsmatrix herangezogen, aus der sich verschiedene Maßzahlen berechnen lassen (Sokolova und Lapalme 2009:429 ff.).

⁵¹ Die Konfusionsmatrix und die Gütemaße lassen sich auch für Mehrklassen Klassifikationen aufstellen und berechnen (Sokolova und Lapalme 2009:430). Zur einfacheren Illustration werden diese im Folgenden auf Basis einer binären Klassifikation dargestellt.

Tabelle 10: Konfusionsmatrix für eine binäre Klassifikation

		Wahre Klasse	
		Positiv	Negativ
Vorhergesagte Klasse	Positiv	Richtig positiv (RP)	Falsch Positiv (FP)
	Negativ	Falsch Negativ (FN)	Richtig Negativ (RN)

Quelle: Eigene Darstellung.

Zu den wichtigsten Maßzahlen gehören die Accuracy (Korrektklassifikationsrate), die Precision (Genauigkeit), der Recall (Sensitivität) und der F_β -Score eines Algorithmus.

$$\text{Accuracy} = \frac{RP + RN}{RP + FN + FP + RN}$$

$$\text{Precision} = \frac{RP}{RP + FP}$$

$$\text{Recall} = \frac{RP}{RP + FN}$$

$$F_\beta \text{ Score} = (1 + \beta^2) \frac{\text{Precision} * \text{Recall}}{(\beta^2 * \text{Precision}) + \text{Recall}}$$

Die Accuracy setzt die Anzahl richtig klassifizierter Fälle ins Verhältnis zu allen untersuchten Fällen und misst damit die Effektivität einer Klassifikation (Sokolova und Lapalme 2009:430). Precision setzt die korrekt klassifizierten Fälle ins Verhältnis zu allen positiv klassifizierten Fällen und gibt die Genauigkeit der Vorhersage an. Der Recall setzt die korrekt klassifizierten Fälle ins Verhältnis zu den wahren positiven Fällen und gibt die Trefferquote des Algorithmus an. Der F_β -Score fasst Precision und Recall gewichtet mit dem Parameter β zusammen. Die Wahl geeigneter Gütemaße richtet sich nach den zugrundeliegenden Daten und dem Klassifikationsproblem.

Abseits der Forschungsfrage dieser Dissertation wird das vorliegende Klassifikationsproblem schon häufig gelöst⁵². Daher liegt es nahe, einen bereits vortrainierten Algorithmus auf den gesammelten Datensatz anzuwenden. Die kontinuierliche Weiterentwicklung neuer Methoden und Ansätze im Bereich des maschinellen Lernens sowie die steigenden Rechenkapazitäten und realistischeren Fotomengen führen dazu, dass regelmäßig neue Algorithmen veröffentlicht werden, die bessere Gütemaße erreichen als bereits vorhandene.

Bei dem vorliegenden Klassifikationsproblem geht es primär darum, möglichst viele Frauen und Männer korrekt zu klassifizieren. Zusätzlich kommt hinzu, dass die den Algorithmen zugrundeliegenden Trainingsdaten⁵³ in aller Regel ausgeglichene Verhältnisse zwischen Frauen und Männern aufweisen (Balanced Data), sodass sich als zentrales Gütemaß zum Vergleich der Algorithmen die Accuracy eignet und durchgesetzt hat.

Zur Auswahl des hier genutzten Algorithmus wird zunächst eine Recherche durchgeführt und die entsprechenden Accuracies der Algorithmen miteinander verglichen.⁵⁴ Ein weiteres Kriterium ist die öffentliche Verfügbarkeit des Programmcodes und die technische Anwendbarkeit des Algorithmus.

Mit einer sehr hohen Accuracy von 90,7 Prozent auf Basis des Adience Datensatzes (Eidinger et al. 2014) bietet der Algorithmus von Kim (2021) für das hier vorliegende Klassifikationsproblem sowohl eine hohe Güte als auch eine gute Anwendbarkeit, weshalb die Wahl auf diesen Algorithmus entfällt. Die hohe Accuracy erreicht der Algorithmus durch die Nutzung modernster Methoden⁵⁵ und dem Training auf Basis des IMDB-WIKI Datensatzes (über 500.000 Fotos) sowie des Adience Datensatzes (über 26.000 Fotos). Der IMDB-WIKI Datensatz besteht dabei aus Bildern der 100.000 bekanntesten Schauspieler:innen, die zusammen mit weiteren Informationen, z. B. dem Geschlecht, von der Internet Movie Database (IMDB) und

⁵² Die Anfänge dieser Methode gehen mindestens bis in die frühen 90er Jahre zurück (Golomb et al. 1990). Für einen systematischen Literaturüberblick zum Thema Geschlechtsbestimmung auf Basis von Fotos siehe Reid et al. (2013) und Makinen und Raisamo (2008).

⁵³ In der Literatur genutzte Trainingsdatensätze sind z. B.: PubFig (41% Frauen) (Kumar et al. 2009); Gallagher (52% Frauen) (Gallagher und Chen 2009); UTKFace (48% Frauen) (Zhang et al. 2022) oder Adience (53% Frauen) (Eidinger et al. 2014)

⁵⁴ Die Recherche zu den Algorithmen erfolgte im Winter 2020/2021.

⁵⁵ Eine detaillierter Beschreibung der Methodik kann dem Artikel von Kim (2021) entnommen werden.

Wikipedia Webseite extrahiert werden (Rothe et al. 2015). Es handelt sich dabei also eher um qualitativ hochwertige Fotos, die häufig gestellte Frontalaufnahmen von Personen im öffentlichen Kontext zeigen. Der zum Training genutzte Datensatz enthält zu 41 Prozent Fotos von Frauen (Kim 2021:5).

Der Adience Datensatz (fast 20.000 Fotos) hingegen basiert auf Fotos aus ungefähr 200 Flickr.com Alben, die mit dem Smartphone aufgenommen und über eine Creative-Commons-Lizenz (CC) öffentlich gemacht werden (Eidinger et al. 2014:2175). Der Frauenanteil für diesen Datensatz liegt bei 53 Prozent (Kim 2021:5). Dadurch, dass die Fotos aus privaten Fotoalben stammen, weisen sie eine hohe Heterogenität hinsichtlich der darauf abgebildeten Objekte (Personen, Gegenstände, Tiere, Landschaften etc.) und der Aufnahmequalität (Belichtung, Winkel, Schärfe etc.) auf und sind in ihrer Vielfalt vergleichbar mit den vorliegenden Profifotos von der Plattform. Daher ist eine ebenfalls hohe Güte des Algorithmus auf Basis der hier gesammelten Daten zu erwarten.

Ob der Algorithmus auch auf den vorliegenden Profifotos ähnlich gut funktioniert, wird durch eine Annotation von 300 zufällig ausgewählten Fotos überprüft. Um eine möglichst hohe Annotationsqualität zu erreichen, wird eine sog. Doppelannotation durch zwei Annotator:innen unter Nutzung der Annotationssoftware *Label Studio*, unabhängig voneinander vorgenommen. Zur Annotation werden drei Labels zur Auswahl gestellt: männlich, weiblich, unbekannt. Die dritte Kategorie soll dabei für Fotos genutzt werden, auf denen mehrere Personen unterschiedlichen Geschlechts zu erkennen sind, da in diesem Fall keine eindeutige Bestimmung der zum Profil zugehörigen Person möglich ist, und wenn die Fotos keine Personen zeigen, sondern z. B. ein Firmenlogo. Zur Bewertung der Annotation wird Cohens-Kappa (Cohen 1960) als Maß herangezogen.

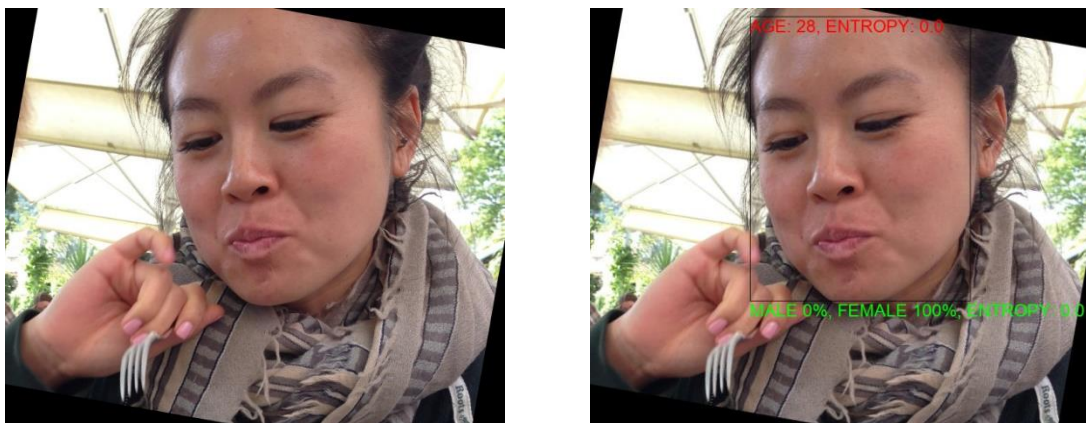
$$\kappa = \frac{p_0 - p_c}{1 - p_c}$$

Das Maß gibt an, wie zuverlässig die beiden Annotator:innen den Profifotos das gleiche Geschlecht zuweisen (Reliabilität). Dabei steht p_0 für die Wahrscheinlichkeit, dass beide Annotator:innen das gleiche Label vergeben und p_c für die Wahrscheinlichkeit, dass eine Übereinstimmung zufällig auftritt. Der Wertebereich des Cohens-Kappa liegt zwischen minus eins und eins und ein Wert

ab 0,81 gilt in der Literatur als nahezu perfekt (Landis und Koch 1977:165). Die hier durchgeführte Annotation weist ein Cohens-Kappa von 0,96 auf. Die Annotator:innen haben den Profildfotos in nahezu allen Fällen gleiche Labels zugewiesen. Lediglich bei einem Profildfoto kommt es zu einem abweichenden Label. Der annotierte Datensatz enthält demnach 63 Frauen, 197 Männer und 35 Fotos unbekanntem Geschlechts.⁵⁶

In einem nächsten Schritt wird der Algorithmus von Kim (2021) auf das Annotationssample angewendet. Zur Veranschaulichung zeigt Abbildung 4 beispielhaft ein Foto aus dem Adience Datensatz⁵⁷ vor- und nach dem Durchlauf des Algorithmus.

Abbildung 4: Beispielfoto vor- und nach der Anwendung des Geschlechtserkennungsalgorithmus



a) Vorher

b) Nachher

Quelle: Eiding et al. (2014): Adience Datensatz (Creative-Commons-Lizenz) und Kim (2021).

In einem ersten Schritt lokalisiert der Algorithmus das Gesicht auf dem Foto (Detection). Dazu werden die fünf Gesichtsmarkale, Mundwinkel, Nase und Augen herangezogen und das Foto auf eine Größe von 112×112×3 Pixel (Rechteckiger Kasten) gebracht.⁵⁸ Anschließend werden Gesichtsmarkale extrahiert, die in einem 512-dimensionalen Vektor repräsentiert werden

⁵⁶ Die Gesamtzahl (295) weicht von den 300 ursprünglich ausgewählten Fotos ab, da fünf Profile das gleiche Standardbild verwenden, das in der Datenbank zwar mit den Profilen der Freelancer:innen in Verbindung steht, aber nur einmalig abgespeichert und entsprechend auch nur einmal annotiert wurde.

⁵⁷ Da die Fotos aus dem Adience-Datensatz unter einer CC-Lizenz genutzt werden können, wird zur Veranschaulichung ein Foto aus diesem Datensatz herangezogen und zur Wahrung der Anonymität nicht von tatsächlichen Freelancer:innen der Plattform.

⁵⁸ Zur Gesichtserkennung wird der RetinaFace Algorithmus genutzt. Methodische Details können dem zugehörigen Forschungsbeitrag von Deng et al. (2020) entnommen werden.

(Extraction).⁵⁹ Im dritten und letzten Schritt wird zur Identifizierung struktureller Ähnlichkeiten in den Gesichtsmerkmalen von Frauen und Männern ein Algorithmus genutzt, der auf einem neuronalen Netz namens Multilayer Perceptron (MLP) beruht (Kim 2021). Als Output liefert der Algorithmus eine Prozentangabe für jedes Geschlecht und ein Maß für die Unsicherheit der Vorhersage (Entropie).

Nur wenn die Vorhersagesicherheit des Algorithmus hinreichend groß⁶⁰ ist, wird die Schätzung übernommen. Andernfalls wird das Label des Fotos auf unbekannt gesetzt. Sofern der Algorithmus mehrere oder kein Gesicht auf dem Foto erkennt, wird das Label ebenfalls auf unbekannt gesetzt, da keine eindeutige Identifikation des Geschlechts möglich ist. Enthält das Foto hingegen ausschließlich Gesichter eines Geschlechts, so wird diese Vorhersage übernommen. Für das Annotationssample können auf diese Weise den Fotos 51 Frauen, 197 Männer und 47 unbekannte Geschlechter zugewiesen werden. Aus dem Vergleich der annotierten Daten und den Vorhersagen des Algorithmus ergeben sich die folgenden Gütemaße.⁶¹

Tabelle 11: Gütemaße Annotationssample auf Basis der Fotos

Gütemaß	Wert
Accuracy	0,9220
Precision	0,9334
Recall	0,9220
F_1-Score	0,9236

Quelle: Eigene Berechnungen.

Über 92 Prozent der Profifotos werden den beiden Geschlechtern korrekt zugeordnet (Accuracy), ein zu anderen in der Literatur genutzten Algorithmen vergleichbarer Wert (Swaminathan et al. 2020:2641). Sofern ein Gesicht erkannt und das Geschlecht vorhergesagt werden kann, ist die Vorhersage in 93,3 Prozent

⁵⁹ Zur Extraktion der Gesichtsmerkmale wird der ArcFace Algorithmus genutzt. Methodische Details können dem zugehörigen Forschungsbeitrag von Deng et al. (2019) entnommen werden.

⁶⁰ Bei der Wahl der maximal zulässigen Entropie besteht ein Trade-Off zwischen einer möglichst geringen Unsicherheit bei der Vorhersage und dem Verlust von Beobachtungen. Da es keine Faustregel für die maximal zulässige Höhe der Entropie gibt, werden verschiedene Niveaus getestet. Das Niveau von 0,05 stellt sich dabei als bestmöglicher Kompromiss im Hinblick auf die Vorhersagegenauigkeit und der Anzahl der unbekannt Geschlechter heraus, was auch anhand der sehr guten Gütemaße in Tabelle 11 ersichtlich ist.

⁶¹ In den folgenden Auswertungen wird stets der F_β -Score mit $\beta = 1$ verwendet, da dieser Precision und Recall gleichgewichtet.

der Fälle korrekt (Precision). Gleichzeitig schafft der Algorithmus es, in 92,2 Prozent der Fälle ein Geschlecht zu identifizieren (Recall). Entsprechend ist das Mittel aus beiden Gütemaßen mit 92,4 Prozent ebenfalls sehr hoch. Zusammenfassend kann daher festgehalten werden, dass der Algorithmus auf dem vorliegenden Datensatz sehr gute Gütemaße erreicht und daher für die Bestimmung des Geschlechts sehr gut geeignet ist.

Der insgesamt über den Algorithmus klassifizierte Datensatz enthält in Summe 62.451 Fotos. Die Abweichung zur gesamten Anzahl an Profilen (78.201) erklärt sich aus Profildotos, auf denen der Algorithmus kein Gesicht erkennt oder solchen, die lediglich das Standardbild haben, welches nur einmalig in die Klassifikation einfließt. Die Geschlechtsbestimmung anhand der Fotos kann für 60.440 Profildotos erfolgreich durchgeführt werden. 14.486 Fotos sind dem weiblichen und 45.954 dem männlichen Geschlecht zugeordnet.

Auf 2.011 Profildotos kann kein Geschlecht identifiziert werden. Dies ist entweder der Fall, weil mehrere Gesichter unterschiedlichen Geschlechts zu erkennen (797 Profildotos) sind oder der Algorithmus in seiner Prognose nicht hinreichend sicher genug ist (1.214 Profildotos). Zusätzlich verbleiben noch weitere 15.750 Profile von Freelancer:innen, auf deren Profildotos der Algorithmus kein Gesicht identifizieren kann. In Summe können damit auf Basis der Profildotos 17.761 Profile keinem Geschlecht zugeordnet werden. Dies entspricht einem Anteil an allen Profilen von 22,7 Prozent. Anders ausgedrückt ist die Geschlechtsbestimmung für 77,3 Prozent der Profile möglich. Andere Forschungsbeiträge erreichen sowohl durch automatisierte Geschlechtsbestimmung als auch eine Kombination mit manueller Annotation Bestimmungsraten von 80–85 Prozent (z. B. Chan und Wang 2018:2979; Leung und Koppman 2018:779; Roussille 2022:9 f.). Es sind aber auch höhere Bestimmungsraten von über 90 Prozent möglich (z. B. Foong et al. 2018:6; Galperin 2021:1096), weshalb in der Stufe 2 für die 17.761 Profile der Name als weiteres geschlechtsidentifizierendes Merkmal herangezogen wird.

Es sollte jedoch auch bedacht werden, dass selbstlernende Algorithmen auch verzerrt sein können (Bias). Dadurch besteht die Gefahr, dass Geschlechterungleichheiten in diese Systeme übergehen und von diesen reproduziert werden (Bundesregierung 2021:34 f.). In der Literatur wird

diesbezüglich vorrangig die Rolle der Trainingsdaten diskutiert (Fabrizzi et al. 2022). Ist der Trainingsdatensatz nicht hinreichend repräsentativ für die Zielgruppe, ist der Algorithmus womöglich nicht in der Lage allgemeingültige Merkmale zu extrahieren und erreicht, bspw. für ein Geschlecht, geringere Erkennungsraten oder eine weniger gute Prognosegenauigkeit. Beinhaltet der Trainingsdatensatz bspw. lediglich Bilder von westeuropäischen Frauen, aber ebenfalls Bilder sowohl von westeuropäischen als auch asiatischen Männern, könnte dies in einer geringen Erkennungsrate oder Falschklassifikation asiatischer Frauen resultieren. Dies liegt daran, dass der Algorithmus nicht gelernt hat, welche Gesichtsmerkmale asiatische Frauen aufweisen und wie diese sich von anderen Frauen oder Männern unterscheiden.

Der zum Vortraining des Algorithmus genutzte Datensatz (IMDB-Wiki) beinhaltet Bilder von weltweit bekannten Schauspieler:innen und besteht zu 80 Prozent aus hellhäutigen Personen. Die restlichen 20 Prozent entfallen auf dunkelhäutige (ca. 10 Prozent), lateinamerikanische und asiatische Personen sowie Personen aus dem Mittleren Osten (Karkkainen und Joo 2021:1549). Damit ist der Datensatz hinsichtlich der Ethnie zur Weltbevölkerung wie auch zur Plattform nicht repräsentativ. Ähnliches lässt sich ebenso für den Adience Datensatz festhalten, der zur Feinjustierung der Modellparameter genutzt wird, in dem dunkelhäutige Personen unterrepräsentiert sind (Buolamwini und Gebru 2018:7; Wu et al. 2020:109). Daher besteht zunächst das Risiko, dass gewisse Personengruppen nicht ausreichend genug erkannt werden und dies die Ergebnisse der empirischen Analyse negativ beeinflussen könnte.

Dagegen spricht, dass der Adience Datensatz nach Geschlecht und Hautfarbe differenziert, keine größeren Unterschiede aufzeigt. In Bezug auf alle Fotos enthält der Datensatz 7,4 Prozent dunkelhäutige Frauen und 6,4 Prozent dunkelhäutige Männer (Buolamwini und Gebru 2018:6). Dabei gilt die Hautfarbe typischerweise als Proxy für die Ethnie von Personen. Muthukumar et al. (2019) zeigen in einem Experiment, dass die Hautfarbe allein lediglich einen minimalen Effekt auf die Klassifikationsentscheidung hat. Zusätzlich kommt hinzu, dass die beiden Trainingsdatensätze mit einem Frauenanteil von 41 Prozent (IMDB-Wiki) und 53 Prozent (Adience) relativ ausgeglichen hinsichtlich des Geschlechts sind. Hieraus lässt sich schließen, dass zwar nicht vollkommen ausgeschlossen werden

kann, dass durch den Algorithmus grundsätzlich Personen mit dunkleren Hautfarben weniger häufig erkannt werden, die Erkennungsrate aber zwischen Frauen und Männern ähnlich hoch sein dürfte. D. h., wenn überhaupt, besteht ein generelles Erkennungsproblem und kein Zuordnungsproblem.

Die Annotation hat gezeigt, dass sowohl die Erkennung (Recall) als auch die Genauigkeit der Vorhersage (Precision) sehr hoch sind, sodass eine mögliche Verzerrung, die aus den Trainingsdaten resultieren könnte, als gering eingeschätzt werden kann.

Weiterhin ist zu beachten, dass der angewendete Algorithmus sich auf das biologische Geschlecht beschränkt. Personen, die sich keinem der beiden biologischen Geschlechter zugehörig fühlen oder deren individuelle Zugehörigkeit vom biologischen Geschlecht abweicht, werden daher in der Analyse möglicherweise nicht adäquat erfasst. In der Vergangenheit besteht für die Klassifizierung z. B. von transgener Personen das Problem, dass entsprechend gelabelte Datensätze nicht verfügbar sind und daher auch keine Algorithmen trainiert werden können, ein Umstand, der sich in den letzten Jahren verbessert hat. Für weitere Informationen zu diesem Thema wird auf den Forschungsbeitrag von Wu et al. (2020) verwiesen, der dem interessierten Leser einen Einstieg in die Literatur ermöglicht.

4.2.2.1.2 Stufe 2: Geschlechtsbestimmung auf Basis der Namen

Neben den Fotos zur Geschlechtsbestimmung wird in der Diskriminierungsliteratur häufig auch der Name hinzugezogen (Chan und Wang 2018; Dubey et al. 2017; Foong et al. 2018; Galperin 2021; Gomez-Herrera und Mueller-Langer 2019; Leung und Koppman 2018; Roussille 2022). Grundsätzlich eignen sich hierfür zwei verschiedene methodische Ansätze: ein Wörterbuchansatz oder ebenfalls die Nutzung von Machine Learning Modellen (Hu et al. 2021:A.2).

Beim sogenannten Wörterbuchansatz wird der Name mit hinterlegten Listen abgeglichen, die neben dem Namen auch ein Geschlechterlabel enthalten. Es kommt also zu einer eins zu eins Zuordnung. Ein Vorteil dieser Methode liegt darin, dass, sofern der Name in der Liste korrekt hinterlegt ist, die richtige Zuordnung zum Geschlecht garantiert ist (hohe Precision). Umfassen die Listen hingegen nur wenige Namen oder bloß Namen aus bestimmten Ländern, so geht dies zulasten

der Erkennungsrate (niedriger Recall). Bei dieser Methode ist es demnach wichtig, dass das hinterlegte Wörterbuch eine Vielzahl von Namen aus vielen Ländern der Welt umfasst, um möglichst viele Namen erkennen und zuordnen zu können. Es eignet sich daher vorrangig für Datensätze, die häufige Namen enthalten (Hu et al. 2021:A.2).

Machine Learning Modelle machen sich den Umstand zunutze, dass Namen nicht aus einer zufälligen Anordnung von Buchstaben bestehen, sondern sich Muster erkennen lassen. So gehören Vornamen, die mit einem „a“ enden (z. B. Maria, Linda oder Alexandra) mit hoher Wahrscheinlichkeit zu einer Frau, wohingegen Namen, die an zweitletzter Stelle ein „u“ enthalten (z. B. Joshua, Arthur oder Julius) meist Männern zugehören (Hu et al. 2021). Durch das Training mit hinreichend großen Datensätzen können die Modelle solche Muster erkennen, erlernen und aus diesen Zusammenhängen eine Vorhersage für das jeweilige Geschlecht treffen. Der Vorteil dieses Ansatzes liegt darin, dass auch Vorhersagen für seltene Namen getroffen werden können und es nicht nötig ist, sämtliche Namen der Welt zu kennen, aufzulisten und zu annotieren. Dennoch muss der Trainingsdatensatz hinreichend viele Namen aus verschiedenen Ländern der Welt beinhalten, damit der Algorithmus auch länder- oder sprachspezifische Namensmuster und deren Geschlechtszugehörigkeit erlernt. Dies setzt einen entsprechend großen Datensatz für das Training voraus. Da der Wörterbuchansatz deutlich einfacher zu implementieren ist und bei gängigen Namen auch sehr gute Ergebnisse erzielen kann, empfiehlt sich ein hierarchisches Vorgehen (Hu et al. 2021:A.2). Zunächst die Bestimmung über den Wörterbuchansatz und falls nötig der Machine Learning Ansatz für die restlichen Profile.

Für den Wörterbuchansatz wird das frei verfügbare Python-Paket *genderComputer* genutzt (Aserebrenik 2022). Das Paket bietet den Vorteil, dass es neben dem Vornamen auf Länderinformationen zurückgreift und damit länderspezifische Geschlechterzuordnungen berücksichtigen kann. Das Wörterbuch des *genderComputer* beinhaltet über 275.000 Namen aus 35 Ländern und Regionen. Der *genderComputer* beinhaltet sowohl weibliche, männliche als auch geschlechtsneutrale Namen.

Um eine Bewertung der Güte des Wörterbuchansatzes vornehmen zu können, wird analog zur Stufe 1 eine Doppelannotation einer zufällig gezogenen Stichprobe von 100 Profilen vorgenommen. Die Übereinstimmung zwischen den beiden Annotator:innen beträgt 0,94 (Cohens-Kappa). Der im Vergleich zu der Fotoannotation leicht geringere Kappa-Wert verdeutlicht, dass eine Geschlechterbestimmung auf Basis der Namen auch für den Menschen herausfordernder ist. Dennoch wird eine so hohe Übereinstimmungsrate erreicht, welche die Validität des Annotationsdatensatzes bestätigt. In diesem Datensatz finden sich demnach 44 weibliche, 53 männliche und drei nicht zuordenbare Namen.

In einem nächsten Schritt wird der *genderComputer* auf den Annotationsdatensatz angewendet. Dies ergibt 37 weibliche, 47 männliche und 16 Namen, die keinem Geschlecht zugeordnet werden können. Aus dem Vergleich mit den annotierten Daten ergeben sich die folgenden Gütemaße.

Tabelle 12: Gütemaße Annotationssample auf Basis der Vornamen und Herkunftsländer

Gütemaß	Wert
Accuracy	0,7900
Precision	0,8924
Recall	0,7900
F_1-Score	0,8312

Quelle: Eigene Berechnungen.

Auf das gesamte Annotationssample bezogen, kann der *genderComputer* in 79 von 100 Fällen das richtige Geschlecht bestimmen (Accuracy). Der Recall liegt mit 0,79 deutlich unter der Precision mit 0,8924. Dies bedeutet, dass der *genderComputer* zwar insgesamt weniger Namen zuordnen kann, aber, sofern eine Vorhersage getroffen wird, diese in fast 90 Prozent der Fälle korrekt ist. Dies liegt hauptsächlich an Namen, die für beide Geschlechter gelten können. Die Annotator:innen haben dies nur unzureichend erkannt und diese Namen einem bestimmten Geschlecht zugeschrieben.

Das Ziel der Stufe 2 ist es, die Anzahl unbekannter Geschlechter mit möglichst hoher Genauigkeit zu reduzieren. Bei der Vielzahl an Daten, die bereits über die Fotos klassifiziert werden konnten, ist es daher wichtiger, dass die Vorhersage

korrekt (Precision) ist, als um jeden Preis sämtliche Profile klassifizieren zu können (Recall). Im Vergleich mit anderen Forschungsergebnissen, die ebenfalls den *genderComputer* zur Geschlechtsbestimmung genutzt haben (z. B. Foong et al. 2018:6), liefert der *genderComputer* im vorliegenden Fall mit einer Precision von fast 90 Prozent ausreichend gute Ergebnisse, auch wenn dafür auf einen geringen Teil der Profile in der weiteren Auswertung verzichtet werden muss.

Angewendet auf die in Stufe 1 als unbekannt gekennzeichneten Profile (17.761) ordnet der *genderComputer* 4.277 Namen das weibliche und 7.916 Namen das männliche Geschlecht zu. Nach der Stufe 2 bleiben demnach 5.568 Profile ohne Geschlecht übrig.

Zu beachten bleibt dabei, dass eine mögliche Unvollständigkeit der hinterlegten Namenslisten die Hauptlimitation des Wörterbuchansatzes darstellt. Diese könnte mit einer erhöhten Nichtzuordnung von Namen einhergehen, da diese dem *genderComputer* unbekannt sind. Weisen die Namenslisten zusätzlich noch eine ungleiche Verteilung von weiblichen, männlichen und geschlechtsneutralen Namen in den hinterlegten Listen auf, besteht theoretisch die Gefahr, dass sich die Erkennungsrate zwischen den Geschlechtern unterscheidet und sich dadurch der Datensatz zugunsten eines Geschlechts verändert.

Um diese Bedenken auszuräumen, wird eine Analyse der hinterlegten Namenslisten durchgeführt. Diese zeigt, dass die Anteile weiblicher Namen zwischen 20 Prozent (Russland) und 77,8 Prozent (USA) schwankt. Knapp die Hälfte der in Stufe 2 zu klassifizierenden Profile von Freelancer:innen stammen aus Indien, dessen Anteil weiblicher Namen bei fast 40 Prozent liegt. Das gewichtete Mittel des Anteils weiblicher Namen über alle Länder liegt bei 53 Prozent, sodass insgesamt betrachtet ein ausgeglichenes Geschlechterverhältnis in den hinterlegten Namenslisten vorherrscht. Zusammen mit den guten Gütemaßen erscheint daher eine mögliche Verzerrung des Datensatzes durch den *genderComputer* als nicht wesentlich. Weiterhin gilt auch für den *genderComputer* die Limitation, dass lediglich das binäre Geschlecht betrachtet werden kann (vgl. dazu auch Abschnitt 4.2.2.1.1).

Bezogen auf den Gesamtdatensatz können damit durch beide Stufen fast 93 Prozent der Profile einem Geschlecht zugeordnet werden. Im Vergleich dazu

erreichen Leung und Koppmann (2018:779) für ihren Datensatz durch manuelle Annotation und Geschlechtsbestimmung über Namen eine Bestimmungsrate von 83 Prozent. Chan und Wang (2018:2979) schaffen durch die Nutzung von Namen und Fotos 80 Prozent. Dubey (2017:15) erzielen allein über den Namen lediglich 55 Prozent. Das hier erzielte Ergebnis übertrifft diese Studien und befindet sich in einer ähnlich guten Höhe wie in der Analyse von Foong et al. (2018:6) (93,5 Prozent).

Da die Geschlechtsbestimmungsrate nach den beiden Stufen bereits sehr hoch ist und der Wörterbuchansatz ausreichend gut funktioniert hat, wird auf einen weiteren Einsatz von Machine Learning Verfahren verzichtet.

Der Datensatz enthält nach den zwei Stufen 18.763 Profile von Frauen, 53.870 Profile von Männern und 5.568 Profile, für die das Geschlecht nicht bestimmt werden kann. Letztere werden in der späteren Auswertung nicht berücksichtigt. In der Auswertung wird die Geschlechtervariable mit weiblich=1 und männlich=0 codiert.

4.2.2.2 Rang der Freelancer:innen

Inwiefern der Rang einen Einfluss auf die Beauftragungswahrscheinlichkeit von Freelancer:innen nimmt und ob dieser einen Teil einer möglichen Geschlechterdifferenz in der Beauftragungswahrscheinlichkeit erklären kann, soll in diesem Forschungsvorhaben erstmals empirisch überprüft werden.

Der Rang eines:r Freelancer:in resultiert aus dem durch den Rankingalgorithmus berechneten Score und ist damit Ausdruck des relativen Scores eines:r jeden Freelancer:in in der Bidlist. Jene Freelancer:innen, die auf den vorderen Rängen gelistet sind, weisen i. d. R. die meisten und besten Bewertungen auf und sind dementsprechend auf der Plattform sehr aktiv (vgl. Abschnitt 3.2.5). Der Rang dient damit als Informationsinstrument für den Auftraggebenden über die erfolgreiche Leistungsfähigkeit eines:r jeden Freelancer:in auf der Plattform. Daher erscheint ein positiver Zusammenhang zwischen dem Rang und der Beauftragungswahrscheinlichkeit auf der Plattform plausibel.

Um den Rang als unabhängige Variable in der empirischen Auswertung nutzen zu können, hat der Web-Scraper den jeweiligen Rang der Freelancer:innen aufgezeichnet. Nach Zuteilung des Auftrags durch den Auftraggebenden wird

der:die Freelancer:in, die den Auftrag erhalten hat, an vorderster Stelle in der Bidlist hervorgehoben. Als Grundlage für die Rangvariable wird dann die letzte zurückliegende Aufzeichnung der Bidlist herangezogen, wodurch auch der Rang des:derjenigen Freelancer:in rekonstruiert werden kann, die den Auftrag erhalten hat. Die Ränge sind aufsteigend durchnummeriert, wobei eins den höchsten und 21 den niedrigsten erreichten Rang beschreibt.

Die Rangvariable, die über diese Weise gewonnen werden kann, entspricht der öffentlich einsehbaren Reihenfolge auf den jeweiligen Auftragsseiten. In der Beschreibung des Rankingalgorithmus weist die Plattform darauf hin, dass diese Reihenfolge nicht zwingend der Reihenfolge entsprechen muss, die der Auftraggebende in seiner Auftragsansicht sieht (Freelancer.com 2016b). Dies liegt daran, dass Auftraggebende auch die Möglichkeit haben, sich die Liste anderweitig zu sortieren. Da es sich dabei aber um die Standardeinstellung handelt, ist davon auszugehen, dass die meisten Auftraggebenden auf Basis dieser Sortierung ihre Entscheidung treffen oder diese zumindest in ihre Entscheidung einbeziehen.

4.2.3 Operationalisierung weiterer Kontrollvariablen

Aus dem Literaturüberblick (vgl. Abschnitt 2.3) geht hervor, dass es neben den beiden zentralen unabhängigen Variablen auch weitere Einflussfaktoren auf die Beauftragungswahrscheinlichkeit und die Angebotspreise geben kann. Um den Einfluss des Geschlechts und des Rangs möglichst gut isolieren zu können, ist es daher notwendig, weitere Kontrollvariablen in den beiden Analysen zu berücksichtigen. Zusätzlich wird dadurch die Gefahr der Verzerrung der Schätzer aufgrund ausgelassener Variablen (omitted variable bias) minimiert (Auer und Rottmann 2020:477 ff.; Greene 2012:96 ff.). Die folgenden Kontrollvariablen stehen im Datensatz für die beiden Modelle zur Verfügung:

Lieferzeit: Bei Angebotsabgabe geben die Freelancer:innen neben dem Angebotspreis auch eine Lieferzeit in Tagen an. Eine im Vergleich zu den anderen Angeboten in der Bidlist sehr lange oder äußerst kurze Lieferzeit kann einen Einfluss auf die Beauftragungswahrscheinlichkeit nehmen. Ebenso dürfte der Angebotspreis mit der Lieferfrist korrelieren, da diese auch Ausdruck des vom Freelancer:in eingeschätzten Arbeitsumfangs ist. Korrespondierend zum Angebotspreis wies die Variable fehlende Werte aufgrund von „Sealed Bids“ auf. An

dieser Stelle wird daher auf das beschriebene Imputationsverfahren in Abschnitt 4.2.1 verwiesen, das auch für diese Variable genutzt wurde.

Rating: Das Rating eines:r Freelancer:in ist ein wichtiges Zeugnis für die Arbeitsleistung auf der Plattform. Nach Abschluss und Bezahlung des Auftrags kann der Auftraggebende den:die Freelancer:in anhand von fünf Kategorien (Qualität, Kommunikation, Expertise, Professionalität, Wiederbeauftragung) bewerten. Hieraus wird dann ein Gesamtrating für den Auftrag errechnet. Das Rating liegt zwischen null (keine Bewertungen erhalten) und fünf Sternen (bestes Rating) und wird für jeden Auftrag, auf den sich ein:e Freelancer:in bewirbt, anhand der bisher abgeschlossenen Aufträge aus einer ähnlichen Tätigkeitskategorie berechnet (Freelancer.com 2022k). Ein hohes Rating signalisiert den Auftraggebenden ein einwandfreies Arbeitsergebnis in vorherigen Aufträgen. Daher ist von einem positiven Einfluss auf die Beauftragungswahrscheinlichkeit auszugehen. Ein Zusammenhang, der auch schon für andere Plattformen gefunden wurde (vgl. Abschnitt 2.3.1). Denkbar ist auch, dass Freelancer:innen mit guten Ratings auch höhere Angebotspreise setzen, wobei dieser Zusammenhang bisher nicht explizit belegt ist.

Bewertungen: In Abgrenzung zu den Ratings umfasst diese Variable die Anzahl der erhaltenen Bewertungen der Freelancer:innen. Damit ist sie ein Indikator für die Menge an abgeschlossenen Aufträgen über die Plattform. Ein ähnlich positiver Einfluss auf Beauftragungswahrscheinlichkeit und Angebotspreis, wie bei den Ratings, scheint plausibel.

Kumuliertes Plattformeinkommen: Diese Variable gibt spezifisch für die Tätigkeitskategorie des dem Angebot zugrundeliegenden Auftrags an, wie viel der:die Freelancer:in in absolvierten Aufträgen dieser Kategorie bisher verdient hat. Die Variable bewegt sich dabei im Intervall zwischen null (niedrig) und zehn (hoch) und ist ein Indikator für die Erfahrung des:der Freelancer:in. Es scheint plausibel, dass erfahrenere Freelancer:innen sowohl häufiger beauftragt werden als auch höhere Preise verlangen können.

Herkunftsland: Das Herkunftsland wird über die Länderflagge, die neben dem Alias in der Bildlist angezeigt wird und dem im Quellcode hinterlegten Land extrahiert. Der Datensatz enthält Freelancer:innen aus über 190 Ländern und

Überseegebieten. Um für mögliche Länderunterschiede in der Analyse kontrollieren zu können, werden die 190 Länder in drei Kategorien eingeteilt: Entwickelte Länder, Schwellenländer und Entwicklungsländer. Die Länderzuordnung erfolgt auf Basis der Kategorisierung des Fiskalmonitors des Internationalen Währungsfonds (IWF) (IMF 2022). Das Herkunftsland einer Freelancer:in kann einen Einfluss auf Beauftragungswahrscheinlichkeit und Angebotspreis nehmen, wobei die Wirkungsrichtung zunächst unklar und vermutlich auch abhängig vom Herkunftsland des Auftraggebenden ist (z. B. Galperin und Greppi 2017; Ghani et al. 2014).

Performancemaße: Diese Variablen basieren auf den Bewertungen der Auftraggebenden nach Abschluss des Auftrags und umfassen vier Kennzahlen, die im oberen Teil der Profile der Freelancer:innen sichtbar sind: Auftragsabschlussrate (Jobs Completed), Einhaltung des Budgets (On Budget), Einhaltung der Lieferfrist (On Time) und die Wiederbeauftragung (Repeat Hire Rate). Die Kennzahlen sind Prozentangaben zwischen null und 100 und setzen, z. B. im Fall der Auftragsabschlussrate, die Anzahl abgeschlossener Aufträge ins Verhältnis zu allen angenommenen Aufträgen. Dadurch kann für Leistungsunterschiede zwischen den Freelancer:innen kontrolliert werden.

Weiterempfehlungen: Auftraggebende haben die Möglichkeit über „Likes“ den:die Freelancer:in weiterzuempfehlen. Die „Likes“ sind in den jeweiligen Profilen des:der Freelancer:innen einsehbar und die in der Analyse genutzte Variable bildet die Anzahl dieser erhaltenen Likes ab. Mehr Weiterempfehlungen sind ebenfalls Ausdruck von guter Arbeitsqualität und dürften sich somit sowohl positiv auf die Beauftragungswahrscheinlichkeit als auch den Angebotspreis auswirken.

Verifizierungsindex: Freelancer:innen können ihre Identität, Zahlungswege, Telefonnummer, E-Mail-Adresse und Facebook Verknüpfung von der Plattform verifizieren lassen. Dadurch wird versucht sicherzustellen, dass zu dem Profil auch tatsächlich eine Person gehört und es sich nicht um einen gefälschten Account handelt. Wie vollständig diese Verifizierungen vom:von der Freelancer:in sind, kann daher einen Einfluss auf die Beauftragungswahrscheinlichkeit nehmen. Ob sich auch der Angebotspreis unterscheidet, ist unklar. Die fünf Verifizierungen werden zu einer Variable zusammengefasst, die den Anteil der durchgeführten

Verifizierungen an allen Verifizierungen angibt und sich folglich im Intervall zwischen null und eins bewegt.

Plattformerfahrung: Zusätzlich zu der Auftragserfahrung, die durch die Anzahl der erhaltenen Bewertungen signalisiert wird, umfasst diese Variable die Zugehörigkeit zur Plattform in Jahren. Im Profil der Freelancer:innen ist angegeben, zu welchem Zeitpunkt der Beitritt zur Plattform erfolgt. Die Plattformerfahrung in Jahren wird als Differenz zwischen dem Zeitpunkt der Abgabe des Angebots und dem Plattformbeitritt berechnet. Freelancer:innen, die lange auf der Plattform aktiv sind, dürften entsprechend mehr Bewertungen und Aufträge absolviert haben, was einen positiven Einfluss auf beide abhängige Variablen haben kann.

Absolvierte Tests: Freelancer:innen können auf der Plattform Tests absolvieren, die dann in ihrem Profil hinterlegt werden. Typischerweise sind das Sprachtests, die ein gewisses Sprachniveau signalisieren sollen. Da diese ein Teil des Profils sind und damit zur Vollständigkeit des Profils beitragen, werden sie in der Analyse als Anzahl absolvierter Tests berücksichtigt.

Kostenpflichtige Mitgliedschaft: Freelancer:innen haben die Möglichkeit gegen Zahlung einer monatlichen oder jährlichen Gebühr eine Mitgliedschaft abzuschließen, aus der gewisse Vorzüge resultieren (vgl. Abschnitt 3.2.3). Ob ein:e Freelancer:in eine solche Mitgliedschaft abgeschlossen hat, wird über einen Badge im Profil sichtbar gemacht, den der Web-Scraper extrahiert hat. Durch die Vorzüge der Mitgliedschaft ist es Freelancer:innen möglich, aktiver zu sein und mehr Plattformerfahrung in kürzerer Zeit zu sammeln. Daher ist ein möglicher Einfluss auf die Beauftragungswahrscheinlichkeit und den Angebotspreis denkbar, weshalb diese Variable in beiden Analysemodellen Berücksichtigung findet. Es handelt sich dabei um eine Dummyvariable mit der Ausprägung eins, sofern eine Mitgliedschaft abgeschlossen wurde und null, wenn nicht.

Erfahrung in der Tätigkeitskategorie: In welchen Tätigkeitsbereichen (Skills) ein:e Freelancer:in bereits Projekte absolviert hat, ist über die „Top Skills“ im Profil ersichtlich. Der Web-Scraper hat aus jedem Profil diese Skills extrahiert und die Top fünf gespeichert. Diese Top fünf Skills werden mit den geforderten Skills je Auftrag gematcht. Sofern sich der passende Skill unter den Top fünf findet, weist die entsprechende Dummyvariable den Wert eins auf. Hat der:die Freelancer:in noch

keinen Auftrag aus dieser Tätigkeitskategorie absolviert, so hat die Variable die Ausprägung null. Vorerfahrung in der jeweiligen Tätigkeitskategorie dürfte einen positiven Einfluss auf die Beauftragungswahrscheinlichkeit und den Angebotspreis nehmen, weshalb diese Variable in beiden Modellen genutzt wird.

Neben diesen überwiegend plattformgenerierten Kontrollvariablen können weitere Variablen aus dem optionalen Freitextbereich der Profile extrahiert werden. Dieser Bereich umfasst Angaben von außerhalb der Plattform und gliedert sich in die Felder Bildung, Erfahrung, Zertifikate und Publikationen. Dadurch ist es möglich, die Effekte der zentralen unabhängigen Variablen auch von Unterschieden zwischen den Freelancer:innen außerhalb der Plattform zu bereinigen.

Bildung: Das Bildungsniveau gilt in der Literatur als Haupteinflussfaktor auf die Lohnhöhe (z. B. Heckman et al. 2006). Aufgrund der großen Bedeutung der Variable wird, im Vergleich zu den anderen Variablen, zur Operationalisierung ein größerer Aufwand betrieben.

Freelancer:innen haben die Möglichkeit, ihren Bildungsabschluss im Profil zu hinterlegen. Dazu können Sie Angaben zum Bildungsabschluss, zur Bildungsinstitution und weitere Angaben in einem Textfeld machen. Die durch den Web-Scraper gesammelten Daten liegen in einer unstrukturierten Form vor, da alle Felder Freitextfelder sind. D. h. es finden sich sowohl Abkürzungen (z. B. B.Sc., Univ.), als auch ausgeschriebene Abschlüsse (z. B. Bachelor, University) in den Daten. Eine Sichtprüfung der Daten hat ergeben, dass sich der Großteil der angegebenen Bildungsabschlüsse international anerkannten Abschlüssen zuordnen lässt, in englischer Sprache angegeben ist und kaum länderspezifische Abschlüsse genannt werden. Daher wird in Anlehnung an das Vorgehen von Foong et al. (2018:7 f.) in einem ersten Schritt eine Liste von Bildungsabschlüssen und Institutionen erstellt (vgl. Tabelle 13) und diese den Bildungsniveaus der International Standard Classification of Education (ISCED) aus dem Jahr 2011 zugeordnet (UNESCO 2012). Die Schlüsselwörter werden von Foong et al. (2018:8)

übernommen und um weitere, durch den Einbezug von länderspezifischer ISCED Mappingtabellen, ergänzt.⁶²

Tabelle 13: Schlüsselwörter zur Identifikation des Bildungsniveaus

Bildungs- niveau	ISCED- Level	Abschluss	Institution
Niedrig	0–2	Childhood, Early, Pre-Primary, Lower, Basic, Primary, Adult, Junior, Secondary	Middle, Junior
Mittel	3–4	Upper, Senior, Higher, Training, Diploma, Certificate	High School
Hoch	5–8	B. Sc., B. A., B. Tech, B. Sc., Eng., Bachelor, MBA, Professional, Master, M. A., M. Sc., Post-graduate, Graduate, Integrated, M. Tech, Doctorate, Doctoral, PhD	University, Institute, College

Quelle: Foong et al. (2018:8), UNESCO (2012) und eigene Recherche.

Da die Schlüsselwörter aus Tabelle 13 nicht immer in genau dieser Form auch in den Profilen der Freelancer:innen stehen, ist ein einfaches Matching der Bildungsniveaus nicht erfolgversprechend. Steht bspw. bei der Bildungsinstitution das deutsche Wort für „Universität“ und nicht das, wie in der Tabelle angegebene englische Wort, „University“ käme es zu keiner Zuordnung, obwohl die Wörter sich relativ ähnlich sind. Um auch solche Fälle erfassen zu können, wird ein sogenanntes „fuzzy string matching“ durchgeführt. Hierzu wird die Levenshtein-Distanz herangezogen, ein Maß, das die minimal nötige Anzahl an Operationen (einfügen, löschen, ersetzen) angibt, die nötig sind, um ein Wort in ein anderes zu verwandeln (Levenshtein 1966). Besonders ähnliche Wörter erfordern nur wenige Operationen, um vom einen in das andere Wort umgewandelt zu werden, d. h. je kleiner die

⁶² Hierzu werden die Mappingtabellen, welche die länderspezifischen Bildungsabschlüsse in die ISCED Klassifikation überführen, für die drei größten Herkunftsländer der Freelancer:innen (Indien, Pakistan und Bangladesch) herangezogen (UNSECO 2016).

Levenshtein-Distanz ist, desto ähnlicher sind sich die Wörter. Im obigen Beispiel (University vs. Universität) beträgt die Levenshtein-Distanz zwei. Ein Buchstabe muss gekürzt (Erste Operation) und das „ä“ muss durch ein „y“ ersetzt werden (Zweite Operation). Zum Wort „High School“ ist die Levenshtein-Distanz hingegen mit elf deutlich größer, sodass die Zuordnung in diesem Fall auf den Universitätsabschluss fallen würde.

Das zuvor illustrierte Vorgehen wird unter Nutzung des Python-Pakets *fuzzywuzzy* (Cohen 2020) für sämtliche Kombinationen aus Profilingaben (Bildungsabschlüsse und -institutionen) und Schlüsselwörtern durchgeführt und jene Kombination mit der geringsten Levenshtein-Distanz gesichert. Sofern das Matching auf Basis des Abschlusses und der Institution das gleiche Ergebnis ergibt, wird dieses übernommen. Kommt es zu einer Abweichung, wird jene Zuordnung übernommen, welche die geringste Levenshtein-Distanz aufweist. Sind beide Zuordnungen durch eine gleich hohe Levenshtein-Distanz gekennzeichnet, wird die Zuordnung auf Basis der Institution übernommen.

Um die Güte des Vorgehens zu messen, wird für eine Stichprobe von 300 Profilen von Freelancer:innen, analog zu der Geschlechtsbestimmung, eine Doppelannotation für die in Tabelle 13 dargestellten drei Bildungsniveaus durchgeführt. Das Cohens-Kappa liegt mit 0,77 nicht im perfekten Bereich der Übereinstimmung. Daher werden die voneinander abweichenden Annotationen nochmals geprüft und für die Berechnung der Gütemaße neu zugeordnet. Werden die auf Basis der Levenshtein-Distanz zugeordneten Bildungsniveaus den annotierten Bildungsniveaus gegenübergestellt, ergeben sich folgende Gütemaße:

Tabelle 14: Gütemaße Annotationssample Bildungsvariable auf Basis der Levenshtein-Distanz

Gütemaß	Wert
Accuracy	0,8800
Precision	0,9535
Recall	0,8800
F₁-Score	0,9138

Quelle: Eigene Berechnungen.

In 88 Prozent der Fälle ist die Zuordnung der Bildungsniveaus über Levenshtein-Distanz und der hinterlegten Entscheidungsregel korrekt. Die Gütemaße Precision,

Recall und F_1 -Score weisen hohe Werte auf, sodass das gewählte Vorgehen als valide angesehen werden kann. Jene Freelancer:innen, die keine Angabe zu ihrer Bildung machen, werden als Referenzgruppe in den beiden Analysen genutzt. Potenziell könnte die Bildung der Freelancer:innen auch Einfluss auf die Beauftragungswahrscheinlichkeit nehmen, weshalb die Variable auch im ersten Modell berücksichtigt wird.

Weitere Profilangaben: Neben der Bildung haben Freelancer:innen auch die Möglichkeit, weitere Angaben von außerhalb der Plattform zu tätigen. Hierzu zählen die Berufserfahrung (z. B. Position und Firma), erworbene Zertifikate (z. B. Softwarekurse, Sprachkurse) und Veröffentlichungen (z. B.: Bücher, Forschungsbeiträge). Diese Angaben können nur schwer inhaltlich mit der Beauftragungswahrscheinlichkeit und dem Angebotspreis in Verbindung gebracht werden. Dennoch trägt die Angabe zu einem vollständigen Gesamtbild des Profils bei und schafft Vertrauen in einer möglichen Geschäftsbeziehung zwischen Auftraggebenden und Freelancer:innen. Um den Einfluss der zentralen unabhängigen Variablen von möglichen Vollständigkeitsunterschieden der Profile zu bereinigen, wird für diese Variablen daher jeweils die Anzahl der hinterlegten Informationen gezählt.

4.2.4 Bereinigung des aufbereiteten Datensatzes

Nachdem die einzelnen Variablen nun für die weitere Analyse vorbereitet sind, wird eine Bereinigung des Datensatzes in mehreren Schritten vorgenommen. Zunächst wird der Projektstatus untersucht, anhand dessen noch Aufträge mit dem Status „Sealed“ und „Local Jobs“ identifiziert werden können. Ersteres sind Aufträge, zu denen ohnehin keine Daten von Freelancer:innen gesammelt werden können und die daher von der weiteren Analyse ausgeschlossen werden. Zweitere sind online vermittelte, aber vor Ort ausgeführte Aufträge, die ebenfalls nicht weiter betrachtet werden, da die Analyse sich auf vollständige Onlinearbeit fokussiert.

Anschließend werden unrealistisch hohe Angebotspreise entfernt. Hierzu wird die vom Auftraggebenden angegebene Budgetschranke genutzt. Sofern der Angebotspreis des:der Freelancer:in kleiner als das minimale Budget minus die 1,5fache Budgetspanne (Budget Maximum minus Minimum) ist oder größer als das

maximale Budget plus die 1,5fache Budgetspanne, wird das Angebot entfernt.⁶³ Im seltenen Fall, dass dies genau ein Angebot eines:r Freelancer:in betrifft, die beauftragt wurde, wird der gesamte Auftrag verworfen.

Um den Datensatz homogener hinsichtlich der Projektbudgets zu machen, werden in einem letzten Schritt ungewöhnlich große oder kleine Projektbudgets herausgefiltert. Dies erfolgt über den 1,5fachen Interquartilsabstand (IQR).

Weiter ist es für die Analyse der Beauftragungswahrscheinlichkeit notwendig, den Datensatz auf jene Aufträge zu beschränken, für die der Web-Scraper auch den:die ausführende Freelancer:in erfasst hat. Um sicherzustellen, dass genügend Beobachtungen je Auftrag zur Verfügung stehen, wird die Mindestanzahl an Geboten pro Auftrag auf fünf festgelegt. Das zweite Modell zur Analyse der Angebotspreise wird, aus Gründen der Einheitlichkeit und begrenzter Rechenkapazitäten, ebenfalls auf Basis dieses Datensatzes berechnet. Der bereinigte Datensatz besteht damit aus 31.316 Angeboten, die sich auf 2.274 Aufträge verteilen und von 10.194 Freelancer:innen stammen. Der Frauenanteil liegt im gesamten Datensatz bei 23,8 Prozent.

4.3 Datenanalyse

Bei den vorliegenden Daten handelt es sich um Querschnittsdaten zu Aufträgen, den zugehörigen Angeboten und weiteren Informationen von Freelancer:innen. Ziel der Analyse ist es, einen funktionalen Zusammenhang zwischen den unabhängigen Variablen und der abhängigen Variable zu schätzen. Hierzu eignen sich im Allgemeinen Regressionsmodelle (Auer und Rottmann 2020:417). Die dafür gewählten Modelle und deren jeweiligen Spezifikationen werden in den nächsten beiden Abschnitten beschrieben.

4.3.1 Modell zur Analyse der Beauftragungswahrscheinlichkeit

Die abhängige Variable zur Analyse der Beauftragungswahrscheinlichkeit⁶⁴ kann die Ausprägungen null (nicht beauftragt) und eins (beauftragt) aufweisen und ist

⁶³ Es werden verschiedene Faktoren getestet. Dabei hat sich gezeigt, dass das 1,5fache der Budgetspanne am besten unrealistisch erscheinende Angebotspreise entfernt.

⁶⁴ Die durch das Modell berechneten Effekte beziehen sich stets auf die Beauftragungschance (im englischen Odds), also das Verhältnis der Wahrscheinlichkeit, beauftragt zu werden, zur Gegenwahrscheinlichkeit. Zwischen Odds und Wahrscheinlichkeiten besteht ein monotoner Zusammenhang, sodass Odds auch in Wahrscheinlichkeiten überführt werden können.

damit eine binäre Variable. Klassische lineare Regressionsmodelle sind für die Analyse einer solchen abhängigen Variable nicht geeignet, da zentrale Annahmen verletzt werden (Greene 2012:721).⁶⁵

Um zu beurteilen, welche Methode zur Analyse der Beauftragungswahrscheinlichkeit geeignet ist, muss das Entscheidungsproblem näher betrachtet und kategorisiert werden. Der Auftraggebende steht vor der Entscheidung, eine:n Freelancer:in unter den mindestens fünf anbietenden Freelancer:innen für den Auftrag auszuwählen (multiples Entscheidungsproblem unter ungeordneten Alternativen). Dabei berücksichtigt er die einzelnen Charakteristika der Freelancer:innen bzw. Alternativen und trifft auf dieser Basis seine Entscheidung. Für ein solches Entscheidungsproblem ist die bedingte logistische Regression (Conditional Logit Model) ein geeignetes Modell (Greene 2012:806; Wooldridge 2002:500 f.), welches auch schon in anderen Analysen verwendet wird (Chan und Wang 2018; Galperin 2021).

McFadden (1974b) hat ein solches Entscheidungsproblem nutzentheoretisch fundiert, das in dieser Arbeit in Anlehnung an Chan und Wang (2018:2979 f.) adaptiert wird. Hier nimmt der Auftraggebende die Rolle des nutzenmaximierenden Konsumierenden ein, der sich zwischen verschiedenen Freelancer:innen (j) entscheiden muss. Dabei bezieht der Auftraggebende die beobachtbaren Variablen aus der Bidlist und den Profilen der Freelancer:innen (x_{ij}), das Geschlecht (g_j), den Rang (r_{ij}) sowie auftragspezifische Effekte (γ_i) in seine Entscheidung mit ein. Der Auftraggebende erhält aus der Beauftragung einer Freelancer:in den folgenden Nutzen:

$$u_{ij} = x_{ij}\beta + g_j\alpha + r_{ij}\delta + g_jr_{ij}\pi + \gamma_i + \varepsilon_{ij}$$

$$\forall i \in [1, 2, \dots, N], \forall j \in [1, 2, \dots, J_i]$$

Hierbei steht N für die Gesamtanzahl an Aufträgen und J_i für die Gesamtanzahl an Angeboten für Auftrag (i). Es wird angenommen, dass der Auftraggebende rational entscheidet und damit jene Alternative wählt, die den Nutzen (u_{ij}) maximiert. Sofern

⁶⁵ Hierunter die Normalverteilung des Fehlerterms oder eine konstante Varianz des Fehlerterms (Homoskedastizität). Zusätzlich ist nicht immer sichergestellt, dass die Vorhersagen des Modells im Intervall (0,1) liegen.

angenommen wird, dass der Fehlerterm (ε_{ij}) mit Lageparameter $\mu = 0$ und Streuungsparameter $\beta = 1$ unabhängig und identisch Gumbel (Extreme Value Type I Verteilung) verteilt ist, lässt sich die Beauftragungswahrscheinlichkeit für Freelancer:in (j) für Auftrag (i) wie folgt darstellen (Greene 2012:801 f.):

$$P_{ij} = P(Y_{ij} = 1 | x_{i1}, x_{i2}, \dots, x_{ij}, g_1, g_2, \dots, g_j, r_{i1}, r_{i2}, \dots, r_{ij})$$

$$= \frac{\exp(x_{ij}\beta + g_j\alpha + r_{ij}\delta + g_j r_{ij}\pi)}{\sum_{k=1}^{J_i} \exp(x_{ik}\beta + g_k\alpha + r_{ik}\delta + g_k r_{ik}\pi)}$$

Die Variable (Y_{ij}) gibt dabei an, ob der:die Freelancer:in beauftragt wird oder nicht. Von besonderem Interesse in der Analyse sind die Koeffizienten α , δ und π , die den jeweiligen Einfluss des Geschlechts, des Rangs und einen geschlechtsspezifischen Rangeffekt beschreiben. Die Berechnung der Effekte erfolgt auf Ebene der einzelnen Aufträge, weshalb bei einer bedingten logistischen Regression keine Koeffizienten für auftragsspezifische und damit alternativen invariante Variablen berechnet werden können. Dies stellt im vorliegenden Fall einen Vorteil dar, da dadurch die Modellergebnisse unabhängig von spezifischen Auftragscharakteristika (z. B. Budget oder Charakteristika der Auftraggebenden) sind (Fixed Effect). Die Schätzung des bedingten logistischen Regressionsmodells erfolgt durch die Maximum Likelihood Methode.

Um den Effekt der zentralen unabhängigen Variablen (Geschlecht und Rang) auf die Beauftragungswahrscheinlichkeit von Unterschieden in anderen Charakteristika der Freelancer:innen, die ebenfalls Einfluss auf die Beauftragungswahrscheinlichkeit nehmen, zu bereinigen, werden weitere Kontrollvariablen im Modell berücksichtigt (vgl. Tabelle 15). Zugleich reduzieren die Kontrollvariablen das Risiko eines verzerrten Schätzers aufgrund ausgelassener Variablen (omitted variable bias) (Greene 2012:751 ff.).

Tabelle 15: Kontrollvariablen der beiden Regressionsmodelle

Gruppe	Variable
Bidlist	Angebotspreis in EUR (nur im ersten Modell genutzt, da im zweiten Modell abhängige Variable)
	Lieferzeit in Tagen
	Rating
	Anzahl an Bewertungen
	Kumuliertes Plattformeinkommen
	Länderdummies Schwellenland, Entwicklungsland
Performancemaße	Auftragsabschlussrate
	Einhaltung des Budgets
	Einhaltung der Lieferzeit
	Wiederbeauftragungsquote
Weitere plattformgenerierte Variablen	Weiterempfehlungen
	Verifizierungsindex
	Plattformerfahrung in Jahren
	Absolvierte Tests
	Kostenpflichtige Mitgliedschaft
Externe Variablen	Erfahrung in der Tätigkeitskategorie
	Bildungsdummies Hoch, Mittel, Niedrig
	Zertifikate
	Erfahrung
	Publikationen

Quelle: Eigene Darstellung.

Dabei können die Variablen in verschiedene Gruppen eingeteilt werden, die anhand der Sichtbarkeit für den Auftraggebenden ausgewählt werden. Zunächst wären da Variablen, die der Auftraggebende in der Bidlist sieht. Anschließend gibt es die im Profil der Freelancer:innen markant herausgestellten Performancemaße und weniger präsent weitere plattformgenerierte Variablen. Zum Schluss werden Variablen, die Informationen von außerhalb der Plattform enthalten, als externe Variablen zusammengefasst. Zur Modellauswahl wird das Modell, unter Einbezug dieser verschiedenen Gruppen, hierarchisch aufbauend geschätzt. Für die Analyse

auf Ebene der Tätigkeitskategorien (H4 und H8) erfolgt eine jeweils separate Schätzung.

Im Modell kritisch zu hinterfragen ist die Annahme unabhängiger und homoskedastischer Fehlerterme, die impliziert, dass das Chancenverhältnis (Odds-Ratio) zweier Alternativen unabhängig von weiteren Alternativen ist (Independence from Irrelevant Alternatives (IIA)) (McFadden 1974a:113). Dies bedeutet, dass das Chancenverhältnis lediglich von den beiden verglichenen Alternativen abhängt und nicht von Charakteristika oder der Existenz einer dritten Alternative (Fry und Harris 1998:401 f.). Problematisch ist diese Annahme hinsichtlich Alternativen, die für den Entscheider kaum unterscheidbar sind.⁶⁶ Daher merkt McFadden (1974a:113) an, dass die bedingte logistische Regression lediglich Anwendung finden sollte, sofern die Alternativen hinreichend unterschiedlich genug sind.

Ob die IIA-Annahme erfüllt ist, kann u. a. durch den Hausman und McFadden (1984) Spezifikationstest geprüft werden (Greene 2012:807 f.). Auf Basis der vorliegenden Daten kann die Nullhypothese des Tests nicht verworfen werden, sodass davon auszugehen ist, dass die IIA-Annahme nicht verletzt wird. Die Spezifikationstests gelten in der Literatur jedoch, je nach vorliegender Modellspezifikation, als sensitiv und daher als umstritten (z. B. Cheng und Long 2007; Fry und Harris 1996, 1998). Zusätzlich zu dem empirischen Ergebnis lässt sich auch argumentativ festhalten, dass Freelancing-Marktplätze zwar eine gewisse Austauschbarkeit begünstigen, die vorliegenden Daten aber auch zeigen, dass sich die Freelancer:innen hinsichtlich ihrer Charakteristika (z. B. Expertise, Arbeitsqualität) unterscheiden. Es erscheint somit wahrscheinlich, dass der Auftraggebende diese nicht wie im Extrembeispiel der Literatur als perfekte Substitute ansieht, sondern ihnen jeweils unabhängige Beauftragungswahrscheinlichkeiten zuweist. Zusätzlich werden in der Analyse durch die Nutzung von Kontrollvariablen zueinander fast identische

⁶⁶ In der Literatur wird zur Illustration hierzu oft das roter/blauer Bus Beispiel angebracht (McFadden 1974a:113). Dies lautet so: Als Transportmittel steht ein Auto oder ein roter Bus zur Wahl. Die IIA-Annahme impliziert, dass das Verhältnis der Beauftragungschancen sich nicht verändert, wenn ein zum roten Bus identischer blauer Bus zur Wahl steht. Intuitiv wäre aber zu erwarten, dass sich die Wahrscheinlichkeit für die Wahl des roten Busses halbiert, sofern die Farbe für den Entscheider irrelevant ist. Die IIA-Annahme erfordert aber ein gleiches Chancenverhältnis, sodass sich die Wahrscheinlichkeit, das Auto zu nehmen, reduzieren muss. Die IIA-Annahme berücksichtigt also nicht, dass die beiden Alternativen roter, blauer Bus Substitute sind und als eine Alternative zusammengefasst werden können.

Freelancer:innen zusammengefasst, sodass der Einfluss einer möglichen Verletzung der IIA-Annahme auf die Modellergebnisse reduziert wird. Alles in allem ist somit nicht davon auszugehen, dass die IIA-Annahme verletzt ist.

4.3.2 Modell zur Analyse der Angebotspreise

Im zweiten Modell gilt es, einen funktionalen Zusammenhang zwischen den Angebotspreisen und dem Geschlecht unter Berücksichtigung der Kontrollvariablen zu schätzen. Im Gegensatz zum ersten Modell sind die Angebotspreise stetig ausgeprägt. In der Literatur werden typischerweise für das vorliegende Problem klassische Regressionsmodelle und Erweiterungen von diesen genutzt (z. B. Abendroth 2021; Gomez-Herrera und Mueller-Langer 2019; Litman et al. 2020; Roussille 2022).

Bei dem vorliegenden Datensatz handelt es sich um Querschnittsdaten, die neben der individuellen Ebene der Freelancer:innen noch eine zweite Dimension auf Auftragsebene aufweisen. D. h. für die Bestimmung der Einflussfaktoren auf den Angebotspreis steht sowohl eine Varianz innerhalb der Aufträge (z. B. Lieferfristen oder Charakteristika der Freelancer:innen) als auch zwischen den Aufträgen (z. B. Budget oder Charakteristika der Auftraggebenden) zur Verfügung. Da für die Forschungsfrage der Einfluss individueller Faktoren der Freelancer:innen untersucht werden soll, wird die Analyse auf die Varianz innerhalb der Aufträge beschränkt. Hierzu eignen sich Erweiterungen des linearen Regressionsmodells, wie das Fixed Effect oder Random Effect Modell.

Das Fixed Effect Modell trifft die Annahme, dass nicht beobachtete Variablen mit denen in der Regression genutzten unabhängigen Variablen auf Auftragsebene korrelieren. Diese Korrelation kann durch die Schätzung gruppenspezifischer Konstanten herausgerechnet werden. Dies stellt zugleich einen Nachteil dieser Methode dar, da eine Berechnung von Effekten auftragsspezifischer Variablen auf den Angebotspreis nicht möglich ist (Greene 2012:399 ff.).

Das Random Effects Modell lockert die Annahme des Fixed Effects Modells und nimmt an, dass die nicht beobachteten Variablen keine Korrelation mit den unabhängigen Variablen aufweisen und daher als zufällig angenommen werden können (strikte Exogenitätsannahme). Damit entfällt die aufwendigere Berechnung auftragsspezifischer Konstanten. Nachteil dieser Methode ist, dass die Effekte nicht

für Unterschiede zwischen den Aufträgen bereinigt werden können und der Schätzer inkonsistent ist, sofern die Exogenitätsannahme doch verletzt ist (Greene 2012:410 ff.). Das Random Effects Modell berücksichtigt sowohl die Varianz zwischen als auch innerhalb der Aufträge.

Bezogen auf den vorliegenden Anwendungsfall trifft das Random Effects Modell mit der Exogenitätsannahme eine starke Annahme, die nur schwer zu begründen und deren Verletzung aufgrund limitierter Daten nicht auszuschließen ist. Welche Modellwahl die richtige ist, kann über den Hausman Spezifikationstest bestimmt werden (Hausman 1978). Hierzu werden beide Modellvarianten berechnet und anhand der Teststatistik verglichen. Die Berechnung des Tests hat ergeben, dass die Nullhypothese bei einem Signifikanzniveau von einem Prozent verworfen werden kann. Dies bedeutet, dass das Fixed Effect Modell für die Untersuchung der Angebotspreise genutzt werden sollte.

Die Regressionsgleichung lässt sich wie folgt aufstellen, wobei, wie im ersten Modell, der Index i den Auftrag und der Index j den:die Freelancer:in beschreibt:

$$\log(p_{ij}) = g_j\beta + x_{ij}\pi + \gamma_i + \varepsilon_{ij}$$

Der Angebotspreis (p_{ij}) wird in der Regression logarithmiert berücksichtigt, da die Variable rechtsschief verteilt ist und auf diese Weise eine symmetrischere Verteilung approximiert wird. Die zentrale unabhängige Variable dieser Regression ist das Geschlecht (g_j) und die Schätzung des entsprechenden Koeffizienten (β) steht im Fokus. Daneben werden die Kontrollvariablen aus Tabelle 15 im Vektor (x_{ij}) berücksichtigt⁶⁷ und π stellt den entsprechenden Vektor an Koeffizienten dar. Die für jeden Auftrag geschätzte Konstante ist im Vektor γ_i enthalten. Der über die Aufträge und Freelancer:innen identisch und unabhängig verteilte Fehlerterm wird in ε_{ij} abgebildet. Zur Modellauswahl wird das Fixed Effects Modell unter Nutzung der Methode der kleinsten Quadrate (Ordinary Least Squares (OLS)) anhand der Kontrollvariablen hierarchisch aufbauend geschätzt. Für die Analyse auf Ebene der Tätigkeitskategorien (H5) erfolgt eine jeweils separate Schätzung auf Basis einer entsprechend zur Tätigkeitskategorie zugehörigen Teilmenge an Aufträgen.

⁶⁷ In Tabelle 15 wird der Angebotspreis als unabhängige Variable gelistet. Dieser ist im zweiten Modell die abhängige Variable und wird entsprechend nicht als Kontrollvariable verwendet.

Collischon und Eberl (2020:292 ff.) erinnern daran, dass es bei all den Vorteilen des Fixed Effect Modells auch Limitationen gibt. Das Modell schließt zwar eine Verzerrung aufgrund ausgelassener auftragspezifischer Variablen aus, dennoch ist es denkbar, dass es nicht beobachtete Variablen von Freelancer:innen gibt, die sich zwischen den Aufträgen verändern (Unbeobachtete Heterogenität) (Collischon und Eberl 2020:292; Hill et al. 2020:363 f.). Der Web-Scraper hat nahezu sämtliche Informationen aus der Bidlist und den Profilen extrahiert und all diese Informationen fließen als Kontrollvariablen in das Modell mit ein. Daher ist davon auszugehen, dass keine potenziell beobachtbaren relevanten Variablen ausgelassen werden. Kritischer könnten solche Variablen sein, die dem Forschenden nicht zur Verfügung stehen, wie interne Daten, Kommunikation zwischen der Plattform und den Freelancer:innen oder andere nicht beobachtbare Faktoren, die den Angebotspreis oder die unabhängigen Variablen beeinflussen. Informationen darüber liegen nicht vor und können daher nicht berücksichtigt werden – ein Problem, das auch bei anderen Regressionsmodellen fortbestehen würde.

Die Beschränkung des Fixed Effects Modells auf die Varianz innerhalb der Aufträge resultiert in größeren Standardfehlern und macht Typ II Fehler (keine Ablehnung der falschen Nullhypothese) wahrscheinlicher. Gleichzeitig ist das Modell damit aber auch konservativer (reduziert Typ I Fehler) und signifikante Ergebnisse deuten auf einen robusten Zusammenhang hin (Hill et al. 2020:362). Collischon und Eberl (2020:295 f.) empfehlen daher, nicht nur auf die Signifikanz zu achten, sondern auch die Effektgröße in der Interpretation zu berücksichtigen.

Die Mindestanzahl an Angeboten je Auftrag wird auf fünf festgelegt und im Datensatz weisen 50 Prozent der Aufträge 15 oder mehr Angebote auf. Dadurch ist sichergestellt, dass die Fixed Effect Ergebnisse nicht nur auf einer geringen Anzahl an Beobachtungen beruhen. Weiter zeigt sich, dass auf diese Weise genügend Varianz innerhalb der Aufträge vorhanden ist, sodass eine effiziente Schätzung des Modells möglich ist.

Letztlich schlussfolgern Collischon und Eberl (2020:298), dass, sofern die zu untersuchenden Daten eine Fixed Effect Analyse ermöglichen, diese immer gegenüber einem Standard OLS-Modell vorgezogen werden sollte. Die Wahl des Fixed Effect Modells zur Analyse der Angebotspreise scheint daher geeignet.

5 Ergebnisdarstellung und Interpretation

Nachdem im vorherigen Kapitel die methodische Herangehensweise detailliert beschrieben wurde, folgt im vorliegenden die Analyse des Datensatzes zur Verifizierung der aufgestellten Hypothesen (vgl. Abschnitt 3.3). Um einen ersten Eindruck über die gesammelten Daten zu erlangen, werden zunächst deskriptive Auswertungen vorgenommen. Anschließend werden die Modellergebnisse für die Analyse der Beauftragungswahrscheinlichkeit und Angebotspreise diskutiert und die jeweiligen Hypothesen auf deren Gültigkeit geprüft. Zum Schluss erfolgt eine kritische Würdigung der Ergebnisse.

5.1 Deskriptive Analyse

Tabelle 16 fasst die einzelnen Variablen des Datensatzes nach dem Geschlecht zusammen und stellt in der letzten Spalte die Differenz zwischen den Geschlechtern sowie das Signifikanzniveau eines T-Tests⁶⁸ dar.⁶⁹ Der bereinigte Datensatz enthält in Summe 31.316 Angebote, von denen 7.466 auf Frauen und 23.850 auf Männer entfallen. Der Frauenanteil der abgegebenen Angebote liegt damit bei 23,8 Prozent.

Unter den 2.274 beauftragten Freelancer:innen befinden sich 502 Frauen und 1.772 Männer. Frauen weisen hierbei eine um 0,7 Prozentpunkte geringere Beauftragungshäufigkeit im Vergleich zu Männern auf (6,7 vs. 7,4 Prozent). Weiterhin liegen die Angebotspreise von Frauen durchschnittlich 8,6 EUR pro Auftrag unter denen von Männern. Bereits deskriptiv lassen sich damit Unterschiede in den abhängigen Variablen zwischen Frauen und Männern feststellen. Um genauer zu verstehen, woraus diese resultieren könnten, hilft es, sich die Verteilung in die zugehörigen Tätigkeitskategorien⁷⁰ anzuschauen.

⁶⁸ Es ist stets ein zweiseitiger T-Test für zwei unabhängige Stichproben gemeint. Um einen besseren Lesefluss zu ermöglichen, wird auf die genaue Bezeichnung im Text verzichtet.

⁶⁹ Im Anhang Tabelle 6 finden sich darüber hinaus auch Angaben zu weiteren Lageparametern der einzelnen Variablen, auf die an dieser Stelle der Übersichtlichkeit halber verzichtet wird.

⁷⁰ Die Tätigkeitskategorien werden anhand der beim Auftrag angegebenen Skills zugeordnet und entsprechen den 16 Kategorien der Plattform im Januar 2022 (Freelancer.com 2022c).

Tabelle 16: Charakteristika der Freelancer:innen nach dem Geschlecht

Variable	Gesamt	Frauen	Männer	Differenz (F-M)
Abhängige Variablen				
<i>Beauftragt (Dummy)</i>	0,073 (0,260)	0,067 (0,250)	0,074 (0,262)	-0,007 **
<i>Angebotspreis (EUR)</i>	104,8 (128,2)	98,3 (122,5)	106,9 (129,8)	-8,6 ***
Zentrale unabhängige Variable				
<i>Rang (1-21)</i>	9,7 (5,7)	10,4 (5,6)	9,5 (5,7)	0,9 ***
Kontrollvariablen				
Bidlist				
<i>Lieferzeit (Tage)</i>	4,4 (4,4)	4,0 (3,7)	4,5 (4,6)	-0,5 ***
<i>Rating (0-5)</i>	4,0 (1,9)	3,9 (1,9)	4,0 (1,9)	-0,1 ***
<i>Bewertungen (Anzahl)</i>	190,1 (448,9)	190,6 (363,3)	189,9 (472,5)	0,7
<i>Kum. Plattformeinkommen (0-10)</i>	4,6 (2,8)	4,6 (2,9)	4,6 (2,8)	0,0
<i>Entwickeltes Land (Dummy)</i>	0,069 (0,253)	0,082 (0,275)	0,064 (0,245)	0,018 ***
<i>Schwellenland (Dummy)</i>	0,806 (0,396)	0,826 (0,379)	0,799 (0,401)	0,026 ***
<i>Entwicklungsland (Dummy)</i>	0,126 (0,332)	0,092 (0,289)	0,136 (0,343)	-0,044 ***
Performance				
<i>Auftragsabschlussrate (%)</i>	84,9 (31,6)	84,1 (32,8)	85,1 (31,2)	-1,0 **
<i>Einhaltung des Budgets (%)</i>	79,6 (31,6)	78,0 (32,2)	80,1 (31,4)	-2,1 ***
<i>Einhaltung der Lieferzeit (%)</i>	79,5 (31,6)	77,9 (32,4)	80,1 (31,3)	-2,2 ***
<i>Wiederbeauftragungsquote (%)</i>	11,0 (9,6)	10,3 (8,9)	11,3 (9,8)	-1,0 ***
Weitere plattformgenerierte Variablen				
<i>Weiterempfehlungen (Anzahl)</i>	17,6 (42,7)	21,7 (38,7)	16,3 (43,9)	5,4 ***
<i>Verifizierungsindex (0-1)</i>	0,7 (0,2)	0,7 (0,2)	0,7 (0,2)	0,0 ***
<i>Plattformerfahrung (Jahre)</i>	4,4 (3,7)	3,8 (3,1)	4,6 (3,8)	-0,8 ***
<i>Absolvierte Tests (Anzahl)</i>	1,7 (1,7)	1,3 (1,5)	1,7 (1,8)	-0,4 ***
<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>	0,470 (0,499)	0,362 (0,481)	0,504 (0,500)	-0,142 ***
<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>	0,808 (0,394)	0,777 (0,416)	0,818 (0,386)	-0,041 ***
Externe Variablen				
<i>Bildungsniveau Hoch (Dummy)</i>	0,661 (0,473)	0,645 (0,479)	0,666 (0,472)	-0,021 ***
<i>Bildungsniveau Mittel (Dummy)</i>	0,033 (0,177)	0,038 (0,191)	0,031 (0,173)	0,007 ***
<i>Bildungsniveau Niedrig (Dummy)</i>	0,056 (0,230)	0,068 (0,252)	0,052 (0,223)	0,016 ***
<i>Zertifikate (Anzahl)</i>	0,6 (0,8)	0,6 (0,8)	0,7 (0,9)	-0,1 ***
<i>Erfahrung (Anzahl)</i>	1,0 (1,0)	0,9 (0,9)	1,0 (1,0)	-0,1 ***
<i>Publikationen (Anzahl)</i>	0,3 (0,8)	0,3 (0,7)	0,3 (0,8)	0,0 ***
Anzahl an Beobachtungen	31.316	7.466	23.850	

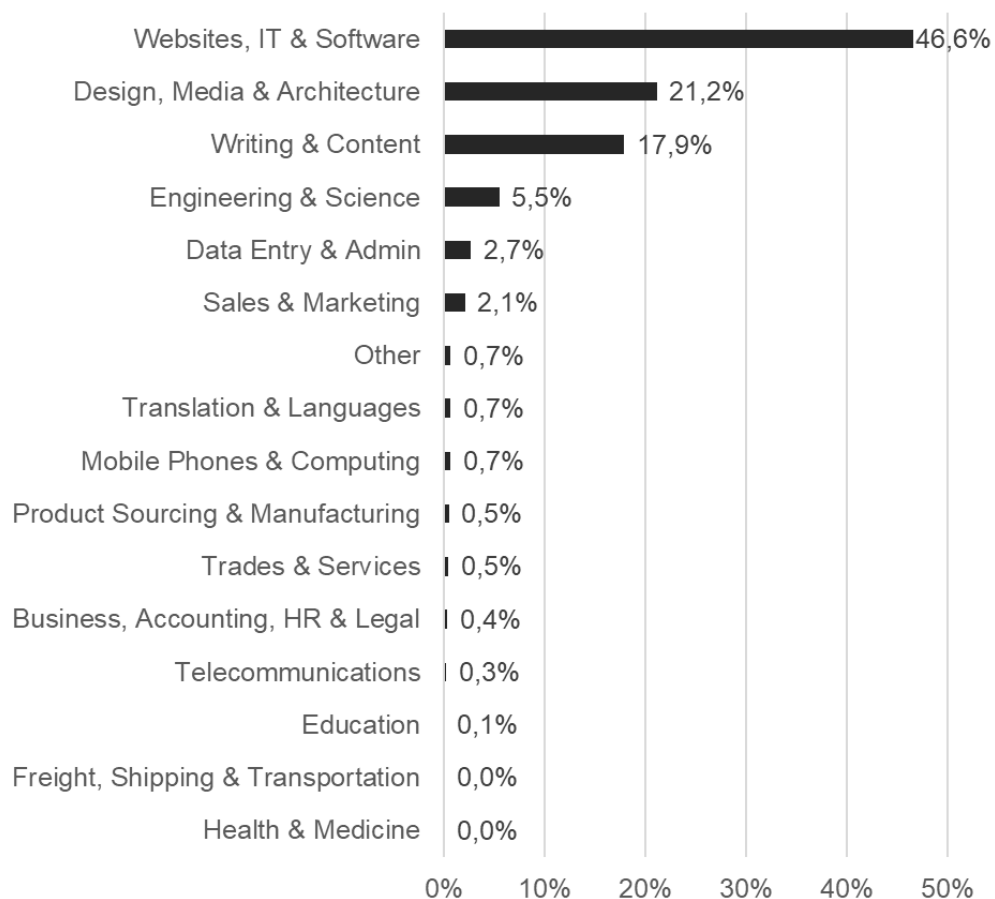
Angegeben ist der Mittelwert und in Klammern die Standardabweichung.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Aus Abbildung 5 wird deutlich, dass ein Großteil der Aufträge sich auf einige wenige Tätigkeitskategorien verteilt. Über 85 Prozent entfallen auf die drei Tätigkeitskategorien „Websites, IT & Software“, „Design, Media & Architecture“ und „Writing & Content“, die weiteren 15 Prozent verteilen sich auf die restlichen 13 Kategorien. Die Tätigkeitsbereiche können dabei sowohl hochkomplexe Aufträge (z. B. das Programmieren von Software) als auch einfache Texterstellungsaufträge umfassen und decken damit auch sehr unterschiedliche Qualifikationsanforderungen an die Freelancer:innen ab. Die hohe Anzahl an Beobachtungen und die Heterogenität innerhalb der Tätigkeitskategorien gilt es in der empirischen Analyse zu nutzen, weshalb sich fortan für die Analyse auf Tätigkeitsebene auf die drei häufigsten Tätigkeitskategorien gestützt wird.

Abbildung 5: Verteilung der abgegebenen Angebote auf die Tätigkeitskategorien

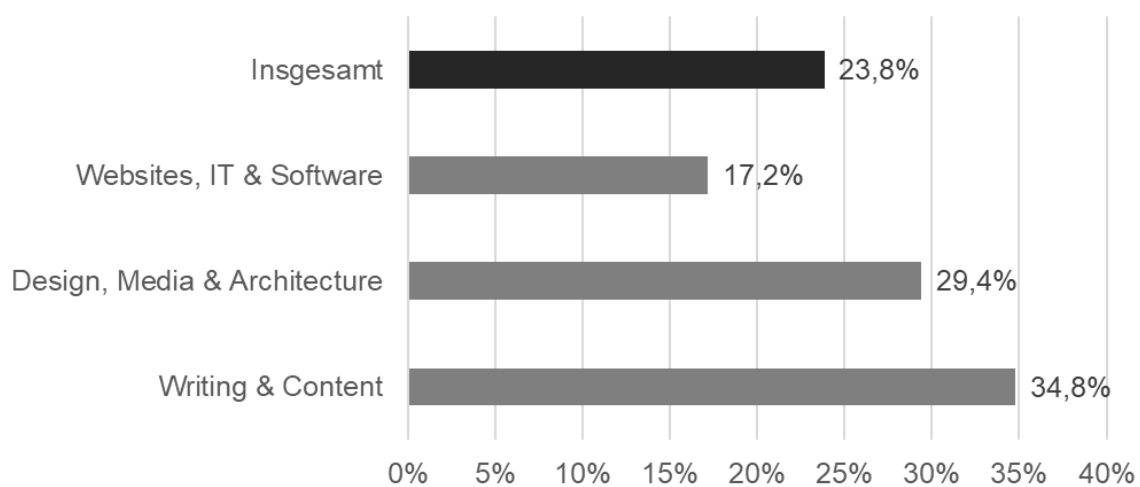


Quelle: Eigene Berechnung und Darstellung auf Basis des bereinigten Datensatzes.

Hinsichtlich der Geschlechteranteile lassen sich zwischen den Tätigkeitskategorien Unterschiede feststellen (vgl. Abbildung 6). Frauen sind im Tätigkeitsbereich „Websites, IT & Software“ im Vergleich zum gesamten Datensatz unterrepräsentiert

und im Bereich „Design, Media & Architecture“ sowie „Writing & Content“ überrepräsentiert. Damit kann für die Kategorie „Websites, IT & Software“ von einer männertypischen Kategorie gesprochen werden.⁷¹ „Writing & Content“ weist den zweithöchsten Frauenanteil⁷² im gesamten Datensatz auf und wird daher als frauentypische Kategorie definiert. „Design, Media & Architecture“ liegt mit genügend Beobachtungen am nächsten zum durchschnittlichen Frauenanteil von 23,8 Prozent und wird deshalb als geschlechterneutrale Kategorie für die nächsten Analyseschritte herangezogen.

Abbildung 6: Frauenanteile der abgegebenen Angebote insgesamt und nach den drei häufigsten Tätigkeitskategorien



Quelle: Eigene Berechnung und Darstellung auf Basis des bereinigten Datensatzes.

Mit dieser Einteilung stimmt *freelancer.com* mit denen anderer Plattformen überein. In der Literatur gelten Tätigkeiten aus dem Bereich Software und Webentwicklung als eher männertypisch und Tätigkeiten aus dem Bereich der Texterstellung und Übersetzung als eher frauentypisch (z. B. Chan und Wang 2018:2988; Dubey et al. 2017:17; Foong et al. 2018:11; Galperin 2021:1095 f.; Leung und Koppman 2018:782). Diese Einteilung steht auch im Einklang mit Forschungsergebnissen zu Stereotypen außerhalb der Plattformökonomie, die ergeben, dass Männern typischerweise bessere mathematische Fähigkeiten und Frauen bessere verbale

⁷¹ Die Tätigkeitskategorie weist mit 17,2 Prozent den drittniedrigsten Frauenanteil im Datensatz auf. Lediglich „Freight, Shipping & Transportation“ (10 Prozent; 10 Angebote) und „Product Sourcing & Manufacturing“ (14,5 Prozent, 165 Angebote) weisen niedrigere Frauenanteile auf, werden aber aufgrund der geringen Anzahl erfasster Angebote nicht weiter berücksichtigt.

⁷² Die Tätigkeitskategorie „Translation & Languages“ hat einen Frauenanteil von 43,2 Prozent, jedoch konnten in dieser Kategorie lediglich 222 Angebote erfasst werden, weshalb sie für die Auswertung nicht in Frage kommt.

Kompetenzen zugeschrieben werden (Baird 2012; Correll 2001; Gorman 2005; Leung und Koppman 2018:780). Auch passt dies zu der horizontalen Segregation auf dem deutschen Arbeitsmarkt (Hobler et al. 2020; IAB 2018; Lott et al. 2022). Das Ausmaß der unterschiedlichen Geschlechteranteile ist zwar nicht vergleichbar mit der Segregation auf dem klassischen Arbeitsmarkt, es lässt sich dennoch festhalten, dass sich eine gewisse Ungleichverteilung auch auf der untersuchten Plattform fortsetzt.

Ob die Unterschiede in den Geschlechteranteilen auch empirisch standhalten, wird mithilfe eines T-Tests geprüft. Bei allen drei Tests kann die Nullhypothese (kein Unterschied in den Geschlechteranteilen) zum Signifikanzniveau von einem Prozent verworfen werden. D. h. die beschriebenen Unterschiede in den Geschlechteranteilen zwischen den Tätigkeitskategorien sind statistisch signifikant. D. h. die Hypothese H3 kann bestätigt werden.⁷³

H3	Die Tätigkeitskategorien der Plattform weisen unterschiedliche Geschlechterverhältnisse auf.	✓
----	--	---

Die neben dem Geschlecht zweite zentrale unabhängige Variable ist der Rang eines:r Freelancer:in in der Bidlist. Dieser ergibt sich über die absteigende Sortierung der Freelancer:innen anhand des skillspezifischen Scores des Rankingalgorithmus (vgl. Abschnitt 3.2.5). Frauen weisen durchschnittlich einen um fast eine Position schlechteren Rang auf als Männer. Für die Bildung des Rangs sind sowohl beobachtbare als auch plattforminterne Variablen und Kennzahlen verantwortlich (vgl. Tabelle 9).

Um sich dem Rangunterschied anzunähern und zu verstehen, woher dieser resultieren könnte, können die Geschlechterunterschiede in den beobachtbaren Variablen betrachtet werden. Bei den relevanten Variablen handelt es sich um die Anzahl und Höhe an Bewertungen des:r Freelancer:in, das Volumen vergangener Projekte sowie die absolvierten Tests und Variablen zur Profilvollständigkeit. Weiter kann die Erfahrung des Auftraggebenden über die Anzahl an Bewertungen erfasst werden. Alle weiteren Kennzahlen aus Tabelle 9 werden von der Plattform intern erhoben und sind nicht öffentlich verfügbar.

⁷³ Entgegen der Reihenfolge der Hypothesen aus Abschnitt 3.3 werden die Hypothesen H3 und H6 bereits hier behandelt, da sie sich auf Basis der deskriptiven Auswertung überprüfen lassen.

Sowohl Frauen als auch Männer weisen im Datensatz durchschnittlich ungefähr gleich viele Bewertungen auf. Die Höhe der Bewertungen unterscheidet sich zwar signifikant zwischen den Geschlechtern, mit 0,1 Punkten ist das Ausmaß jedoch gering. Auch für das kumulierte Plattformeinkommen als Proxy für das Volumen vergangener Projekte lässt sich im Mittel kein Unterschied zwischen Frauen und Männern feststellen. Außerdem selektieren sich weibliche Freelancer:innen nicht auffällig häufig in Aufträge von Auftraggebern mit geringer Plattformerfahrung, das sich negativ auf den Score auswirken würde (vgl. Tabelle 17). Bei den Angaben zu externen Zertifikaten und der externen Berufserfahrung, weisen weibliche Freelancer:innen im Durchschnitt zehn Prozent weniger Angaben auf als Männer. Weiter liegt die durchschnittliche Anzahl der absolvierten Tests um 0,4 Tests bei Frauen niedriger als bei Männern. Die Verifizierungen der Profilinformationen sind hingegen ähnlich hoch wie bei Männern.

Tabelle 17: Charakteristika der Auftraggebenden und Aufträge nach dem Geschlecht der Freelancer:innen

Variable	Gesamt	Frauen	Männer	Differenz (F-M)
Auftraggebende				
Rating (0-5)	3,1 (2,4)	3,0 (2,4)	3,2 (2,4)	-0,2 ***
Bewertungen (Anzahl)	19,6 (65,9)	20,7 (76,5)	19,3 (62,2)	1,4
Entwickeltes Land (Dummy)	0,646 (0,478)	0,625 (0,484)	0,652 (0,476)	-0,027 ***
Schwellenland (Dummy)	0,326 (0,469)	0,350 (0,477)	0,319 (0,466)	0,031 ***
Entwicklungsland (Dummy)	0,028 (0,166)	0,025 (0,157)	0,029 (0,169)	-0,004 *
Verifizierungsindex (0-1)	0,7 (0,3)	0,7 (0,3)	0,7 (0,3)	-0,1 ***
Aufträge				
Budget Minimum (EUR)	40,8 (65,2)	40,1 (64,1)	41,1 (65,6)	-0,9
Budget Maximum (EUR)	5.701,9 (74.108,4)	4.193,5 (63.255,2)	6.174,1 (77.188,0)	-1.980,6 **
Stundenbasierter Auftrag (Dummy)	0,130 (0,336)	0,122 (0,327)	0,132 (0,339)	-0,011 **
Anzahl an Beobachtungen	31.316	7.466	23.850	
Angegeben ist der Mittelwert und in Klammern die Standardabweichung				
Statistische Signifikanz: *10%, **5%, ***1%-Level				

Quelle: Eigene Berechnungen und Darstellung.

Um eine Intuition dafür zu bekommen, welche Zusammenhänge zwischen dem Rang und den für den Rankingalgorithmus relevanten Variablen besteht, wird eine

einfache lineare Regression geschätzt⁷⁴, deren Ergebnisse im Anhang Tabelle 13 entnommen werden können. Diese zeigt, dass zwischen den relevanten Variablen und den Rängen der Freelancer:innen signifikante Zusammenhänge bestehen, die jedoch aufgrund der geringen beobachteten Differenzen zwischen den Geschlechtern, den Rangunterschied nicht vollständig erklären könnten. Dies lässt die Schlussfolgerung zu, dass die Rangunterschiede maßgeblich auf die internen Daten der Plattform zurückgehen, die nicht beobachtet werden können.

Sofern Auftraggebende die Freelancer:innen anhand von Stereotypen auswählen, wäre bei ansonsten gleichen Charakteristika eine höhere Beauftragungswahrscheinlichkeit für Frauen in frauentypischen und für Männer in männertypischen Tätigkeitskategorien zu erwarten. Ob sich dies empirisch bestätigen lässt, wird in Abschnitt 5.2 untersucht. Angenommen, es würde sich ein solches Beauftragungsverhalten finden lassen, wäre es damit Frauen und Männern möglich, in den jeweiligen geschlechtstypischen Tätigkeitskategorien, bei gleicher Arbeitsleistung und anderer für den Rankingalgorithmus relevanter Charakteristika, höhere Scores zu erreichen, da sie bspw. mehr Aufträge und damit mehr Bewertungen erhalten können. Damit einhergehen würde ein systematisch besserer Rang von Frauen in frauentypischen und Männern in männertypischen Tätigkeitskategorien. Der Rankingalgorithmus würde dadurch dazu beitragen, dass sich vorherrschende Stereotype verfestigen. Dazu wird die Hypothese H6 aufgestellt.

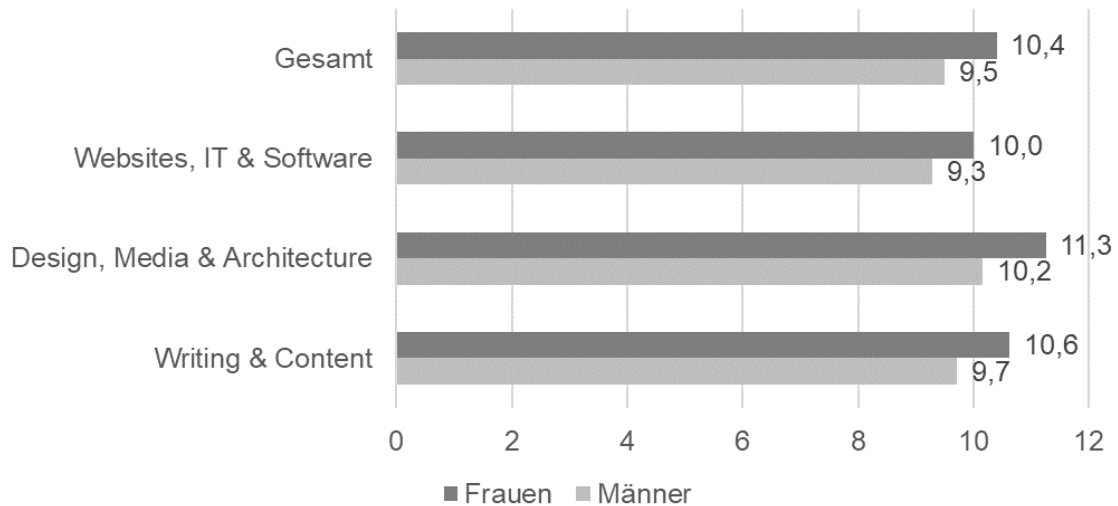
Aus Abbildung 7 wird ersichtlich, dass Frauen sowohl in geschlechtstypischen als auch -untypischen Tätigkeitskategorien durchschnittlich schlechtere Ränge als Männer aufweisen. Die Unterschiede sind jeweils statistisch hochsignifikant.⁷⁵ Es zeigt sich also kein für die Tätigkeitskategorien spezifisches Muster in den Rängen,

⁷⁴ Bei dem Rang handelt es sich um eine ordinalskalierte Variable, weshalb eine geordnete logistische Regression ebenfalls ein geeignetes Verfahren zur Schätzung des Zusammenhangs ist. Jedoch kann die abhängige Variable aufgrund der Vielzahl an Rängen auch als stetige Variable interpretiert und dementsprechend eine lineare Regression geschätzt werden. Um sicherzugehen, dass die Ergebnisse nicht von der Wahl des Analysemodells abhängen, wird ebenfalls eine geordnete logistische Regression geschätzt, deren Koeffizienten sowohl in Wirkungsrichtung als auch hinsichtlich der Signifikanz mit denen der linearen Regression übereinstimmen.

⁷⁵ Durchgeführt wird für die jeweilige Tätigkeitskategorie ein T-Test, deren Nullhypothesen jeweils zum Signifikanzniveau von einem Prozent verworfen werden können.

das mit der vorangegangenen Argumentation vereinbar ist, weshalb die Hypothese H6 von den vorliegenden Daten nicht gestützt werden kann.

Abbildung 7: Durchschnittlicher Rang von Frauen und Männern nach den drei häufigsten Tätigkeitskategorien



Quelle: Eigene Berechnung und Darstellung auf Basis des bereinigten Datensatzes.

Auch auf Tätigkeitsebene lassen sich die unterschiedlichen Ränge nicht durch Unterschiede in den beobachtbaren und für den Rankingalgorithmus relevanten Variablen (vgl. Anhang Tabelle 7 bis Anhang Tabelle 12) erklären. Es lässt sich keine eindeutige Erklärung der durchweg niedrigeren Ränge von Frauen im Vergleich zu Männern finden. Letztlich bleiben damit nur noch die Einflussfaktoren aus den internen Daten der Plattform, die in der Analyse nicht zur Verfügung stehen, um diese Unterschiede zu erklären.

H6	Weibliche und männliche Freelancer weisen unterschiedliche Ränge in geschlechtstypischen Tätigkeitskategorien auf.	x
----	--	----------

Ein möglicher Ansatz, um die plattformintern erfassten Variablen zu approximieren, offenbart Anhang Tabelle 13. In dieser fällt auf, dass Freelancer:innen mit einer kostenpflichtigen Mitgliedschaft tendenziell ein um einen Rang besseres Ranking aufweisen. Frauen schließen im Vergleich zu Männern rund 14 Prozentpunkte weniger häufig eine kostenpflichtige Mitgliedschaft auf der Plattform ab. Zwar wird diese Variable laut der Plattform nicht im Rankingalgorithmus direkt genutzt, könnte aber als Proxy für die internen nichtbeobachtbaren Variablen dienen. Eine Vermutung wäre, dass es sich hierbei um Freelancer:innen handelt, die sehr

ernsthaft und vielleicht sogar im Hauptgewerbe auf der Plattform aktiv sind und dementsprechend bereit sind, den Mitgliedsbeitrag zu bezahlen. Diese weisen daher bessere Werte bei den von der Plattform intern erfassten Daten (z. B. häufigere Nutzung von Milestone Zahlungen oder der Desktop-App, hohes Reaktionsvermögen etc.) auf und erhalten dadurch einen höheren Score und ein besseres Ranking. Diese Erkenntnisse bekräftigen das angedachte empirische Vorgehen, sowohl die Mitgliedschaft als auch den Rang als unabhängige und Kontrollvariable in der Analyse zu inkludieren, da diese als Proxy für die internen nichtbeobachtbaren Daten dienen können.

Die zuvor beschriebenen Geschlechterunterschiede in den beiden zentralen unabhängigen Variablen lassen sich auch bei der deskriptiven Auswertung der weiteren Kontrollvariablen feststellen (vgl. Tabelle 16). Weibliche Freelancer:innen weisen um einen halben Tag signifikant geringere Lieferzeiten auf, das mit der Selbstselektion der Freelancer:innen in Tätigkeitskategorien mit eher kleineren Aufträgen einhergeht. Insgesamt stammen mehr als 80 Prozent der Freelancer:innen aus Schwellenländern, knapp 7 Prozent aus entwickelten Ländern und fast 13 Prozent aus Entwicklungsländern. Weibliche Freelancer:innen kommen dabei häufiger aus entwickelten und Schwellenländern (4,4 Prozentpunkte) und weniger häufig aus Entwicklungsländern. Im Gegensatz dazu kommen die Auftraggebenden zu fast 65 Prozent aus entwickelten Ländern, zu 33 Prozent aus Schwellenländern und zu knapp 3 Prozent aus Entwicklungsländern, ein Gefälle, das typisch für Arbeitsplattformen ist (z. B. Galperin und Greppi 2017; Jinnai 2016; Mill 2011).

Bei den Performancevariablen fällt auf, dass alle vier bei Frauen statistisch signifikant geringer ausfallen als bei Männern. Ein Blick in die drei Tätigkeitskategorien zeigt, dass dies aus der männertypischen Tätigkeitskategorie „Websites, IT & Software“ resultiert. Im Bereich „Design, Media & Architecture“ weisen weibliche Freelancer eine höhere Auftragsabschlussrate, aber eine niedrigere Wiederbeauftragungsquote auf und im Bereich „Writing & Content“ zeigen sich keine signifikanten Unterschiede. Sowohl eine Minderleistung von Frauen in der männertypischen Tätigkeitskategorie als auch das Ansetzen höherer Maßstäbe bei Frauen könnten als mögliche Erklärungsansätze für diese Unterschiede dienen.

Bei den weiteren plattformgenerierten Variablen lassen sich ebenfalls Unterschiede feststellen. Im Durchschnitt sind die Freelancer:innen auf der Plattform bereits seit 4,4 Jahren registriert. Frauen weisen eine um fast zehn Monate geringere Plattformzugehörigkeit auf. Fast die Hälfte der Freelancer:innen schließen eine kostenpflichtige Mitgliedschaft ab. Unter den Frauen machen dies lediglich 36,2 Prozent. Über 80 Prozent der Freelancer:innen bewerben sich auf Aufträge aus Tätigkeitsbereichen, in denen sie bereits zuvor Erfahrung gesammelt haben. Bei weiblichen Freelancern fällt dieser Anteil mit 77,7 Prozent signifikant geringer aus. Der Durchschnitt, der im Profil angegebenen Weiterempfehlungen, liegt bei 17,6 Angaben und Frauen weisen durchschnittlich 5,4 Angaben mehr als Männer auf.

Rund 66 Prozent der Freelancer:innen geben einen hohen Bildungsabschluss, 3,3 Prozent einen mittleren und 5,6 Prozent einen niedrigen Bildungsabschluss an. Für rund 25 Prozent bleibt damit das Bildungsniveau unbekannt. Der Anteil von Frauen mit hohem Bildungsniveau ist im Vergleich zu Männern 2,1 Prozentpunkte geringer. Mehrheitlich handelt es sich auf der Plattform also um hochqualifizierte Freelancer:innen mit akademischen Abschlüssen, ein Ergebnis (vgl. Abschnitt 2.1.4.4), das so auch auf andere Plattformen (z. B. Ipeirotis 2010b; Levay et al. 2016) und Plattformarbeitende im Allgemeinen zutrifft (z. B. Pesole et al. 2018:25; Urzi Brancati et al. 2020:25).

Zusammenfassend kann festgehalten werden, dass der:die durchschnittliche Freelancer:in auf der Plattform männlich und hochqualifiziert ist sowie aus einem Schwellenland stammt und bereits seit einigen Jahren auf der Plattform aktiv ist. Im Vergleich dazu weisen Frauen auf der Plattform durchschnittlich schlechtere Ränge in der Bidlist auf, geringere Performancemaße, eine geringere Plattformzugehörigkeit in Jahren und schließen deutlich weniger häufig eine kostenpflichtige Mitgliedschaft ab. Auch ist eine Selbstselektion von Frauen und Männern in geschlechertypische Tätigkeitskategorien zu beobachten. Welche Rolle diese Beobachtungen in der Quantifizierung der Beauftragungswahrscheinlichkeit und den Unterschieden in den Angebotspreisen von weiblichen und männlichen Freelancern auf der Plattform spielen, wird in den nächsten beiden Abschnitten empirisch untersucht.

5.2 Quantifizierung der Beauftragungswahrscheinlichkeit in Abhängigkeit des Geschlechts und des Rangs

Der vorherige Abschnitt hat gezeigt, dass sich deskriptiv in der Beauftragungshäufigkeit Geschlechterunterschiede feststellen lassen. Ziel in diesem Abschnitt ist es, den Einfluss des Geschlechts und des Rangs auf die Beauftragungswahrscheinlichkeit unter Berücksichtigung von Kontrollvariablen zu quantifizieren. Hierzu werden bedingte logistische Regressionsmodelle sowohl unter Einbezug aller Tätigkeitskategorien als auch einzeln für die drei Kategorien geschätzt (vgl. Abschnitt 4.3.1).

5.2.1 Zu prüfende Hypothesen und Hinweise zur Bewertung der Modellergebnisse

Tabelle 18 listet die in diesem Abschnitt zu prüfenden Hypothesen auf. Dabei nehmen Hypothese H1 und H4 Bezug auf den Koeffizienten der Geschlechtsvariable α . Hypothese H7 bezieht sich auf den Koeffizienten der Rangvariable δ und um die Hypothese H8 prüfen zu können, wird der Koeffizient der Interaktionsvariable π zwischen dem Geschlechterdummy und der Rangvariable betrachtet. Durch die Interaktionsvariable lassen sich geschlechtsspezifische Effekte des Rangs auf die Beauftragungswahrscheinlichkeit bestimmen.

Auf Ebene aller Tätigkeitskategorien werden zunächst verschiedene bedingte logistische Regressionsmodelle geschätzt. Um zu zeigen, wie sich die jeweiligen Koeffizienten und Gütemaße bei Hinzunahme weiterer Kontrollvariablen verändern, bauen die einzelnen Modelle aufeinander auf. Auch lässt sich auf diese Weise ein Eindruck gewinnen, wie robust der geschätzte Zusammenhang der zentralen unabhängigen Variablen mit der abhängigen Variable ist. Im voll spezifizierten Modell werden sämtliche für das Angebot spezifische oder für den:die Freelancer:in spezifische Variablen berücksichtigt. Zu beachten ist, dass Effekte für Variablen, die auftragspezifisch und damit konstant für alle anbietenden Freelancer:innen sind, in einem bedingten logistischen Regressionsmodell nicht berechnet werden können. Das Modell berechnet für jeden Auftrag eigene Konstanten (γ_i), die der Übersichtlichkeit halber nicht in den Regressionsergebnissen gezeigt werden.

Tabelle 18: Übersicht über die Hypothesen zur Beauftragungswahrscheinlichkeit

Nr.	Hypothese
H1	Die Beauftragungswahrscheinlichkeit von Freelancer:innen unterscheidet sich nach dem Geschlecht.
H4	Weibliche und männliche Freelancer weisen unterschiedliche Beauftragungswahrscheinlichkeiten in geschlechtstypischen Tätigkeitskategorien auf.
H7	Ein besserer Rang geht mit einer höheren Beauftragungswahrscheinlichkeit einher.
H8	Der Effekt eines besseren Rangs auf die Beauftragungswahrscheinlichkeit ist für weibliche und männliche Freelancer in geschlechtstypischen Tätigkeitskategorien unterschiedlich.

Quelle: Eigene Darstellung.

Tabelle 19 und Tabelle 20 stellen die jeweiligen Regressionsergebnisse dar. Dabei werden die Regressionskoeffizienten, die Standardfehler und das jeweilige Signifikanzniveau angegeben. Bei der Interpretation der Koeffizienten ist zu beachten, dass diese bei einer bedingten logistischen Regression, den Effekt auf das logarithmierte Chancenverhältnis (log-Odds-Ratio) angeben und nicht den marginalen Effekt auf die Beauftragungswahrscheinlichkeit. Das logarithmierte Chancenverhältnis zwischen einer Alternative j und k ist dabei definiert als das Verhältnis der Wahrscheinlichkeiten bei Auftrag i zwischen den Alternativen j und k zu wählen und ist aufgrund der IIA-Annahme unabhängig von Wahrscheinlichkeiten anderer Alternativen (vgl. Abschnitt 4.3.1).

$$\log(\text{Odds-Ratio}) = \log\left(\frac{P_{ij}}{P_{ik}}\right)$$

Für eine intuitive Interpretation und zum besseren Verständnis der Regressionskoeffizienten dient das folgende Zahlenbeispiel. Ein Koeffizient einer unabhängigen Variable x in Höhe von -0,05 gibt an, dass sich bei einer Veränderung der Variable x um eine Einheit, gegeben alle anderen Variablen bleiben konstant, das log-Odds-Ratio um diesen Faktor verändert. Wird die Exponentialfunktion auf den Koeffizienten angewendet, ergibt sich ein Odds-Ratio von $\exp(-0,05) = 0,95$.

Dieses gibt an, dass sich die Beauftragungschance (Odds)⁷⁶ von Alternative j , durch die Veränderung der Variable x um eine Einheit, um fünf Prozent reduziert. Die folgenden Tabellen beinhalten stets die Regressionskoeffizienten und beschreiben damit den Effekt auf das logarithmierte Odds-Ratio. Im Text wird dann auf den Effekt auf die Beauftragungschance eingegangen.

Auf Ebene aller Tätigkeitskategorien werden insgesamt acht verschiedene Modelle geschätzt. Die ersten vier Modelle beinhalten keine Kontrollvariablen, sondern berücksichtigen jeweils die zentralen unabhängigen Variablen allein und in Kombination. Ab Modell fünf werden Schritt für Schritt weitere Kontrollvariablen in das Modell eingefügt. Zur Bewertung der Güte des Modells werden verschiedene Teststatistiken angegeben. Zunächst wäre da der Log-Likelihood Wert. Ein höheres Log-Likelihood deutet dabei auf eine bessere Anpassungsgüte des Modells an die Daten hin. Es eignet sich also dazu, zwei Modelle miteinander zu vergleichen. Problematisch ist dabei, dass das Log-Likelihood mit der Anzahl der inkludierten Variablen steigt. Deshalb wird jeweils zum vorherigen Modell ein Likelihood Ratio Test durchgeführt. Dieser gibt an, ob die Hinzunahme der weiteren Variablen zu einer signifikanten Verbesserung der Anpassungsgüte geführt hat (Greene 2012:566 f.). Um die jeweilige Modellspezifikation der einzelnen Modelle bewerten zu können, wird zusätzlich noch die Teststatistik und das Signifikanzniveau eines Likelihood Ratio Tests zum Nullmodell, das nur eine Konstante als erklärende Variable enthält, angegeben. Der Übersichtlichkeit halber werden die Koeffizienten und Standardfehler der Kontrollvariablen in den folgenden Tabellen nicht gezeigt. Diese finden sich im Anhang Tabelle 15 für die Ebene aller und Anhang Tabelle 16 für die einzelnen Tätigkeitskategorien.

5.2.2 Analyse über alle Tätigkeitskategorien

In diesem Abschnitt erfolgt zunächst die Berechnung der bedingten logistischen Regression auf Ebene aller 16 Tätigkeitskategorien. Der zugrundeliegende Datensatz umfasst damit 31.316 Angebote, die auf 2.274 Aufträge entfallen und von 10.194 Freelancer:innen stammen. Die Berechnung der

⁷⁶ Die Beauftragungschance (Odds) ist definiert als die Wahrscheinlichkeit für Auftrag i Alternative j zu wählen (P_{ij}), geteilt durch die Gegenwahrscheinlichkeit ($1 - P_{ij}$).

Beauftragungswahrscheinlichkeit beruht für Männer auf 1.772 und für Frauen auf 502 Beobachtungen.

In Tabelle 19 zeigt sich, unabhängig von der Anzahl der inkludierten Kontrollvariablen, eine robuste Schätzung für die zentralen unabhängigen Variablen. Der Likelihood Ratio Test zum Nullmodell ist für alle Modelle, abgesehen vom ersten, hochsignifikant. D. h. alle Modelle, außer dem Ersten, können die Daten besser erklären als das Nullmodell mit nur einer Konstanten als erklärende Variable.


Die Geschlechtsvariable allein bietet keinen Erklärungsmehrwert gegenüber dem Nullmodell (Modell 1). Dies zeigt sich auch im dritten Modell, bei dem der Likelihood Ratio Test zum Vormodell insignifikant bleibt. Die aufbauende Hinzunahme der Kontrollvariablen, kann die Anpassungsgüte des Modells immer weiter erhöhen. Lediglich das achte Modell, das sich zum siebten Modell in der Hinzunahme plattformexterner Kontrollvariablen unterscheidet, kann keinen weiteren Erklärungsmehrwert liefern. Dies zeigt, dass Erfahrungen von außerhalb der Plattform weniger relevant für die Beauftragung der Freelancer:innen sind als plattforminterne Variablen wie das Rating oder Bewertungen. Ein Ergebnis, das im Einklang mit den Kernergebnissen aus der Literatur steht (vgl. Abschnitt 2.3.3).

Der niedrige Erklärungsgehalt der Geschlechtsvariable zeigt sich auch in den insignifikanten Koeffizienten. Diese signalisieren einen negativen Zusammenhang zwischen dem weiblichen Geschlecht und der Beauftragungswahrscheinlichkeit⁷⁷. Im ersten Modell weisen weibliche Freelancer:innen ein Odds Ratio von 0,94 ($\exp(-0,062)$) auf, d. h. weibliche Freelancer haben demnach eine um sechs Prozent niedrigere Beauftragungschance⁷⁸ als männliche Freelancer. Dieser Effekt nimmt durch die Hinzunahme weiterer Kontrollvariablen kontinuierlich ab. Im vollspezifizierten achten Modell liegt der Geschlechterunterschied in der Beauftragungschance bei 2,8 Prozent ($\exp(-0,038 + 0,009) - 1$). Die Effekte bleiben in sämtlichen Modellen insignifikant, weshalb geschlossen werden kann, dass Freelancer:innen, die sich lediglich im Geschlecht voneinander unterscheiden, die


⁷⁷ Das Vorzeichen eines Koeffizienten lässt sich auch im direkten Bezug zur Beauftragungswahrscheinlichkeit interpretieren, die Höhe des Koeffizienten zeigt hingegen den Effekt auf das log-Odds-Ratio.

⁷⁸ Das Odds Ratio gibt an, wieviel die Odds von weiblichen Freelancern von denen männlicher Freelancern abweichen. Daher muss hier von der Beauftragungschance in Abgrenzung zur Wahrscheinlichkeit gesprochen werden.

gleiche Beauftragungswahrscheinlichkeit auf der Plattform haben. Somit lassen sich keine Hinweise zur Bestätigung von Hypothese H1 finden.

H1	Die Beauftragungswahrscheinlichkeit von Freelancer:innen unterscheidet sich nach dem Geschlecht.	
----	--	---

Anders sieht dies bei der zweiten zentralen unabhängigen Variable aus, dem Rang. Es zeigt sich über alle Modelle ein hochsignifikanter negativer Zusammenhang zwischen dem Rang eines:r Freelancer:in und der Beauftragungswahrscheinlichkeit. Zu beachten ist hierbei, dass die Rangvariable invers definiert ist, d. h. ein negativer Koeffizient wirkt sich bei einer Rangverbesserung positiv auf die Beauftragungswahrscheinlichkeit aus. Bei der alleinigen Betrachtung des Rangs im zweiten Modell führt eine Verbesserung um eine Position (z. B. von Position drei auf zwei in der Bidlist) zu einem Anstieg der Beauftragungschance um 6,8 Prozent ($\exp(-0,071) - 1$). Die Rangposition spielt demnach eine wichtige Rolle in der Beauftragungsentscheidung von Auftraggebenden, bessere Ränge gehen mit einer höheren Beauftragungswahrscheinlichkeit einher, was die Hypothese H7 bestätigt.

H7	Ein besserer Rang geht mit einer höheren Beauftragungswahrscheinlichkeit einher.	
----	--	---

Ergänzend dazu kann untersucht werden, ob sich bei dem zuvor beschriebenen Rangeffekt Geschlechterunterschiede feststellen lassen. Dazu wird der Rangeffekt ab dem vierten Modell, durch den Einbezug der Interaktionsvariable, nach dem Geschlecht getrennt. Laut dem achten Modell führt eine Verbesserung des Rangs um eine Position für Männer zu einem Anstieg der Beauftragungschance um 7,6 Prozent ($\exp(-0,079) - 1$) und für Frauen um 6,8 Prozent ($\exp(-0,079 + 0,009) - 1$). Die Differenz von 0,8 Prozentpunkten impliziert, dass Frauen weniger von einer Rangverbesserung profitieren als Männer. Jedoch ist die Interaktionsvariable in keinem Modell statistisch signifikant. Damit lässt sich kein geschlechtsspezifischer Rangeffekt auf Ebene aller Tätigkeitskategorien feststellen.

Tabelle 19: Ergebnisse der bedingten logistischen Regression zur Analyse der Beauftragungswahrscheinlichkeit

Abhängige Variable: Beauftrag (Dummy)	1	2	3	4	5	6	7	8
Zentrale unabhängige Variablen								
Geschlecht (Dummy: 1=Frau, 0=Mann)	-0,062 (0,055)		-0,014 (0,055)	-0,081 (0,099)	-0,052 (0,100)	-0,045 (0,100)	-0,039 (0,101)	-0,038 (0,101)
Rang (1-21)		-0,071 *** (0,004)	-0,071 *** (0,004)	-0,073 *** (0,005)	-0,080 *** (0,008)	-0,076 *** (0,008)	-0,078 *** (0,008)	-0,079 *** (0,008)
Geschlecht x Rang				0,008 (0,010)	0,007 (0,010)	0,007 (0,010)	0,009 (0,010)	0,009 (0,010)
Kontrollvariablen								
Bidlist					✓	✓	✓	✓
Performance						✓	✓	✓
Weitere plattformgenerierte Variablen							✓	✓
Externe Variablen								✓
Anzahl an Angeboten	31.316	31.316	31.316	31.316	31.316	31.316	31.316	31.316
Anzahl an Aufträgen	2.274	2.274	2.274	2.274	2.274	2.274	2.274	2.274
Log-Likelihood	-5.793	-5.663	-5.663	-5.663	-5.572	-5.485	-5.412	-5.409
Likelihood Ratio Test (zum Nullmodell)	1,3	261,5 ***	261,6 ***	262,3 ***	366,1 ***	543,1 ***	699,9 ***	706,0 ***
Likelihood Ratio Test (zum vorherigen Modell)	-	260,4 ***	0,0	0,6	181,0 ***	174,4 ***	147,0 ***	4,8

Angegeben sind die jeweiligen Regressionskoeffizienten der bedingten logistischen Regression.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Zunächst kann damit festgehalten werden, dass sich über alle Tätigkeitskategorien hinweg auf der Plattform keine Diskriminierung anhand des Geschlechts feststellen lässt. Unterschiede in den Charakteristika der Freelancer:innen sowie in den Rängen, können die Differenz in den beobachteten Beauftragungshäufigkeiten der deskriptiven Analyse vollständig erklären. Freelancer:innen mit gleichen Charakteristika, die sich lediglich im Geschlecht unterscheiden, weisen weder unterschiedliche Beauftragungswahrscheinlichkeiten auf, noch bewerten Auftraggebende deren Ränge unterschiedlich.

Die Analyse hat einen wichtigen und in bisherigen Untersuchungen vernachlässigten Einfluss auf die Beauftragungsentscheidung aufgedeckt, der Rang von Freelancer:innen. Die Ergebnisse zeigen, dass dem Rankingalgorithmus der Plattform eine bedeutende Rolle im Beauftragungsprozess zukommt, dem Freelancer:innen ausgesetzt sind. Für die Beauftragungsentscheidung der Auftraggebenden scheint es bedeutender zu sein, welchen Rang Freelancer:innen aufweisen und weniger, welchem Geschlecht sie angehören. Von den Auftraggebenden geht demnach keine Diskriminierung aus. Problematisch ist jedoch, dass aus nicht weiter belegbaren Gründen Frauen auf der Plattform durchschnittlich schlechtere Ränge aufweisen als Männer. In Kombination mit den hier berechneten positiven Rangeffekten ergeben sich damit durchschnittlich geringere Beauftragungschancen für Frauen. Ob der Rankingalgorithmus Frauen diskriminiert oder der Geschlechterunterschied auf die internen Daten der Plattform zurückgeht, bleibt offen und bedarf weiterer Forschung.

5.2.3 Analyse auf Ebene der Tätigkeitskategorien

Bisherige Untersuchungen haben gezeigt, dass sich die Beauftragungswahrscheinlichkeiten der Geschlechter zwischen den Tätigkeitskategorien unterscheiden können (vgl. Abschnitt 2.3.1). Auch im vorliegenden Fall wäre es möglich, dass sich die Geschlechterunterschiede aufgrund der Zusammensetzung der verschiedenen Tätigkeitskategorien im Datensatz auf oberster Ebene ausgleichen und daher auf dieser Ebene keine Unterschiede festgestellt werden können. Weiter kann die Analyse der jeweils geschlechtertypischen Tätigkeitskategorien Hinweise auf die Nutzung von Stereotypen bei der Beauftragung liefern, sofern sich für die Kategorien spezifische Geschlechterunterschiede in der Beauftragungswahrscheinlichkeit feststellen

lassen. Zur Untersuchung auf Ebene der Tätigkeitskategorien wird daher das vollspezifizierte achte Modell für die einzelnen Tätigkeitsbereiche berechnet. Auch, wenn dieses Modell durch den Einbezug der plattformexternen Variablen keinen signifikanten Erklärungsmehrwert gegenüber dem siebten Modell aufweist, wird dieses trotzdem genutzt, um zu vermeiden, dass fälschlicherweise mögliche Geschlechterunterschiede auf Tätigkeitsebene ausgewiesen werden, die eigentlich auf Unterschieden von außerhalb der Plattform beruhen.

In Tabelle 20 sind die Regressionsergebnisse der einzelnen Tätigkeitskategorien zusammen mit den vorherigen Ergebnissen auf Ebene aller Tätigkeitskategorien enthalten. Die Angabe des Likelihood Ratio Tests im Vergleich zum Vormodell sowie dem Log-Likelihood entfällt, da den einzelnen Spalten unterschiedliche Daten zugrunde liegen und dadurch eine sinnvolle Interpretation der Kennzahlen nicht möglich ist. Die Stichprobe der Kategorie „Websites, IT & Software“ ist mit 14.598 Angeboten die größte, gefolgt von „Design, Media & Architecture“ mit 6.624 Angeboten und „Writing & Content“ mit 5.603 Angeboten. Den Ergebnissen liegen entsprechend 1.115, 448 und 380 Aufträge zugrunde.

Der Likelihood Ratio Test zum Nullmodell ist in allen Tätigkeitsbereichen hochsignifikant, was auf eine bessere Anpassungsgüte der Modelle zu den Daten im Vergleich zum Nullmodell mit einer Konstanten hindeutet. Im Vergleich zum Gesamtmodell zeigen sich innerhalb der Tätigkeitskategorien sowohl hinsichtlich der Höhe und dem Vorzeichen der Koeffizienten als auch hinsichtlich der Signifikanzniveaus Unterschiede.

Die Geschlechtskoeffizienten zeigen über die Tätigkeitskategorien hinweg heterogene Zusammenhänge zur Beauftragungswahrscheinlichkeit. Im Bereich „Websites, IT & Software“, einem männertypischen Tätigkeitsbereich, liegt die Beauftragungschance von Frauen 3,1 Prozent ($\exp(0,030) - 1$) über denen von vergleichbaren männlichen Freelancern. In der geschlechtsneutralen Tätigkeitskategorie „Design, Media & Architecture“ weisen weibliche Freelancer eine um 26,1 Prozent ($\exp(0,232) - 1$) höhere Beauftragungschance auf. Im als frauentypisch geltenden Tätigkeitsbereich „Writing & Content“ reduziert sich die Beauftragungschance von Frauen im Vergleich zu Männern um 29,4 Prozent ($\exp(-0,349) - 1$). Auch, wenn die Effekte von ihrer Größe bedeutend sind, sind sämtliche

Koeffizienten statistisch nicht signifikant, weshalb sich ebenso über die Tätigkeitskategorien kein Zusammenhang zwischen dem Geschlecht und der Beauftragungswahrscheinlichkeit nachweisen lässt. Demnach zeigt sich keine Evidenz für die Stützung der Hypothese H4.

H4	Weibliche und männliche Freelancer weisen unterschiedliche Beauftragungswahrscheinlichkeiten in geschlechtstypischen Tätigkeitskategorien auf.	x
----	--	----------

Tabelle 20: Ergebnisse der bedingten logistischen Regression zur Analyse der Beauftragungswahrscheinlichkeit – Tätigkeitskategorien

Modell 8 - Tätigkeitskategorien Abhängige Variable: Beauftrag (Dummy)	Gesamt	Websites, IT & Software	Design, Media & Architecture	Writing & Content
Zentrale unabhängige Variablen				
<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	-0,038 (0,101)	0,030 (0,166)	0,232 (0,225)	-0,349 (0,221)
<i>Rang (1-21)</i>	-0,079 *** (0,008)	-0,074 *** (0,012)	-0,086 *** (0,019)	-0,102 *** (0,022)
<i>Geschlecht x Rang</i>	0,009 (0,010)	-0,005 (0,017)	-0,019 (0,021)	0,059 *** (0,022)
Kontrollvariablen				
Bidlist	✓	✓	✓	✓
Performance	✓	✓	✓	✓
Weitere plattformgenerierte Variablen	✓	✓	✓	✓
Externe Variablen	✓	✓	✓	✓
Anzahl an Angeboten	31.316	14.598	6.624	5.603
Anzahl an Aufträgen	2.274	1.115	448	380
Anzahl beauftragter Frauen	502	165	119	141
Likelihood Ratio Test (zum Nullmodell)	706,0 ***	307,8 ***	179,8 ***	186,2 ***

Angegeben sind die jeweiligen Regressionskoeffizienten der bedingten logistischen Regression.
 Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Die hohe Bedeutung des Rangs für die Beauftragungswahrscheinlichkeit zeigt sich auch über die Tätigkeitskategorien hinweg. Es lässt sich wie im Gesamtmodell ein hochsignifikanter negativer Zusammenhang feststellen. Die Einflusshöhe des Rangs schwankt dabei zwischen den Tätigkeitskategorien und den Geschlechtern. In der männertypischen Tätigkeitskategorie „Websites, IT & Software“ geht eine Verbesserung des Rangs um eine Position für männliche Freelancer mit einer Verbesserung der Beauftragungschance in Höhe von 7,1 Prozent ($\exp(-0,074) - 1$) einher. Für weibliche Freelancer hingegen steigt die Beauftragungschance um 7,6 Prozent ($\exp(-0,074 - 0,005) - 1$), wobei der Unterschied zu den Männern statistisch nicht signifikant ist.

Bei Aufträgen der geschlechterneutralen Kategorie „Design, Media & Architecture“ steigt die Beauftragungschance durch eine Verbesserung des Rangs um eine Position bei männlichen Freelancern um 8,2 Prozent ($\exp(-0,086) - 1$) und bei weiblichen Freelancern um 9,9 Prozent ($\exp(-0,086 - 0,019) - 1$). Frauen profitieren in dieser Kategorie damit um 1,7 Prozentpunkte mehr von einem besseren Rang als Männer. Dieser Unterschied ist jedoch ebenfalls nicht statistisch signifikant.

In der als frauentypisch eingestuften Tätigkeitskategorie „Writing & Content“ lassen sich signifikante Geschlechterunterschiede im Hinblick auf die Rangvariable feststellen. Durch die Verbesserung des Rangs um eine Position steigt die Beauftragungschance für männliche Freelancer um 9,7 Prozent ($\exp(-0,102) - 1$). Weibliche Freelancer hingegen profitieren mit einem Anstieg der Beauftragungschance um 4,3 Prozent ($\exp(-0,102 + 0,059) - 1$) signifikant weniger von einer Rangverbesserung.

Auch auf Ebene der Tätigkeitskategorien zeigt sich, dass der Rang auf die Beauftragungswahrscheinlichkeit von Freelancer:innen einen großen Einfluss nimmt. Bei männertypischen und geschlechterneutralen Tätigkeitsbereichen ist der Rangeffekt für weibliche und männliche Freelancer gleich. Im frauentypischen Tätigkeitsbereich zeigt sich, dass die Beauftragungschance von Frauen 5,4 Prozentpunkte weniger bei einer Rangverbesserung steigt als bei Männern. Auftraggebende in dieser Tätigkeitskategorie bewerten demnach die Ranginformation von Frauen und Männern unterschiedlich. Auf Basis der Auswertung lässt sich damit Evidenz für die Hypothese H8 finden.

H8	Der Effekt eines besseren Rangs auf die Beauftragungswahrscheinlichkeit ist für weibliche und männliche Freelancer in geschlechtstypischen Tätigkeitskategorien unterschiedlich.	✓
----	--	---

Zusammenfassend wäre zu erwarten gewesen, sofern Auftraggebende Stereotype in ihrer Beauftragungsentscheidung berücksichtigen, dass Frauen in frauentypischen Tätigkeitskategorien und Männer in männertypischen Tätigkeitskategorien höhere Beauftragungswahrscheinlichkeiten aufweisen. Die Analyse konnte jedoch in Bezug auf den Geschlechtereinfluss keine signifikanten Effekte messen, welche diese These stützen. Im Gegenteil: Von der Wirkungsrichtung her deuten die Koeffizienten auf deutlich geringere

Beauftragungschancen für Frauen in der frauentypischen Tätigkeitskategorie und leicht höheren Beauftragungschancen von Frauen in männertypischen Tätigkeitskategorien hin. Jedoch sind diese Ergebnisse aufgrund der fehlenden statistischen Signifikanz mit Vorsicht zu betrachten, weshalb von keinem Zusammenhang ausgegangen werden muss.

Weibliche Freelancer werden demnach zwar bei der Beauftragung nicht benachteiligt, es zeigt sich aber, dass der Einfluss des Rangs auf die Beauftragungschance für weibliche Freelancer im frauentypischen Tätigkeitsfeld „Writing & Content“ geringer ist als für männliche. Für Auftraggebende scheint in dieser Tätigkeitskategorie der Rang eines weiblichen Freelancers für die Beauftragungsentscheidung weniger eine Rolle zu spielen als der Rang eines männlichen Freelancers. Dies lässt sich insofern mit stereotypbehaftetem Entscheidungsverhalten vereinbaren, dass Auftraggebende weiblichen Freelancern in der frauentypischen Tätigkeitskategorie grundsätzlich bessere Fähigkeiten zuschreiben und daher ein besserer Rang weniger informativ ist als ein besserer Rang von vergleichbaren männlichen Freelancern.

Diesem möglichen Beauftragungsverhalten entgegensteht, dass Frauen durchschnittlich schlechtere Ränge aufweisen als Männer. Es wäre zu erwarten gewesen, sofern weibliche Freelancer tatsächlich auch bessere Arbeitsergebnisse erbringen, dass sie durchschnittlich auch bessere Ränge aufweisen. Bei den beobachtbaren Kontrollvariablen von weiblichen und männlichen Freelancern zeigen sich für die Tätigkeitskategorie jedoch keine bedeutenden Unterschiede, die den schlechteren Rang erklären könnten (vgl. Anhang Tabelle 11). Daher bleiben nur die internen Daten der Plattform und der Rankingalgorithmus selbst als Erklärung für den schlechteren Rang. Damit zeigt sich für die Plattform, dass das Stereotyp von besseren Arbeitsergebnissen eines weiblichen Freelancers im Vergleich zu einem männlichen in einer frauentypischen Tätigkeitskategorie auf der Plattform nicht korrekt ist und Auftraggebende nicht stereotypgeleitet beauftragen.

5.3 Analyse der Geschlechterunterschiede in den Angebotspreisen

Neben Unterschieden in der Beauftragungswahrscheinlichkeit hat die deskriptive Analyse gezeigt, dass sich auch signifikante Unterschiede in den Angebotspreisen von weiblichen und männlichen Freelancern feststellen lassen. Ziel dieses

Abschnittes ist es, den Geschlechterunterschied in den Angebotspreisen ökonometrisch zu untersuchen und unter Berücksichtigung der Kontrollvariablen zu quantifizieren. Hierzu werden Fixed Effect Regressionen sowohl unter Einbezug aller Tätigkeitskategorien als auch einzeln für die drei geschlechertypischen Kategorien geschätzt (vgl. Abschnitt 4.3.2).

5.3.1 Zu prüfende Hypothesen und Hinweise zur Bewertung der Modellergebnisse

Die in diesem Abschnitt zu prüfenden Hypothesen sind in Tabelle 21 dargestellt. Hypothese H2 zielt dabei auf den Koeffizienten der Geschlechtsvariable α ab und soll zunächst auf Ebene aller Tätigkeitskategorien prüfen, ob die deskriptiv gefundenen Unterschiede in den Angebotspreisen, auch unter Einbezug der Kontrollvariablen, bestehen bleiben. Die Hypothese H5 bezieht sich auf die Berechnung auf Ebene der Tätigkeitskategorien.

Wie im Abschnitt zuvor werden die Fixed Effect Modelle auf Ebene aller Tätigkeitskategorien aufbauend geschätzt, um zu zeigen, wie und ob sich die Geschlechtervariable und die Gütemaße durch Einbezug von weiteren Kontrollvariablen verändern. Dies gibt zudem einen Eindruck über die Robustheit des geschätzten Zusammenhangs. Wie im vorherigen Modell können in einem Fixed Effect Modell ebenfalls keine Effekte für auftragsspezifische und für die Freelancer:innen konstante Variablen berechnet werden. Das Modell berechnet für jeden Auftrag eigene Konstanten (γ_i), die der Übersichtlichkeit halber nicht in den Regressionsergebnissen gezeigt werden.

Tabelle 21: Übersicht über die Hypothesen zu den Angebotspreisen

Nr.	Hypothese
H2	Der Angebotspreis von Freelancer:innen unterscheidet sich nach dem Geschlecht.
H5	Weibliche und männliche Freelancer verlangen unterschiedliche Angebotspreise in geschlechtstypischen Tätigkeitskategorien.

Quelle: Eigene Darstellung.

In Tabelle 22 und Tabelle 23 sind die Regressionsergebnisse dargestellt. Darin finden sich Angaben zu den Regressionskoeffizienten, den Standardfehlern und den jeweiligen Signifikanzniveaus. Der Angebotspreis als abhängige Variable fließt

logarithmiert ins Modell ein, d. h. es weist eine sog. log-level oder auch semilog-Spezifikation auf (Greene 2012:200). Eine Änderung der unabhängigen Variable um eine Einheit entspricht damit einer $100 * \text{Koeffizient}$ Prozentänderung in der abhängigen Variable.

Auf Ebene aller Tätigkeitskategorien werden insgesamt fünf verschiedene Modelle geschätzt. Das erste Modell berücksichtigt darin lediglich die Geschlechtsvariable und keine weiteren Kontrollvariablen. Alle darauffolgenden Modelle bauen sich Schritt für Schritt hinsichtlich der verschiedenen Kontrollvariablen auf. Die in den vorherigen Abschnitten genutzte Rangvariable wird in diesem Modell als Kontrollvariable verwendet und unter den Kontrollvariablen der Bidlist subsumiert. Auf eine Interaktionsvariable mit dem Geschlecht wird verzichtet, da es unplausibel erscheint, dass weibliche oder männliche Freelancer im Bewusstsein ihres eigenen Rangs, in der jeweiligen Bidlist Angebotspreise unterschiedlich setzen.

Zur Bewertung der Güte des Modells werden sowohl der Anteil der erklärten Varianz insgesamt (R^2 Overall) als auch der Anteil der erklärten Varianz innerhalb der Aufträge (R^2 Within) angegeben. Ein höheres R^2 deutet dabei auf eine bessere Anpassungsgüte des Modells an die Daten hin. Weiter wird zur Bewertung der Modellspezifikation die Teststatistik und das Signifikanzniveau eines F-Tests angegeben, der die Gesamtsignifikanz des Modells testet. Der Übersichtlichkeit halber werden die Koeffizienten und Standardfehler der Kontrollvariablen in den folgenden Tabellen nicht gezeigt. Eine ausführliche Übersicht findet sich im Anhang Tabelle 17 für die Ebene aller Tätigkeitskategorien und im Anhang Tabelle 18 für die einzelnen Tätigkeitskategorien.

5.3.2 Analyse über alle Tätigkeitskategorien

Analog zu Abschnitt 5.2.2 werden zunächst die Fixed Effect Modelle auf Ebene aller 16 Tätigkeitskategorien berechnet. Entsprechend umfasst der zugrunde gelegte Datensatz 31.316 Angebote, die auf 2.274 Aufträge entfallen und von 10.194 Freelancer:innen stammen. Die Geschlechterverteilung liegt bei 1.772 Beobachtungen für Männer und 502 Beobachtungen für Frauen.

In Tabelle 22 werden die einzelnen Ergebnisse der Fixed Effect Modelle dargestellt. Sämtliche F-Tests zur Prüfung der Gesamtsignifikanz des Modells sind hochsignifikant. Die Nullhypothese, dass sämtliche inkludierte Variablen keinen

Einfluss auf die Angebotspreise nehmen, kann damit in allen Modellen verworfen werden. Der Anteil der erklärten Varianz innerhalb der Aufträge liegt zwischen 0,0 im ersten und 11,2 Prozent im fünften Modell. Der Anstieg des R^2 zwischen dem vierten und fünften Modell ist am geringsten. Dies zeigt analog zum vorherigen Modell, dass die plattformexternen Variablen keine große Rolle in der Erklärung der Varianz der Angebotspreise spielen.

Die Koeffizienten der Geschlechtsvariable sind in Modell eins bis drei signifikant und negativ. Weibliche Freelancer:innen verlangen signifikant geringere Angebotspreise als männliche Freelancer:innen. Im ersten Modell liegt dieser Unterschied bei 2,3 Prozent. Durch die Hinzunahme von Kontrollvariablen aus der Bidlist (inkl. dem Rang) und die Berücksichtigung von Performanceunterschieden sinkt dieser Zusammenhang auf 1,4 Prozent. Nachdem noch weitere Kontrollvariablen aus den Profilen der Freelancer:innen hinzugenommen werden, wird der Geschlechterkoeffizient insignifikant. Dies impliziert, dass sich auf Ebene aller Tätigkeitskategorien – unter Einbezug sämtlicher Unterschiede in den Charakteristika der Freelancer:innen – keine signifikante Geschlechterdifferenz in den Angebotspreisen finden lässt. Anders ausgedrückt, unterscheiden sich die Angebotspreise zwischen zwei identischen Freelancer:innen mit gleichem Rang in der Bidlist, die sich lediglich in der Geschlechtszugehörigkeit unterscheiden, auf der Plattform nicht. Es lassen sich also keine Hinweise auf Selbstdiskriminierung der Freelancer:innen auf Ebene aller Tätigkeitskategorien finden. Hypothese H2 lässt sich demnach nicht bestätigen.

H2	Der Angebotspreis von Freelancer:innen unterscheidet sich nach dem Geschlecht.	x
----	--	---

Tabelle 22: Ergebnisse der Fixed Effect Regression zur Analyse der Angebotspreise

Abhängige Variable: log(Angebotspreis (in 100 EUR))	1	2	3	4	5
Zentrale unabhängige Variable					
<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	-0,023 *** (0,007)	-0,016 ** (0,007)	-0,014 ** (0,007)	0,008 (0,006)	0,008 (0,006)
Konstante	-0,669 *** (0,002)	-0,664 *** (0,038)	-0,682 *** (0,041)	-0,842 *** (0,038)	-0,846 *** (0,038)
Kontrollvariablen					
Bidlist		✓	✓	✓	✓
Performance			✓	✓	✓
Weitere plattformgenerierte Variablen				✓	✓
Externe Variablen					✓
Anzahl an Angeboten	31.316	31.316	31.316	31.316	31.316
Anzahl an Aufträgen	2.274	2.274	2.274	2.274	2.274
R ² Overall	0,000	0,080	0,081	0,083	0,083
R ² Within	0,000	0,092	0,095	0,111	0,112
F-Test Overall	11,8 ***	367,7 ***	253,0 ***	201,4 ***	153,1 ***

Angegeben sind die jeweiligen Regressionskoeffizienten der Fixed Effect Regression mit cluster robusten Standardfehlern.
 Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Dadurch, dass sich auf Ebene aller Tätigkeitskategorien keine Geschlechtsdiskriminierung bei der Beauftragung feststellen lässt (vgl. Abschnitt 5.2.2), ist das Ergebnis keiner Geschlechtsdifferenz bei den Angebotspreisen schlüssig und unterstützt das in Abschnitt 3.3.1 angeführte Argument. Demnach müssen Frauen auf der Plattform keine Bedenken haben, gegeben gleicher Charakteristika weniger häufig beauftragt zu werden. Deshalb entfällt der Anreiz, über niedrigere Preise die Benachteiligung bei der Beauftragung zu kompensieren.

5.3.3 Analyse auf Ebene der Tätigkeitskategorien

In der bisherigen Forschung finden sich Hinweise darauf, dass sich die Preisunterschiede zwischen den Geschlechtern vorrangig in geschlechtstypischen Tätigkeitskategorien zeigen (vgl. Abschnitt 2.3.2). Ob sich dies auch auf der hier untersuchten Plattform feststellen lässt, wird durch die einzelne Analyse der Tätigkeitskategorien untersucht. Hierzu wird das fünfte Modell auf Ebene der einzelnen Tätigkeitskategorien geschätzt.

Die Ergebnisse sind in Tabelle 23 dargestellt. Die Stichprobengrößen entsprechen mit 14.598 Angeboten in der Kategorie „Websites, IT & Software“, mit 6.624 Angeboten in der Kategorie „Design, Media & Architecture“ und mit 5.603 Angeboten aus dem Bereich „Writing & Content“ denen aus Abschnitt 5.2.3.

Entsprechend liegen den Ergebnissen jeweils 1.115, 448 und 380 Aufträge zugrunde.

Der F-Test zur Gesamtsignifikanz ist in allen Modellen hochsignifikant, d. h. das Modell hat eine bessere Anpassungsgüte als das Nullmodell mit nur einer Konstanten. Der Anteil der erklärten Varianz innerhalb der Aufträge schwankt zwischen den Tätigkeitskategorien von 7,8 Prozent im Bereich „Websites, IT & Software“, über 18,4 Prozent im Bereich „Writing & Content“ bis zu 26,1 Prozent im Bereich „Design, Media & Architecture“.

Tabelle 23: Ergebnisse der Fixed Effect Regression zur Analyse der Angebotspreise – Tätigkeitskategorien

Modell 5 - Tätigkeitskategorien Abhängige Variable: log(Angebotspreis (in 100 EUR))	Gesamt	Websites, IT & Software	Design, Media & Architecture	Writing & Content
Zentrale unabhängige Variable				
<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	0,008 (0,006)	0,027 *** (0,009)	0,049 *** (0,013)	-0,029 ** (0,014)
Konstante	-0,846 *** (0,038)	-0,678 *** (0,042)	-1,193 *** (0,086)	-1,134 *** (0,073)
Kontrollvariablen				
Bidlist	✓	✓	✓	✓
Performance	✓	✓	✓	✓
Weitere plattformgenerierte Variablen	✓	✓	✓	✓
Externe Variablen	✓	✓	✓	✓
Anzahl an Angeboten	31.316	14.598	6.624	5.603
Anzahl an Aufträgen	2.274	1.115	448	380
R ² Overall	0,083	0,063	0,192	0,107
R ² Within	0,112	0,078	0,261	0,184
F-Test Overall	153,1 ***	47,4 ***	90,7 ***	48,7 ***

Angegeben sind die jeweiligen Regressionskoeffizienten der Fixed Effect Regression mit cluster robusten Standardfehlern.
 Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Im Vergleich zum Gesamtmodell zeigen sich innerhalb der Tätigkeitskategorien sowohl hinsichtlich der Höhe und Vorzeichen der Koeffizienten als auch hinsichtlich der Signifikanzniveaus Unterschiede. Bei Aufträgen aus der Kategorie „Websites, IT & Software“, einem männertypischen Tätigkeitsbereich, verlangen weibliche Freelancer 2,7 Prozent höhere Angebotspreise als vergleichbare männliche Freelancer. Für die geschlechtsneutrale Tätigkeitskategorie „Design, Media & Architecture“ liegt dieser Unterschied bei 4,9 Prozent und in der Kategorie „Writing & Content“, einem frauentypischen Tätigkeitsbereich, verlangen weibliche Freelancer 2,9 Prozent weniger als vergleichbare männliche Freelancer. Dieser Unterschied besteht trotz des Einbezugs sämtlicher Kontrollvariablen. Daher lässt sich im Einklang mit der Hypothese H5 schlussfolgern, dass sich

Geschlechterunterschiede in den Angebotspreisen auf der Plattform feststellen lassen und diese sich zwischen den Tätigkeitskategorien unterscheiden.

H5	<i>Weibliche und männliche Freelancer verlangen unterschiedliche Angebotspreise in geschlechtstypischen Tätigkeitskategorien.</i>	✓
----	---	---

Da sich hinsichtlich der Beauftragungswahrscheinlichkeit auch auf Ebene der Tätigkeitskategorien keine signifikanten Geschlechterunterschiede feststellen lassen, wäre analog zur Ebene aller Tätigkeitskategorien zu erwarten gewesen, dass sich auch keine Unterschiede in den Angebotspreisen zeigen.

Trotzdem finden sich nicht unerhebliche Preisdifferenzen, deren Richtung jedoch konträr zum Argument der Nutzung von Stereotypen durch die Auftraggebenden ist. Sofern stereotypbehaftetes Beauftragungsverhalten auftreten würde und Freelancer:innen dieses antizipieren, wäre zu erwarten, dass weibliche Freelancer in männertypischen Tätigkeitskategorien mit niedrigeren Angebotspreisen versuchen an Aufträge zu kommen und gleichzeitig in frauentypischen Tätigkeitskategorien, allein aufgrund der Geschlechtszugehörigkeit, höhere Preise durchsetzen können. Konträr dazu zeigt sich auf dieser Plattform, dass weibliche Freelancer in männertypischen Tätigkeitskategorien höhere Preise verlangen als vergleichbare männliche Freelancer und in frauentypischen Tätigkeitskategorien niedrigere Preise. Auf Basis dieser Analyse kann damit zusammenfassend festgehalten werden, dass der Unterschied in den durchschnittlichen Angebotspreisen von weiblichen und männlichen Freelancern nicht im Einklang mit der Nutzung von Stereotypen durch die Auftraggebenden steht.

5.4 Kritische Würdigung der Ergebnisse

Durch die explizite Betrachtung der Rolle von Stereotypen in Beauftragung und Preissetzung, der Generierung weiterer empirischer Evidenz über einen einzigartigen Datensatz einer weltweit aktiven Plattform und der erstmaligen Berücksichtigung konkreter plattformspezifischer Mechanismen in Form der Ränge in der Analyse, trägt die vorangegangene Untersuchung wesentlich zur Schließung der aufgedeckten Forschungslücke bei (vgl. Abschnitt 2.4).

Bisher war es noch nicht möglich, allgemeingültige Aussagen bzgl. der Geschlechterdiskriminierung auf Freelancing-Marktplätzen zu treffen. Die

vorliegende Analyse hat über die Ableitung der Hypothesen aus der Theorie der Stereotype und ihrer anschließenden Überprüfung zur Ursachenforschung von Geschlechterdiskriminierung auf Freelancing-Marktplätzen beigetragen. Der eigens dafür erhobene Datensatz einer der weltweit größten Freelancing-Marktplätze hat weitere empirische Evidenz geschaffen und dabei einen Detailgrad erreicht, der sämtliche auf der Plattform öffentlich beobachtbare Kennzahlen der Freelancer:innen und der Aufträge umfasst, den bisher nur wenige Studien in diesem Umfang erreicht haben. Ein Alleinstellungsmerkmal der Analyse ist der explizite Einbezug der Rangvariable als unabhängige und Kontrollvariable und damit die Berücksichtigung möglicher Verzerrungen in der Beauftragung oder den Angebotspreisen durch den Rankingalgorithmus der Plattform.

Natürlich weisen die angewendeten Methoden auch Limitationen auf, auf die hingewiesen werden muss. Zuallererst ist hierunter die fehlende Repräsentativität des Datensatzes zu nennen, der keine Verallgemeinerung oder Übertragung der gefundenen Effekte auf andere Plattformkategorien oder Plattformen zulässt. Die Ergebnisse sind daher nur im Kontext der untersuchten Plattform valide. Dies liegt maßgeblich an den großen Unterschieden zwischen den Plattformen, die sich z. B. hinsichtlich der Weboberfläche, dem Vermittlungsmechanismus zwischen Auftraggebenden und Freelancer:innen, den verfügbaren Informationen über die Akteur:innen und dem Vorhandensein von Algorithmen zur Marktsteuerung unterscheiden.

Wie in Abschnitt 2.1.4 gezeigt wird, ist die Erwerbstätigenstruktur in der Plattformökonomie im Allgemeinen nicht vergleichbar mit der Gesamtbevölkerung. Selektionseffekte können zu anderen Ergebnissen für die Plattformökonomie im Vergleich zum klassischen Arbeitsmarkt führen, weshalb Vergleiche mit Ergebnissen des klassischen Arbeitsmarkts, wenn überhaupt, nur eingeschränkt möglich sind. Diese Einschränkungen sind nicht spezifisch für die vorliegende Analyse, alle anderen Studien in der Plattformökonomie müssen aus denselben Gründen ebenfalls mit einer eingeschränkten Übertragbarkeit ihrer Ergebnisse umgehen. Umso wichtiger ist es, genügend verschiedene Plattformen zu untersuchen, um ggf. Gemeinsamkeiten und Unterschiede herauszuarbeiten und Zusammenhänge zu verstehen. Dazu hat diese Arbeit wesentlich beigetragen.

Durch die Berücksichtigung von Fixed Effects auf Auftragsebene in beiden Modellen können mögliche Endogenitätsprobleme, die z. B. durch unbeobachtete Auftragscharakteristika verursacht werden, auf Ebene der Aufträge adressiert werden. Auf Ebene der Freelancer:innen wird durch den Einbezug einer Vielzahl von Kontrollvariablen in beiden Modellen das Risiko einer Verzerrung der Schätzung durch fehlende relevante Variablen maximal möglich minimiert. Trotzdem kann nicht vollständig ausgeschlossen werden, dass andere unbeobachtete Variablen, die mit den inkludierten unabhängigen Variablen korrelieren, Endogenitätsprobleme verursachen könnten. Ein klassisches Beispiel aus der Literatur sind Unterschiede in der angeborenen Fähigkeit (im Englischen ability) von Individuen, die z. B. Einfluss auf Bildungsentscheidungen oder die Performance eines:r Freelancer:in nehmen kann und unbeobachtet bleibt. Um mit dem Problem des ability bias umgehen zu können, werden in der Literatur quasi-experimentelle Ansätze (z. B. Propensity Score Matching) genutzt (z. B. Chan und Wang 2018; Foong et al. 2018). Aufgrund der im Vergleich zu den anderen Studien geringeren Stichprobengröße ist eine Durchführung eines quasi-experimentellen Forschungsansatzes nicht möglich. Damit kann die Analyse eine Indikation geben, ob die gefundenen Effekte im Einklang mit den Vorhersagen der Theorie der Stereotype stehen (Korrelation), aber keinen kausalen Zusammenhang ableiten. Weitere methodische Limitationen bei der Geschlechtsbestimmung, der Operationalisierung der Variablen und den beiden Modellen, können den jeweiligen Abschnitten im Methodikkapitel entnommen werden (vgl. Kapitel 4).

Neben den methodischen Limitationen besteht auch eine weitere Limitation in der Authentizität der Freelancer:innen. Die Plattform versucht über die Verifikationsschritte, welche die Freelancer:innen durchlaufen können, sicherzustellen, dass die im Profil angegebene Freelancer:in auch tatsächlich existiert und die gemachten Angaben der Realität entsprechen. Es wäre dennoch denkbar, dass z. B. weibliche Freelancer sich als männliche Freelancer ausgeben, um einer vermuteten Diskriminierung zu entgehen oder dass sich mehrere Freelancer:innen unterschiedlicher Geschlechter einen Account teilen. Eine solche Strategie würde die gefundenen Geschlechtereffekte unterwandern. Ob ein solches Verhalten in relevanten Maßstäben auftritt, ist bislang nicht untersucht worden. Die in dieser Analyse untersuchte Form von Diskriminierung, die von den

Auftraggebenden ausgeht, dürfte davon jedoch nicht sonderlich beeinflusst werden, da die Auftraggebenden ebenfalls das wahre Geschlecht nicht identifizieren können und von dem durch Name und Foto suggerierten Geschlecht ausgehen müssen. Team-Accounts, die ganz offensichtlich von mehreren Freelancer:innen betrieben werden, werden in der Analyse nicht berücksichtigt, da diese in der Regel sowohl keinen typischen Klarnamen als auch kein Foto mit Personen in den Profilen hinterlegen und dadurch keine Geschlechtsidentifikation möglich ist.

Abschließend kann festgehalten werden, dass das gewählte Vorgehen trotz der angeführten Limitationen einen wesentlichen Beitrag zur Diskriminierungsforschung in der Plattformökonomie geleistet hat.

6 Fazit

In diesem Kapitel werden die Ergebnisse der vorangegangenen Analyse im Hinblick auf die Beantwortung der Forschungsfragen zusammengefasst und ein Ausblick auf künftigen weiteren Forschungsbedarf gegeben. Hierauf aufbauend identifiziert der zweite Abschnitt Handlungsfelder für die Akteur:innen der Plattformökonomie und staatlicher Institutionen.

6.1 Zusammenfassung und Ausblick

Das Ziel der Dissertation ist es zu prüfen, ob Geschlechterdiskriminierung in der Plattformökonomie auftritt und welche Gründe sich hierfür identifizieren lassen. Ein Überblick über die bisherige Literatur hat gezeigt, dass eine Übertragung von Geschlechterstereotypen des klassischen Arbeitsmarkts auf die Plattformökonomie plausibel erscheint. Um hypothesenbasiert zu prüfen, ob dies tatsächlich auch der Fall ist und welche Effekte hieraus für die Beauftragungswahrscheinlichkeit und Preissetzung resultieren, wird als theoretische Grundlage die Diskriminierungstheorie der Stereotype herangezogen. Zur Auswahl eines geeigneten Untersuchungsgegenstandes werden die Annahmen der Theorie betrachtet und jene Plattform ausgewählt, auf die diese möglichst gut zutreffen. Die Analyse wird auf Basis einer Plattform namens *freelancer.com* durchgeführt, die zu den größten weltweit aktiven Freelancing-Marktplätzen gehört. Diese Plattform passt nicht nur gut zu den Annahmen, sondern bietet auch eine Vielzahl von Informationen und ermöglicht erstmalig auch die Bereinigung der Geschlechtereffekte um den Einfluss eines Algorithmus. Hieraus ergab sich die folgende Forschungsfrage:

Welche Rolle spielen Geschlechterstereotype für die Beauftragungsentscheidung von Auftraggebern und die Preissetzung von Auftragnehmern unter Berücksichtigung des Einflusses eines Algorithmus?

Zur Beantwortung der Forschungsfrage werden theoriegeleitet acht Hypothesen gebildet, die auf Basis des selbst erhobenen Datensatzes geprüft werden. Mithilfe eines eigens programmierten Web-Scrapers werden Daten der Plattform *freelancer.com* über einen längeren Zeitraum gesammelt. Der Datensatz umfasst

Auftragsinformationen, Details zu den abgegebenen Angeboten sowie detaillierte Profilinformationen der Freelancer:innen. Die beiden zentralen unabhängigen Variablen der Analysen sind das Geschlecht und der Rang der Freelancer:innen in der Angebotsliste (Bidlist). Angaben zum Geschlecht der Freelancer:innen sind auf der Plattform nicht direkt verfügbar. Daher wird zur Geschlechtsbestimmung auf die Profildaten und Klarnamen der Freelancer:innen zurückgegriffen, welche unter anderem über Verfahren des maschinellen Lernens klassifiziert werden. Zur empirischen Beantwortung der Forschungsfrage werden zwei Modelle geschätzt. Die Beauftragungswahrscheinlichkeit wird mithilfe eines bedingten logistischen Regressionsmodells untersucht und die Analyse der Angebotspreise erfolgt durch eine Fixed Effect Regression.

Die Hauptfragestellung lässt sich in zwei Teile gliedern. Erstens, ob sich Hinweise für die Nutzung von Stereotypen in der Beauftragungsentscheidung der Auftraggebenden auf der Plattform finden lassen und inwiefern diese einen Einfluss auf die Preissetzung nehmen. Zweitens, inwiefern der Rankingalgorithmus Einfluss auf die Beauftragungsentscheidung nehmen kann und dadurch Stereotypen entgegenwirkt oder gar Stereotype auf der Plattform verfestigt. Zum ersten Teil werden die folgenden beiden Unterfragen gebildet, die es zunächst zu beantworten gilt:

- 1. Welche Rolle spielen Geschlechterstereotype in der Beauftragungsentscheidung von Auftraggebenden?*
- 2. Welchen Einfluss haben Geschlechterstereotype auf die Angebotspreise der Auftragnehmenden?*

Zunächst gilt zu klären, ob sich auf der Plattform *freelancer.com* unterschiedliche Beauftragungswahrscheinlichkeiten zwischen weiblichen und männlichen Freelancern messen lassen. Die Ergebnisse der bedingten logistischen Regression zeigen keine signifikanten Geschlechterunterschiede in der Beauftragungswahrscheinlichkeit auf Ebene aller Tätigkeitskategorien. Es kann demnach keine Evidenz für die **Hypothese H1** gefunden werden.

Da sich keine Unterschiede in der Beauftragungswahrscheinlichkeit finden lassen, ist gemäß der Theorie der Stereotype auch von keinem Unterschied bei den Angebotspreisen auszugehen. Die Analyse der Angebotspreise auf Ebene aller

Tätigkeitskategorien bestätigt diese Vorhersage. Unter Einbezug aller Kontrollvariablen zeigt sich kein signifikanter Unterschied in den Angebotspreisen zwischen weiblichen und männlichen Freelancern. Dementsprechend findet sich auch keine Evidenz für die **Hypothese H2**.

In der bisherigen Forschung hat sich gezeigt, dass sich Geschlechterunterschiede bei der Beauftragungswahrscheinlichkeit und den Angebotspreisen vorwiegend innerhalb von Tätigkeitskategorien zeigen. Auch für die vorliegende Plattform ist denkbar, dass sich die Effekte aufgrund der Verteilung der Aufträge über die 16 Tätigkeitskategorien auf Ebene aller aufheben und sich daher weder Evidenz für Geschlechterunterschiede bei der Beauftragungswahrscheinlichkeit noch bei den Angebotspreisen finden lässt.

Die Aufträge auf der Plattform konzentrieren sich auf einige wenige Tätigkeitskategorien. Über 85 Prozent der vermittelten Aufträge entfallen auf die Bereiche „Websites, IT & Software“, „Design, Media & Architecture“ sowie „Writing & Content“. Innerhalb der Tätigkeitskategorien zeigen sich unterschiedliche Geschlechteranteile, die im Einklang mit typischen Geschlechterstereotypen des klassischen Arbeitsmarkts stehen und die **Hypothese H3** bestätigen. Im Vergleich zum gesamten Datensatz sind weibliche Freelancer:innen in der Kategorie „Websites, IT & Software“ unterrepräsentiert und in der Kategorie „Writing & Content“ überrepräsentiert. Dementsprechend werden die beiden Modelle jeweils getrennt für die drei häufigsten Tätigkeitskategorien geschätzt. Wobei „Websites, IT & Software“ als männertypisch, „Design, Media & Architecture“ als neutral und „Writing & Content“ als frauentypische Tätigkeitskategorien in Übereinstimmung mit der Literatur definiert werden.

Sofern Auftraggebende anhand von Stereotypen beauftragen, wäre gemäß der Theorie auf Ebene der Tätigkeitskategorien ein zu den Kategorien passendes geschlechtsspezifisches Muster in der Beauftragungswahrscheinlichkeit zu erwarten. In der männertypischen Tätigkeitskategorie „Websites, IT & Software“ müsste sich eine geringere Beauftragungswahrscheinlichkeit für weibliche Freelancer, für die als frauentypisch geltende Tätigkeitskategorie „Writing & Content“ eine höhere Beauftragungswahrscheinlichkeit für weibliche Freelancer und für die geschlechtsneutral definierte Tätigkeitskategorie „Design, Media &

Architecture“ keine Unterschiede zwischen den Geschlechtern feststellen lassen. Die Analyse auf Tätigkeitsebene zeigt jedoch für keine der drei Tätigkeitskategorien signifikante Geschlechterunterschiede in der Beauftragungswahrscheinlichkeit, weshalb keine Evidenz für die **Hypothese H4** gefunden werden kann.

Bei gleich hoher Beauftragungswahrscheinlichkeit für die Geschlechter in den Tätigkeitskategorien, sind ebenfalls keine Unterschiede in den Angebotspreisen innerhalb der Tätigkeitskategorien zu erwarten. Die Analyse hat jedoch, auch nach Einbezug aller Kontrollvariablen, signifikante Unterschiede in den Angebotspreisen zwischen weiblichen und männlichen Freelancern festgestellt. Weibliche Freelancer weisen in der männertypischen Tätigkeitskategorie „Websites, IT & Software“ einen um 2,7 Prozent höheren Angebotspreis auf als vergleichbare männliche Freelancer. In der als geschlechtsneutral definierten Tätigkeitskategorie beträgt diese Differenz 4,9 Prozent und in der frauentypischen Tätigkeitskategorie „Writing & Content“ weisen weibliche Freelancer um 2,9 Prozent geringere Angebotspreise auf. Dies bestätigt die **Hypothese H5**.

Durch die fünf untersuchten Hypothesen lassen sich die zuvor aufgestellten Unterfragestellungen beantworten. Die Ergebnisse lassen die Schlussfolgerung zu, dass sich keine Evidenz finden lässt, die auf die Nutzung von Stereotypen in der Beauftragungsentscheidung hindeutet (**Unterfrage eins**). In der bisherigen Forschung wird beobachtet, dass das für die Tätigkeitskategorie atypische Geschlecht geringere Preise setzt, um die eigene Beauftragungswahrscheinlichkeit zu erhöhen. Dies ist auf der vorliegenden Plattform nicht nötig, da keine Unterschiede bei den Beauftragungswahrscheinlichkeiten zwischen den Geschlechtern vorherrschen. Es lassen sich zwar Preisdifferenzen feststellen, diese sind jedoch in ihrer Richtung nicht mit der Theorie der Stereotype erklärbar, weshalb geschlussfolgert wird, dass Stereotype keinen Einfluss auf die Angebotspreise der Auftragnehmenden haben (**Unterfrage zwei**).

Dass keine Unterschiede in der Beauftragungswahrscheinlichkeit gefunden wurden, bedeutet in Bezug auf das Modell von Arrow (1971:25 ff.) und Coate und Loury (1993:1223 ff.) entweder, dass Auftraggebende keine abweichenden Vorvermutungen zwischen weiblichen und männlichen Freelancern haben oder deren Vorvermutungen durch die von der Plattform bereitgestellten Informationen

derart beeinflusst werden, dass sich die initialen Unterschiede in den Vorvermutungen zwischen den Geschlechtern angleichen und das Geschlecht für den Auftraggebenden letztlich keine Rolle mehr spielt. Demnach zeigt sich, dass die Transparenz der Informationen über die Freelancer:innen auf den Plattformen die Übertragung von Stereotypen des klassischen Arbeitsmarkts auf die Plattformökonomie verhindern oder abschwächen kann.

In Bezug auf die Angebotspreise ist zu beachten, dass diese unter Berücksichtigung sämtlicher Kontrollvariablen und der Fixed Effects auf Auftragsebene messbar bleiben. D. h. Freelancer:innen, die sich auf den gleichen Auftrag bewerben, die gleichen beobachtbaren Charakteristika aufweisen und sich lediglich im Geschlecht unterscheiden, verlangen unterschiedliche Angebotspreise in Abhängigkeit der Tätigkeitskategorie. Die Theorie der Stereotype bietet dafür keine Erklärung. Auffällig ist, dass weibliche und männliche Freelancer in der jeweiligen geschlechtsatypischen Tätigkeitskategorie höhere Löhne verlangen als in der geschlechtstypischen Tätigkeitskategorie, was konträr zu den Vorhersagen der Theorie der Stereotype ist. Ein denkbarer Grund könnte in einem höheren gleichgeschlechtlichen Wettbewerb in geschlechtstypischen Tätigkeitskategorien liegen, der sich negativ auf den Angebotspreis auswirkt und von dem das andere Geschlecht profitieren kann. Offen bleibt aber dann, warum in einem solchen Fall überhaupt noch Freelancer:innen des atypischen Geschlechts beauftragt werden, wenn diese vergleichbar sind, aber höhere Angebotspreise verlangen. Ein weiterer denkbarer Grund könnte darin liegen, dass die Angebotsabgabe von geschlechtsatypischen Freelancer:innen ein derart bedeutendes Signal der Leistungsfähigkeit ist, dass sie höhere Angebotspreise verlangen können, obwohl sie objektiv betrachtet in allen Variablen vergleichbar zu geschlechtstypischen Freelancer:innen sind und der Wert des Signals in Form höhere Angebotspreise monetarisiert werden kann. Inwiefern diese Gründe zutreffen können, sollte Gegenstand künftiger Untersuchungen sein.

Neben dem Geschlecht als zentrale unabhängige Variable wird auch die Rolle des Rangs in der Angebotsliste für die Beauftragungswahrscheinlichkeit betrachtet und dessen Einfluss quantifiziert. Der Rang eines:r Freelancer:in resultiert unmittelbar aus dem Rankingalgorithmus der Plattform. Durch die Quantifizierung des Einflusses auf die Beauftragungswahrscheinlichkeit ist es damit möglich, indirekt

den Einfluss des Algorithmus zu messen und zu prüfen, ob sich in diesem Geschlechterunterschiede feststellen lassen. Hierzu werden die folgenden beiden Unterfragen gebildet, die durch die Untersuchung von drei weiteren Hypothesen beantwortet werden:

3. *Welche Rolle spielt das Ranking bei der Beauftragungsentscheidung?*
4. *Welchen Einfluss nimmt das Ranking auf den Geschlechtsunterschied in der Beauftragungswahrscheinlichkeit?*

Dass der Rang der Freelancer:innen in der Auftragsliste für die Beauftragungswahrscheinlichkeit relevant ist, überrascht zunächst nicht. Wenn ein:e Freelancer:in sich auf Position eins befindet, signalisiert die Plattform dem Auftraggebenden, dass der:die Freelancer:in besser für den Auftrag geeignet ist als ein:e Freelancer:in die sich bspw. auf Position zehn befindet. Dementsprechend ist zu erwarten, dass Auftraggebende Freelancer:innen mit besseren Rängen eher beauftragen. Für den Rang entscheidend, ist der jeweilige skillspezifische Score der Freelancer:innen, der durch den Rankingalgorithmus berechnet wird. Bei der Scoreberechnung fließen Faktoren wie Bewertungen, die Qualität des Profils oder das Reaktionsvermögen der Freelancer:innen ein, aber auch die Nutzung von plattformeigenen Tools (z. B. die Desktop-App) werden positiv honoriert. Der Rankingalgorithmus fördert damit besonders aktive Freelancer:innen und führt zu einer sich selbst verstärkenden Spirale, in der diese Freelancer:innen noch einfacher an Aufträge kommen. Freelancer:innen, die nur gelegentlich auf der Plattform oder der Tätigkeitskategorie aktiv sind, haben es damit ungleich schwerer überhaupt Aufträge zu erhalten. Daher ist es wichtig zu untersuchen, welche Bedeutung der Rang für die Beauftragung hat, ob sich Geschlechterunterschiede in den Rängen zeigen und ob der Rankingalgorithmus womöglich zum Bestehen dieser Unterschiede beiträgt. Dazu werden die Ränge zunächst deskriptiv untersucht und anschließend deren Einfluss auf die Beauftragungschance quantifiziert.

Da die Freelancer:innen sowohl auf Ebene aller als auch innerhalb der Tätigkeitskategorien im Durchschnitt kaum Unterschiede in den für den Rankingalgorithmus relevanten Variablen aufweisen, wäre anhand dessen zu erwarten gewesen, dass weibliche und männliche Freelancer ähnliche

durchschnittliche Ränge erhalten. Für weibliche Freelancer können hingegen sowohl auf Ebene aller als auch innerhalb der Tätigkeitskategorien durchschnittlich signifikant schlechtere Ränge nachgewiesen werden. Dies ist konträr zu den laut der **Hypothese H6** erwartbaren geschlechtsspezifischen Mustern in den Tätigkeitskategorien und kann als weiteres Indiz gegen die Nutzung von Stereotypen gewertet werden. Da die Rangunterschiede sich nicht mit Unterschieden in den beobachtbaren und für den Rankingalgorithmus relevanten Variablen erklären lassen, bleibt lediglich die Schlussfolgerung, dass entweder weibliche Freelancer bei den anderen nichtbeobachtbaren Variablen schlechter abschneiden als männliche Freelancer oder der Rankingalgorithmus, abweichend zu den Angaben der Plattform, das Geschlecht berücksichtigt. Die genaue Untersuchung der Funktionsweise des Algorithmus geht über den Umfang dieser Arbeit hinaus und sollte daher Gegenstand künftiger Forschung sein.

Ob ein schlechterer Rang die Beauftragungswahrscheinlichkeit reduziert, wird mithilfe des bedingten logistischen Regressionsmodells überprüft. Es zeigt sich auf Ebene aller Tätigkeitskategorien ein erwartungsgemäß hochsignifikanter Zusammenhang zwischen dem Rang und der Beauftragungswahrscheinlichkeit. Der Anstieg der Beauftragungschance bei einer Verbesserung des Rangs um eine Position liegt bei fast sieben Prozent. Dementsprechend lässt sich empirische Evidenz für die **Hypothese H7** finden.

Im Kontext der Theorie der Stereotype ist der Rang als ein Produktivitätssignal anzusehen. Unter der Annahme, dass Auftraggebende geschlechtstypische Freelancer:innen in Tätigkeitskategorien für besser geeignet halten, kann das Produktivitätssignal die Vorvermutungen der Auftraggebenden über die geringere Eignung geschlechtsatypischer Freelancer:innen nur dann genug beeinflussen, sodass es trotzdem zu einer Beauftragung kommt, wenn der Rang hinreichend besser ist als von geschlechtstypischen Freelancer:innen. Dies impliziert, dass der Effekt des Rangs auf die Beauftragungswahrscheinlichkeit für das atypische Geschlecht der Tätigkeitskategorie geringer sein sollte als für das typische Geschlecht.

Da jedoch bisher keine Hinweise auf die Nutzung von Stereotypen in der Beauftragung der Freelancer:innen gefunden werden können, ist, gemäß der

Theorie, kein geschlechtsspezifischer Einfluss des Rangs auf die Beauftragungswahrscheinlichkeit zu erwarten. Zur Prüfung dieser These wird die Analyse auf Ebene der Tätigkeitskategorien fortgesetzt.

Für die Tätigkeitskategorien „Websites, IT & Software“ sowie „Design, Media & Architecture“ trifft die Vermutung zu, dass keine signifikant unterschiedlichen Rangeffekte zwischen weiblichen und männlichen Freelancern auftreten. Dem gegenüber steht das Ergebnis für die frauentypische Tätigkeitskategorie „Writing & Content“, für die signifikante Geschlechterunterschiede in den Rangeffekten berechnet werden. Für weibliche Freelancer erhöht sich die Beauftragungschance durch eine Rangverbesserung um eine Position um 4,3 Prozent, wohingegen männliche Freelancer von einer Erhöhung um 9,7 Prozent profitieren. Ein Unterschied von 55 Prozent oder 5,4 Prozentpunkten, der zumindest teilweise Evidenz für die **Hypothese H8** liefert. Für Auftraggebende in der frauentypischen Tätigkeitskategorie scheint der Rang eines weiblichen Freelancers für die Beauftragungsentscheidung weniger eine Rolle zu spielen als der Rang eines männlichen Freelancers. Anders ausgedrückt müssen weibliche Freelancer einen mehr als doppelt so hohen Rang aufweisen als vergleichbare männliche Freelancer, um die gleiche Beauftragungswahrscheinlichkeit zu erhalten. Dieses Ergebnis ist überraschend und konträr zur Vorhersage der Theorie.

Die Analyse kann in Bezug auf die Rangvariable zwei Erkenntnisse hervorbringen. Der Rang eines:r Freelancer:in ist für die Beauftragung entscheidend (**Unterfrage drei**) und es lassen sich unterschiedliche Rangeffekte anhand des Geschlechts feststellen (**Unterfrage vier**). Für eine frauentypische Tätigkeitskategorie kann festgestellt werden, dass der Rang von weiblichen Freelancern weniger von Bedeutung für die Beauftragungswahrscheinlichkeit ist als für männliche Freelancer. Anders ausgedrückt profitieren weibliche Freelancer in dieser Kategorie weniger von einer Rangverbesserung als männliche Freelancer. Dies kommt einer Benachteiligung von weiblichen Freelancern gleich. Sie müssen im Vergleich zu männlichen Freelancern einen doppelt so hohen Rang erreichen, um eine vergleichbare Beauftragungswahrscheinlichkeit zu erhalten. Wichtig zu beachten ist, dass diese Diskriminierung von den Auftraggebenden ausgeht, die den Rang von weiblichen Freelancern für weniger informativ halten und nicht vom Algorithmus oder der Plattform. Dennoch zeigt es auch, dass das zentrale Element zur

Steuerung der Beauftragung von Freelancer:innen nicht geschlechtsneutral bewertet wird und zu einem Geschlechtsunterschied in der Beauftragungswahrscheinlichkeit beiträgt.

Zusammenfassend hat die vorliegende Analyse gezeigt, dass sich zwar auch auf der Plattform *freelancer.com* eine zum klassischen Arbeitsmarkt ähnliche Geschlechtersegregation in Tätigkeitskategorien einstellt, ein Beauftragungsverhalten entlang von Stereotypen sich aber nicht feststellen lässt und daher auch das Preissetzungsverhalten der Auftragnehmenden hiervon nicht beeinflusst wird. Entgegen den Hypothesen scheinen Geschlechterstereotype auf der Plattform damit keine Rolle zu spielen. Im Gegenteil, die Plattform schafft es, dass sich Stereotype vom klassischen Arbeitsmarkt nicht auf die Plattform übertragen.

Weiterhin hat die vorliegende Arbeit einen Beitrag dazu geleistet, zu bemessen, welche Rolle von Algorithmen gesteuerten Elementen in der Beauftragung zukommt. Es hat sich gezeigt, dass der Rankingalgorithmus für die Beauftragungsentscheidung der Auftraggebenden wichtige Informationen zur Bewertung der Freelancer:innen bereitstellt und diese von Auftraggebenden in Abhängigkeit der Tätigkeitskategorie und des Geschlechts unterschiedlich bewertet werden, was zu Geschlechterungleichheiten führen kann.

Für künftige Forschungsprojekte ergeben sich, auf Basis der in dieser Arbeit erzielten Ergebnisse, weitere Anknüpfungspunkte. So könnte dem Grund für die fehlende Übertragung von Stereotypen auf die Plattform nachgegangen werden. Es wird die These aufgestellt, dass dies mit den Informationsvorteilen auf der Plattform gegenüber dem klassischen Arbeitsmarkt einhergeht, welche die Auftraggebenden befähigt, die wahre Leistungsfähigkeit der Freelancer:innen zu erkennen. Ob dies tatsächlich zutrifft, könnte bspw. durch einen experimentellen Forschungsansatz geprüft werden. Hierzu wäre jedoch vermutlich eine enge Zusammenarbeit mit der Plattform nötig.

Die in dieser Arbeit aufgedeckten und zur Theorie der Stereotype konträren Preisdifferenzen zwischen weiblichen und männlichen Freelancern sollten in künftigen Untersuchungen genauer betrachtet werden. Dabei bilden die beiden aufgestellten Thesen, dass dies auf höheren gleichgeschlechtlichen Wettbewerb in

geschlechtstypischen Tätigkeitskategorien zurückgeht oder die Partizipation geschlechtsatypischer Freelancer:innen als Produktivitätssignal gewertet wird, geeignete Ausgangspunkte.

Überdies wirft der für Tätigkeitskategorien geschlechtstypische Freelancer:innen niedrigere Rangeffekt offene Fragen auf und bietet einen Anknüpfungspunkt für künftige Forschungsvorhaben. Die unterschiedliche Bewertung des Rangs als Produktivitätssignal in Abhängigkeit des Geschlechts ließe sich auf den ersten Blick eher mit der Screening Discrimination Theorie von Phelps (1972) vereinbaren. Diese nutzt Ungenauigkeiten bei der Messbarkeit der Produktivitätssignale von Personen, um Preisdifferenzen vorherzusagen. Dem entgegen steht jedoch, dass gemäß dieser Theorie, die Preisdifferenzen eher zum Vorteil der geschlechtstypischen Freelancer:innen ausfallen müssten und nicht den geschlechtsatypischen Freelancer:innen, wie es auf der vorliegenden Plattform der Fall ist. Künftige Forschung sollte daher genauer untersuchen, was die möglichen Gründe sein könnten, dass die Ranginformation in Abhängigkeit des Geschlechts unterschiedlich bewertet wird.

Die vorliegende Analyse kann zeigen, dass dem Rankingalgorithmus eine große Bedeutung für die Beauftragungsentscheidung zukommt. Es bleibt jedoch unklar, ob die durchschnittlich geringeren Ränge weiblicher Freelancer tatsächlich auf schlechtere interne Kennzahlen zurückgehen oder der Rankingalgorithmus weibliche Freelancer benachteiligt. Zum besseren Verständnis könnten daher in einem nächsten Schritt Simulationen mit eigens angelegten Profilen von Freelancer:innen genutzt werden, um über die hier gefundenen Korrelationen hinaus Zusammenhänge des Rangs mit anderen Charakteristika der Freelancer:innen abzuleiten. Um jedoch die vollständige Funktion des Rankingalgorithmus zu untersuchen, wäre eine enge Zusammenarbeit mit der Plattform und ein vollständiger Datenzugriff nötig.

6.2 Sozialpolitische Implikationen

Die vorliegende Analyse hat für die Plattform *freelancer.com* gezeigt, dass keine Geschlechterdiskriminierung von den Auftraggebenden bei der Beauftragung ausgeht. In Bezug auf diese mögliche Art der Diskriminierung bietet die Plattform,

im Vergleich zum klassischen Arbeitsmarkt, Frauen damit die Chance, gleichberechtigt erwerbstätig zu sein.

Im Vergleich zur bisherigen Literatur ist dies ein überraschendes Ergebnis, das mutmaßlich auf die spezifische Ausgestaltung der Plattform *freelancer.com* zurückzuführen ist. Denn die Plattform stellt dem Auftraggebenden nicht nur viele Informationen über die Freelancer:innen zur Verfügung und ermöglicht so eine stereotypfreie Beauftragung, sondern bietet über die öffentliche Darstellung der Wettbewerbssituation in der Angebotsliste auch eine höhere Transparenz im Angebotsprozess im Vergleich zu anderen Plattformen.

Das Ergebnis dieser Analyse ist gerade auch im Kontext der Debatte um die Vereinbarkeit von Sorgearbeit und Beruf relevant. Plattformarbeit bietet für Personengruppen, für die eine Partizipation am klassischen Arbeitsmarkt durch Sorgeverpflichtungen erschwert ist, aufgrund höherer Zeit- und Raumsouveränität, eine Chance zur Erwerbspartizipation. Hiervon könnten vorrangig Frauen profitieren, die nach wie vor einen Großteil der Sorgearbeit übernehmen (Gender-Care-Gap) (Lott et al. 2022:33 ff.). Damit bietet die Plattformarbeit die Chance, die Erwerbspartizipation von Frauen zu erhöhen. Sozialpolitisch sollte dies aufgegriffen und Aufklärungsarbeit zu Beschäftigungsmöglichkeiten und -modellen geleistet werden, um die Sichtbarkeit dieser Erwerbsform zu erhöhen. Gleichzeitig dürfen dabei aber auch Risiken, die aus der fehlenden sozialen Absicherung bei dieser Erwerbsform resultieren, nicht übersehen werden.

Zu beachten bleibt, dass von der Chance zur Erwerbspartizipation jedoch nicht sämtliche weibliche Erwerbspersonen profitieren können, sondern lediglich jene, die auch Zugang zur Plattformökonomie haben. Die Analyse hat gezeigt, dass nur wenige spezifische Tätigkeitskategorien auf der Plattform größtmäßig relevant sind. Demnach sind bei Weitem nicht alle Berufe und Tätigkeitsfelder über die Plattform ausübbar. Die horizontale Segregation und der geringere Digitalisierungsgrad von Frauen (Digital-Gender-Gap) haben zur Folge, dass sie weniger an der Plattformökonomie teilhaben können (Initiative D21 e.V. 2020). Die Herstellung gleicher Teilhabemöglichkeiten für Frauen und Männern stellt ein zentrales sozialpolitisches Handlungsfeld dar.

Weiter hat die Analyse gezeigt, dass der Rankingalgorithmus der Plattform für die Beauftragung eine wichtige Rolle spielt und gleichzeitig für die Freelancer:innen hinsichtlich seiner genauen Funktion weitestgehend eine Blackbox ist, die sie selbst nicht beeinflussen können. Auf der Plattform werden auch weitere Algorithmen eingesetzt, deren Funktionsweise gänzlich unbekannt ist (z. B. zur Generierung von Auftragsvorschlägen). Auch wenn sich keine Diskriminierung in der Beauftragungswahrscheinlichkeit messen lässt, ist auffällig, dass weibliche Freelancer auf der Plattform durchschnittlich geringere Ränge aufweisen und sich hierfür keine eindeutige Erklärung findet. Ob und wie solche Algorithmen zu Geschlechterungleichheiten führen können, kann letztlich nur über eine Offenlegung der Funktionsweise und der genutzten Inputdaten geprüft werden. Dazu hat bereits der dritte Gleichstellungsbericht der Bundesregierung umfangreiche Handlungsempfehlungen formuliert. Es wird vorgeschlagen, dass Plattformen eine Datenschutz Folgenabschätzung (nach Art. 35 Abs. 4 Datenschutz-Grundverordnung (DSGVO)) hinsichtlich der Diskriminierungsrisiken solcher Algorithmen erstellen müssen. Zusätzlich sollen sie verpflichtet werden, über den Einsatz algorithmischer Systeme zu informieren und deren Funktionsweisen offenzulegen (Art. 15 DSGVO). Sofern sie dies nicht möchten, sollen sie die Beweislast tragen, dass der Algorithmus nicht diskriminiert. Weiter wird gefordert, dass Daten wie das Geschlecht unter besonderen Schutz im Sinne des Art. 9 DSGVO gestellt werden sollen. All diese Maßnahmen können Plattformbetreibende dafür sensibilisieren, Diskriminierungsquellen zu identifizieren und mögliche daraus resultierende Probleme ernst zu nehmen (Bundesregierung 2021:68 f.).

Neben den Chancen zeigen sich auch Risiken, die mit einer intensiven Arbeit über die Plattform einhergehen. Ein Risiko besteht in der fehlenden Übertragbarkeit der auf der Plattform gesammelten Arbeitserfahrung zwischen den Plattformen. Die Bewertungsmechanismen auf der Plattform führen zu sogenannten Lock-In Effekten, welche die Freelancer:innen an die Plattform binden, wodurch eine hohe Abhängigkeit entsteht (Ciotti et al. 2021). Da es vorkommen kann, dass Plattformen Profile ohne Vorwarnung sperren, Freelancer:innen downgraden oder nicht genügend Aufträge auf der Plattform zur Verfügung stehen, macht es für Freelancer:innen prinzipiell Sinn, auf mehreren Plattformen aktiv zu sein. Jedoch

wird diese Form der Diversifikation durch die Lock-In Effekte und die damit entstehenden hohen Wechselkosten stark erschwert (vgl. Abschnitt 2.1.4.7). Der dritte Gleichstellungsbericht fordert daher folgerichtig ein Recht auf Datenportabilität im Sinne des Art. 20 DSGVO, das Plattformen zumindest verpflichtet, Auskunft über die gesammelte Reputation zu geben (Bundesregierung 2021:69 f.). Weiter wäre eine Verpflichtung zur Annahme plattformfremder Reputation ebenfalls wünschenswert.

Plattformarbeit kann insbesondere für bestimmte Lebensphasen, in der z. B. eine höhere Flexibilität nötig ist, eine Alternative zum klassischen Arbeitsmarkt darstellen. Jedoch kann der Rückweg zum klassischen Arbeitsmarkt, bspw. in eine sozialversicherungspflichtige Beschäftigung, aufgrund der zuvor erwähnten fehlende Portabilität der Arbeitserfahrung erschwert sein. Hieraus kann sich eine generelle Lock-In Gefahr für die Plattformökonomie ergeben. Dies ist im Hinblick auf fehlende soziale Sicherungssysteme (aufgrund des Status als Selbstständige) problematisch und kann zur Verschärfung der jetzt schon bestehenden Geschlechterunterschiede in Bezahlung (Gender-Pay-Gap), Lebenseinkommen (Gender-Lifetime-Earnings-Gap) oder Rentenansprüchen (Gender-Pension-Gap) resultieren. Daher sollten auch Möglichkeiten geschaffen werden, die eine bessere Anerkennung der auf der Plattform gesammelten Arbeitserfahrung auf dem klassischen Arbeitsmarkt ermöglicht. Das geforderte Auskunftsrecht ist dafür ein guter Anfang. Das Ziel sollte eine gleichwertige Anerkennung der Plattformerfahrungen zur Arbeitserfahrung auf dem klassischen Arbeitsmarkt sein.

Mit dem Digital Service Act (DSA), der am 16.11.2022 in Kraft getreten ist und ab dem 17.02.2024 in allen Mitgliedsstaaten der Europäischen Union gilt, geht die Europäische Kommission einen wichtigen Schritt zur Regulierung der Onlinemärkte in der Europäischen Union (Europäische Kommission 2022). Unter anderem verpflichtet dieser Plattformen die Funktionsweise der Bewertungssysteme und der Algorithmen offenzulegen. Abzuwarten bleibt, wie genau diese Offenlegung aussehen wird und ob dies Plattformen dazu treibt, ihre internen Prozesse genauer, bspw. auf mögliche Diskriminierung, zu prüfen. Im Kontext der Diskriminierungsforschung oder auch für andere Fragestellungen eröffnen sich

dadurch ganz neue Forschungsmöglichkeiten. Sehr große Plattformen⁷⁹ sind verpflichtet, eine erste Risikobewertung im Juni 2023 zu veröffentlichen – kleineren Plattformen, zu der auch *freelancer.com* zählt, wird mehr Zeit eingeräumt.

Die vorliegende Analyse hat einen wichtigen Beitrag zur Erforschung der Plattformökonomie im Allgemeinen und der Freelancing-Marktplätze im Speziellen geliefert. Es kann auch gezeigt werden, dass die Plattformökonomie weiterhin viel Potenzial für weitere Forschung bietet. Um mögliche, bisher unentdeckte Probleme und Fehlentwicklungen erfassen und sozialpolitisch gegensteuern zu können, ist es daher wichtig, dass auch die Datenverfügbarkeit vonseiten der Statistikämter erhöht wird, bei denen die Plattformökonomie bisher nicht separat ausgewiesen wird. Entsprechende Projekte, wie diese überhaupt erfasst werden kann, sollten daher ausgebaut werden. Neben dem amtlichen Zugang sollten Stakeholder aus Politik, Wirtschaft und Wissenschaft Anstrengungen unternehmen, die Plattformen zur Zusammenarbeit im Sinne der Wissenschaft zu bewegen, um so an detailliertere Daten zu kommen, aus denen sich neue Erkenntnisse gewinnen lassen.

⁷⁹ Die Schwelle liegt hier bei sehr großen Plattformen und Suchmaschinen, die monatlich mindestens 45 Millionen aktive EU-Nutzende haben. Dies entspricht ungefähr zehn Prozent der Gesamtbevölkerung der EU.

Literatur

- Abendroth, Anja-Kristin. 2021. „The Gender Pay Gap in the Platform Economy: Comparing the Importance of Market and Organisational Dynamics on Two German Crowdfunding Platforms“. *Gender a Výzkum / Gender and Research* 21(2):59–84. doi: 10.13060/gav.2020.011.
- Admin. 2013. „Tips for Requesters on Mechanical Turk: The Reasons Why Amazon Mechanical Turk No Longer Accepts International Turkers“. Abgerufen 9. Mai 2022 (<https://turkrequesters.blogspot.com/2013/01/the-reasons-why-amazon-mechanical-turk.html>).
- Agrawal, Ajay, John Horton, Nicola Lacetera, und Elizabeth Lyons. 2015. „Digitization and the Contract Labor Market: A Research Agenda“. S. 219–50 in *Economic Analysis of the Digital Economy*, herausgegeben von A. Goldfarb, S. M. Greenstein, und C. E. Tucker. Chicago, London: The University of Chicago Press.
- Agrawal, Ajay, Nicola Lacetera, und Elizabeth Lyons. 2016. „Does Standardized Information in Online Markets Disproportionately Benefit Job Applicants from Less Developed Countries?“ *Journal of International Economics* 103:1–12. doi: 10.1016/j.jinteco.2016.08.003.
- Ahrne, Göran, Patrik Aspers, und Nils Brunsson. 2015. „The Organization of Markets“. *Organization Studies* 36(1):7–27. doi: 10.1177/0170840614544557.
- Ahuja, Rishi, und Ronan C. Lyons. 2019. „The Silent Treatment: Discrimination against Same-Sex Relations in the Sharing Economy“. *Oxford Economic Papers* 71(3):564–76. doi: 10.1093/oep/gpz025.
- Aigner, Dennis J., und Glen G. Cain. 1977. „Statistical Theories of Discrimination in Labor Markets“. *Industrial and Labor Relations Review* 30(2):175–87. doi: 10.2307/2522871.
- Al-Ani, Ayad, und Stefan Stumpp. 2015. *Motivationen Und Durchsetzung von Interessen Auf Kommerziellen Plattformen. Ergebnisse Einer Umfrage Unter Kreativ- Und IT-Crowdworkern. Discussion Paper*. 2699065. Rochester: Social Science Research Network.
- Aleksynska, Mariya, Anastasia Bastrakova, und Natalia Kharchenko. 2018. *Work on Digital Labour Platforms in Ukraine: Issues and Policy Perspectives*. Genf: International Labour Organisation.
- Alpaydin, Ethem. 2022. *Maschinelles Lernen*. 3. Aufl. Berlin: Walter de Gruyter.
- Altonji, Joseph G. 2005. „Employer Learning, Statistical Discrimination and Occupational Attainment“. *American Economic Review* 95(2):112–17. doi: 10.1257/000282805774670455.
- Altonji, Joseph G., und Rebecca M. Blank. 1999. „Chapter 48: Race and Gender in the Labor Market“. S. 3143–3259 in *Handbook of Labor Economics*. Bd. 3, herausgegeben von O. C. Ashenfelter und D. Card. Amsterdam [u. a.]: Elsevier/North-Holland.

- Altonji, Joseph G., und Charles R. Pierret. 2001. „Employer Learning and Statistical Discrimination“. *The Quarterly Journal of Economics* 116(1):313–50. doi: 10.1162/003355301556329.
- Arrow, Kenneth J. 1971. *The Theory of Discrimination. Working Paper*. 30A. Princeton: Princeton University.
- Arrow, Kenneth J. 1972a. „Models of Job Discrimination“. S. 83–102 in *Racial Discrimination in Economic Life*, herausgegeben von A. H. Pascal. o. O.: Lexington Books.
- Arrow, Kenneth J. 1972b. „Some Mathematical Models of Race Discrimination in the Labor Market“. S. 187–204 in *Racial Discrimination in Economic Life*, herausgegeben von A. H. Pascal. o. O.: Lexington Books.
- Arrow, Kenneth J. 1998. „What Has Economics to Say About Racial Discrimination?“ *Journal of Economic Perspectives* 12(2):91–100. doi: 10.1257/jep.12.2.91.
- Aserebrenik. 2022. „GitHub - Tue-Mdse/GenderComputer: Tool That Tries to Guess Persons’s Gender Based on Their Name and Location“. Abgerufen 26. Oktober 2022 (<https://github.com/tue-mdse/genderComputer>).
- Auer, Benjamin, und Horst Rottmann. 2020. *Statistik und Ökonometrie für Wirtschaftswissenschaftler: Eine anwendungsorientierte Einführung*. 4. Aufl. Wiesbaden: Springer Fachmedien.
- Autor, David H. 2001. „Wiring the Labor Market“. *Journal of Economic Perspectives* 15(1):25–40. doi: 10.1257/jep.15.1.25.
- Ayalew, Shibiru, Shanthi Manian, und Ketki Sheth. 2021. „Discrimination From Below: Experimental Evidence on Female Leadership in Ethiopia“. *Journal of Development Economics* 151:102653. doi: 10.1016/j.jdeveco.2021.102653.
- Baethge, Catherine B., Michael Boberach, Anke Hoffmann, und Ole Wintermann. 2019. *Plattformarbeit in Deutschland: Freie und flexible Arbeit ohne soziale Sicherheit*. Gütersloh: Bertelsmann Stiftung.
- Baird, Chardie L. 2012. „Going Against the Flow: A Longitudinal Study of the Effects of Cognitive Skills and Gender Beliefs on Occupational Aspirations and Outcomes“. *Sociological Forum* 27(4):986–1009. doi: 10.1111/j.1573-7861.2012.01365.x.
- Bar, Revital, und Asaf Zussman. 2017. „Customer Discrimination: Evidence from Israel“. *Journal of Labor Economics* 35(4):1031–59. doi: 10.1086/692510.
- Bartoš, Vojtěch, Michal Bauer, Julie Chytilová, und Filip Matějka. 2016. „Attention Discrimination: Theory and Field Experiments with Monitoring Information Acquisition“. *American Economic Review* 106(6):1437–75. doi: 10.1257/aer.20140571.
- Barzilay, Arianne Renan, und Anat Ben-David. 2017. „Platform Inequality: Gender in the Gig-Economy“. *Seton Hall Law Review* 47(2):393–431. doi: 10.2139/ssrn.2995906.

- Bauer, Robert M., und Thomas Gegenhuber. 2015. „Crowdsourcing: Global Search and the Twisted Roles of Consumers and Producers“. *Organization* 22(5):661–81. doi: 10.1177/1350508415585030.
- Beblo, Miriam, Anja Heinze, und Elke Wolf. 2008. „Entwicklung der beruflichen Segregation von Männern und Frauen zwischen 1996 und 2005: Eine Bestandsaufnahme auf betrieblicher Ebene“. *Journal for Labour Market Research* 41(2/3):181–98.
- Becker, Gary S. 1971. *The Economics of Discrimination*. 2. Aufl. Chicago: University of Chicago Press.
- Berg, Janine. 2016. „Income Security in the On-Demand Economy: Findings and Policy Lessons from a Survey of Crowdworkers“. *Comparative Labor Law & Policy Journal* 37(3):543–70.
- Bertrand, Marianne, Dolly Chugh, und Sendhil Mullainathan. 2005. „Implicit Discrimination“. *American Economic Review* 95(2):94–98. doi: 10.1257/000282805774670365.
- Bertrand, Marianne, und Esther Duflo. 2017. „Chapter 8 - Field Experiments on Discrimination“. S. 309–93 in *Handbook of Economic Field Experiments*. Bd. 1, herausgegeben von A. V. Banerjee und E. Duflo. Amsterdam/Oxford: Elsevier/North-Holland.
- Bertschek, Irene, Jörg Ohnemus, und Steffen Viète. 2016. *Befragung zum sozioökonomischen Hintergrund und zu den Motiven von Crowdworkern: Endbericht. Forschungsbericht*. 462. Berlin: Bundesministerium für Arbeit und Soziales (BMAS).
- Black, Dan A. 1995. „Discrimination in an Equilibrium Search Model“. *Journal of Labor Economics* 13(2):309–34. doi: 10.1086/298376.
- Blau, Francine D., und Lawrence M. Kahn. 2017. „The Gender Wage Gap: Extent, Trends, and Explanations“. *Journal of Economic Literature* 55(3):789–865. doi: 10.1257/jel.20160995.
- Boes, Andreas, Tobias Kämpf, Barbara Langes, und Thomas Lühr. 2015. „Landnahme im Informationsraum. Neukonstituierung gesellschaftlicher Arbeit in der ‚digitalen Gesellschaft‘“. *WSI-Mitteilungen* 68(2):77–85. doi: 10.5771/0342-300X-2015-2-77.
- Bohren, J. Aislinn, Alex Imas, und Michael Rosenberg. 2019. „The Dynamics of Discrimination: Theory and Evidence“. *American Economic Review* 109(10):3395–3436. doi: 10.1257/aer.20171829.
- Bonin, Holger, und Ulf Rinne. 2017. *Omnibusbefragung zur Verbesserung der Datenlage neuer Beschäftigungsformen. IZA Research Report*. 80. Bonn: Institute for the Study of Labor (IZA).
- Booth, Alison, und Andrew Leigh. 2010. „Do Employers Discriminate by Gender? A Field Experiment in Female-Dominated Occupations“. *Economics Letters* 107(2):236–38. doi: 10.1016/j.econlet.2010.01.034.
- Bordalo, Pedro, Katherine Coffman, Nicola Gennaioli, und Andrei Shleifer. 2016. „Stereotypes“. *The Quarterly Journal of Economics* 131(4):1753–94. doi: 10.1093/qje/qjw029.

- Borjas, George J. 2015. *Labor Economics*. 7. Aufl. New York: McGraw-Hill Higher Education.
- Borjas, George J., und Stephen G. Bronars. 1989. „Consumer Discrimination and Self-Employment“. *The Journal of Political Economy* 97(3):581–605. doi: 10.1086/261617.
- Boulanger, Jean-Edouard. 2021. „quickforex 0.1.3: Simple foreign exchange rates retrieval API - PyPi“. Abgerufen 31. Oktober 2022 (<https://pypi.org/project/quickforex/>).
- Bowlus, Audra J., und Zvi Eckstein. 2002. „Discrimination and Skill Differences in an Equilibrium Search Model“. *International Economic Review* 43(4):1309–45. doi: 10.1111/1468-2354.t01-1-00057.
- Bühmann, Andrea D., Uwe Fachinger, und Eva M. Welskop-Deffaa, Hrsg. 2018. *Hybride Erwerbsformen*. Wiesbaden: Springer Fachmedien.
- Bundesregierung. 2021. *Digitalisierung geschlechtergerecht gestalten. Gutachten für den Dritten Gleichstellungsbericht der Bundesregierung*. Berlin: Geschäftsstelle Dritter Gleichstellungsbericht.
- Buolamwini, Joy, und Timnit Gebru. 2018. „Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification“. *Proceedings of Machine Learning Research* (81):1–15.
- Busch, Anne. 2013a. „Der Einfluss der beruflichen Geschlechtersegregation auf den ‚Gender Pay Gap‘: Zur Bedeutung geschlechtlich konnotierter Arbeitsinhalte“. *Kölner Zeitschrift für Soziologie und Sozialpsychologie* 65(2):301–38. doi: 10.1007/s11577-013-0201-1.
- Busch, Anne. 2013b. „Die berufliche Geschlechtersegregation in Deutschland: Ursachen, Reproduktion, Folgen“. Dissertation Philosophische Fakultät III, Humboldt-Universität zu Berlin, Berlin.
- van Buuren, Stef. 2018. *Flexible Imputation of Missing Data*. 2. Aufl. Boca Raton: CRC Press.
- Cain, Glen G. 1986. „Chapter 13: The Economic Analysis of Labor Market Discrimination: A Survey“. S. 693–785 in *Handbook of Labor Economics*. Bd. 1, herausgegeben von O. C. Ashenfelter und R. Layard. Amsterdam [u. a.]: Elsevier/North-Holland.
- Carlsson, Magnus. 2011. „Does Hiring Discrimination Cause Gender Segregation in the Swedish Labor Market?“ *Feminist Economics* 17(3):71–102. doi: 10.1080/13545701.2011.580700.
- Cerqua, Augusto, und Peter J. Urwin. 2018. „Unpicking the Gender Hiring Bias in Online Labor Markets“. *Academy of Management Proceedings* 2018(1):16137. doi: 10.5465/AMBPP.2018.16137abstract.
- Chan, Jason, und Jing Wang. 2018. „Hiring Preferences in Online Labor Markets: Evidence of a Female Hiring Bias“. *Management Science* 64(7):2973–94. doi: 10.1287/mnsc.2017.2756.
- Charles, Kerwin K., und Jonathan Guryan. 2011. „Studying Discrimination: Fundamental Challenges and Recent Progress“. *Annual Review of*

- Economics* 3(1):479–511. doi: 10.1146/annurev.economics.102308.124448.
- Chen, Le, Ruijun Ma, Anikó Hannák, und Christo Wilson. 2018. „Investigating the Impact of Gender on Rank in Resume Search Engines“. S. 1–14 in *CHI '18: Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems, Paper No. 651*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.
- Cheng, Simon, und J. Scott Long. 2007. „Testing for IIA in the Multinomial Logit Model“. *Sociological Methods & Research* 35(4):583–600. doi: 10.1177/0049124106292361.
- Ciotti, Fabrizio, Lars Hornuf, und Eliza Stenzhorn. 2021. *Lock-In Effects in Online Labor Markets. CESifo Workin Papers*. 9379. München: CESifo.
- Coate, Stephen, und Glenn C. Loury. 1993. „Will Affirmative-Action Policies Eliminate Negative Stereotypes?“ *American Economic Review* 83(5):1220–40.
- Codagnone, Cristiano, Fabienne Abadie, und Federico Biagi. 2016. *The Future of Work in the 'Sharing Economy'. JRC Science for Policy Report*. EUR 27913 EN. Seville: Institute for Prospective Technological Studies.
- Cohen, Adam. 2020. „fuzzywuzzy 0.18.0: Fuzzy string matching in python - PyPi“. Abgerufen 2. November 2022 (<https://pypi.org/project/fuzzywuzzy/>).
- Cohen, Jacob. 1960. „A Coefficient of Agreement for Nominal Scales“. *Educational and Psychological Measurement* 20(1):37–46. doi: 10.1177/001316446002000104.
- Collischon, Matthias, und Andreas Eberl. 2020. „Let's Talk About Fixed Effects: Let's Talk About All the Good Things and the Bad Things“. *Kölner Zeitschrift Für Soziologie Und Sozialpsychologie* 72(2):289–99. doi: 10.1007/s11577-020-00699-8.
- Combes, Pierre-Philippe, Bruno Decreuse, Morgane Laouénan, und Alain Trannoy. 2016. „Customer Discrimination and Employment Outcomes: Theory and Evidence from the French Labor Market“. *Journal of Labor Economics* 34(1):107–60. doi: <https://doi.org/10.1086/682332>.
- Cornell, Bradford, und Ivo Welch. 1996. „Culture, Information, and Screening Discrimination“. *Journal of Political Economy* 104(3):542–71. doi: <https://doi.org/10.1086/262033>.
- Correll, Shelley J. 2001. „Gender and the Career Choice Process: The Role of Biased Self-Assessments“. *American Journal of Sociology* 106(6):1691–1730. doi: 10.1086/321299.
- Cotropia, Christopher A., Jonathan S. Masur, und David L. Schwartz. 2018. *Gender Discrimination in Online Markets. University of Chicago Coase-Sandor Institute for Law & Economics Research Paper No. 864. U of Chicago, Public Law Working Paper No. 692. Northwestern Law & Econ Research Paper No. 18-24*. Rochester: Social Science Research Network.
- Cui, Ruomeng, Jun Li, und Dennis J. Zhang. 2020. „Reducing Discrimination with Reviews in the Sharing Economy: Evidence from Field Experiments on

- Airbnb“. *Management Science* 66(3):1071–94. doi: 10.1287/mnsc.2018.3273.
- Cullen, Zoe B., John E. Humphries, und Bobak Pakzad-Hurson. 2019. „Gender and Sorting in the On-Demand Economy“. in *ASSA Annual Meeting*. Atlanta.
- Däubler, Wolfgang, und Thomas Klebe. 2015. „Crowdwork: Die neue Form der Arbeit – Arbeitgeber auf der Flucht?“ *Neue Zeitschrift für Arbeitsrecht* (17):1032–41.
- Davis, Gerald F. 2015. „What Might Replace the Modern Corporation: Uberization and the Web Page Enterprise“. *Seattle University Law Review* 39(2):501–14.
- De Groen, Willem, Ilaria Maselli, und Brian Fabo. 2016. *The Digital Market for Local Services: A One-Night Stand for Workers? An Example from the On-Demand Economy*. CEPS Special Report. 133. Brüssel: Centre for European Policy Studies.
- Deng, Jiankang, Jia Guo, Evangelos Ververas, Irene Kotsia, und Stefanos Zafeiriou. 2020. „RetinaFace: Single-Shot Multi-Level Face Localisation in the Wild“. S. 5202–11 in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, herausgegeben von Institute of Electrical and Electronics Engineers. New York: IEEE/CPS.
- Deng, Jiankang, Jia Guo, Niannan Xue, und Stefanos Zafeiriou. 2019. „Arcface: Additive angular margin loss for deep face recognition“. S. 4690–99 in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, herausgegeben von Institute of Electrical and Electronics Engineers. New York: IEEE/CPS.
- Destatis. 2022. „Ein Viertel aller Erwerbstätigen arbeitete 2021 im Homeoffice“. Abgerufen 1. Dezember 2022 (https://www.destatis.de/DE/Presse/Pressemitteilungen/Zahl-der-Woche/2022/PD22_24_p002.html).
- Deutsch, Askan. 2009. „Die Zulässigkeit des so genannten" Screen-Scraping" im Bereich der Online-Flugvermittler“. *Gewerblicher Rechtsschutz und Urheberrecht (GRUR)* 111(11):1027.
- Difallah, Djellel, Elena Filatova, und Panos Ipeirotis. 2018. „Demographics and Dynamics of Mechanical Turk Workers“. S. 135–43 in *WSDM '18: Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.
- van Dijck, Jose. 2013. *The Culture of Connectivity: A Critical History of Social Media*. New York: Oxford University Press.
- Ding, Xianghua, Patrick C. Shih, und Ning Gu. 2017. „Socially Embedded Work: A Study of Wheelchair Users Performing Online Crowd Work in China“. S. 642–54 in *CSCW '17: Proceedings of the 2017 ACM Conference on Computer Supported Cooperative Work and Social Computing*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.

- Dolata, Ulrich. 2018. *Privatisierung, Kuratierung, Kommodifizierung - Kommerzielle Plattformen im Internet. SOI Discussion Paper. 2018–04.* Stuttgart: Universität Stuttgart, Institut für Sozialwissenschaften, Abteilung für Organisations- und Innovationssoziologie.
- Dube, Arindrajit, Jeff Jacobs, Suresh Naidu, und Siddharth Suri. 2020. „Monopsony in Online Labor Markets“. *American Economic Review: Insights* 2(1):33–46. doi: 10.1257/aeri.20180150.
- Dubey, Alpana, Kumar Abhinav, Mary Hamilton, und Alex Kass. 2017. „Analyzing Gender Pay Gap in Freelancing Marketplace“. S. 13–19 in *SIGMIS-CPR '17: Proceedings of the 2017 ACM SIGMIS Conference on Computers and People Research*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.
- Edelman, Benjamin, Michael Luca, und Dan Svirsky. 2017. „Racial Discrimination in the Sharing Economy: Evidence from a Field Experiment“. *American Economic Journal: Applied Economics* 9(2):1–22. doi: 10.1257/app.20160213.
- Eichhorst, Werner, Holger Hinte, Ulf Rinne, und Verena Tobsch. 2017. „How Big Is the Gig? Assessing the Preliminary Evidence on the Effects of Digitalization on the Labor Market“. *Management Revue* 28(3):298–318. doi: 10.5771/0935-9915-2017-3-298.
- Eidinger, Eran, Roe Enbar, und Tal Hassner. 2014. „Age and Gender Estimation of Unfiltered Faces“. *IEEE Transactions on Information Forensics and Security* 9(12):2170–79. doi: 10.1109/TIFS.2014.2359646.
- Erdsiek, Daniel. 2021. „Unternehmen setzen verstärkt auf Crowdworking“. *Wirtschaftsdienst* 101(11):912–14. doi: 10.1007/s10273-021-3045-8.
- Europäische Kommission. 2022. „Verordnung (EU) 2022/2065 des europäischen Parlaments und des Rates vom 19.10.2022 über einen Binnemarkt für digitale Dienste und zur Änderung der Richtlinie 2000/31/EG (Gesetz über digitale Dienste)“. *Amtsblatt der Europäischen Union* 65(L277).
- Eurostat. 2022. „Collaborative economy platforms - Experimental statistics - Eurostat“. Abgerufen 29. Juli 2022 (<https://ec.europa.eu/eurostat/web/experimental-statistics/collaborative-economy-platforms>).
- Ewens, Michael, Bryan Tomlin, und Liang C. Wang. 2013. „Statistical Discrimination or Prejudice? A Large Sample Field Experiment“. *Review of Economics and Statistics* 96(1):119–34. doi: https://doi.org/10.1162/REST_a_00365.
- Fabbrizzi, Simone, Symeon Papadopoulos, Eirini Ntoutsis, und Ioannis Kompatsiaris. 2022. „A Survey on Bias in Visual Datasets“. *Computer Vision and Image Understanding* 223(October 2022):103552. doi: <https://doi.org/10.1016/j.cviu.2022.103552>.
- Fabo, Brian, Miroslav Beblavy, Zachary Kilhoffer, und Karolien Lenaerts. 2017. *An Overview of European Platforms: Scope and Business Models. JRC Science for Policy Report. JRC109190.* Luxembourg: Publications Office of the European Union.

- Faircrowd.work. 2019. „Fair Crowd Work - Plattform-Profil - upwork“. Abgerufen 3. Oktober 2019 (<http://faircrowd.work/de/platform/upwork/>).
- Farber, Henry S., und Robert Gibbons. 1996. „Learning and Wage Dynamics“. *Quarterly Journal of Economics* 111(4):1007–47. doi: <https://doi.org/10.2307/2946706>.
- Farrell, Diana, und Fiona Greig. 2016. „Paychecks, Paydays, and the Online Platform Economy: Big Data on Income Volatility“. *Proceedings. Annual Conference on Taxation and Minutes of the Annual Meeting of the National Tax Association* 109(2016):1–40.
- Fiverr.com. 2020. „Fiverr’s Payment Terms“. Abgerufen 11. April 2021 (<https://www.fiverr.com/content/payments-terms-and-conditions>).
- Fivesquid.com. 2020. „Terms of Service - Fivesquid“. Abgerufen 11. April 2021 (<https://www.fivesquid.com/terms-of-service>).
- Foong, Eureka, Nicholas Vincent, Brent Hecht, und Elizabeth M. Gerber. 2018. „Women (Still) Ask For Less: Gender Differences in Hourly Rate in an Online Labor Marketplace“. *Proceedings of the ACM on Human-Computer Interaction* 2(CSCW):1–21. doi: <https://doi.org/10.1145/3274322>.
- Forde, Chris, Mark Stuart, Simon Joyce, Liz Oliver, Danat Valizade, Gabriella Alberti, Kate Hardy, Vera Trappmann, Charles Umney, und Calum Carson. 2017. *The Social Protection of Workers in the Platform Economy. Study for the EMPL Committee*. PE 614.184. Brüssel: Europäisches Parlament.
- Freelancer.com. 2014. „Proposed Milestones | Freelancer Blog“. Abgerufen 19. April 2022 (<https://www.freelancer.com/community/articles/proposed-milestones>).
- Freelancer.com. 2016a. „Quick Tips in Monitoring Your Freelancer Contest | Freelancer Blog“. Abgerufen 6. April 2022 (<https://www.freelancer.com/community/articles/quick-tips-in-monitoring-your-freelancer-contest>).
- Freelancer.com. 2016b. „The Freelancer.Com Bid Ranking Guide | Freelancer Blog“. Abgerufen 13. April 2022 (<https://www.freelancer.com/community/articles/the-freelancer-com-bid-ranking-guide>).
- Freelancer.com. 2017a. „Freelancer Rewards: How to Earn Experience Points, Credits, Badges | Freelancer Blog“. Abgerufen 13. April 2022 (<https://www.freelancer.com/community/articles/freelancer-rewards-how-to-earn-experience-points-credits-badges>).
- Freelancer.com. 2017b. „Welcome to Freelancer Services | Freelancer Blog“. Abgerufen 7. April 2022 (<https://www.freelancer.com/community/articles/welcome-to-freelancer-services>).
- Freelancer.com. 2020. „Freelancer Updates Ranking Algorithm | Freelancer Blog“. Abgerufen 14. April 2022 (<https://www.freelancer.com/community/articles/freelancer-updates-ranking-algorithm>).

- Freelancer.com. 2021a. „Freelancer.Com Know Your Customer Program Benefits | Freelancer Blog“. Abgerufen 13. April 2022 (<https://www.freelancer.com/community/articles/kyc-program-benefits>).
- Freelancer.com. 2021b. „Hire Freelancers & Find Freelance Jobs Online | Freelancer“. Abgerufen 11. April 2021 (<https://www.freelancer.com/>).
- Freelancer.com. 2021c. „KYC Verified and Freelancer Verified, Siblings but Not Twins | Freelancer Blog“. Abgerufen 13. April 2022 (<https://www.freelancer.com/community/articles/kyc-verified-and-freelancer-verified-siblings-but-not-twins>).
- Freelancer.com. 2022a. „Applying for the Preferred Freelancer Program | Profile | Freelancer Support“. Abgerufen 11. April 2022 (<https://www.freelancer.com/support/freelancer/profile/how-to-apply-to-the-preferred-freelancer-program>).
- Freelancer.com. 2022b. „Bid Limit and Replenishment | Project | Freelancer Support“. Abgerufen 11. April 2022 (<https://www.freelancer.com/support/freelancer/Project/bid-limit-and-replenishment>).
- Freelancer.com. 2022c. „Browse All Categories“. Abgerufen 12. Januar 2022 (<https://www.freelancer.com/hire>).
- Freelancer.com. 2022d. „Desktop Application“. Abgerufen 13. April 2022 (<https://www.freelancer.com/desktop-app/>).
- Freelancer.com. 2022e. „Freelancer Community: Articles, Tips & Advice | Freelancer“. Abgerufen 13. April 2022 (<https://www.freelancer.com/community>).
- Freelancer.com. 2022f. „Freelancer Fees and Charges, Earn And Save More!“ Abgerufen 11. April 2022 (<https://www.freelancer.com/feesandcharges>).
- Freelancer.com. 2022g. *Freelancer Limited Financial Report & Directors Report FY21. Financial Report & Directors Report. FY21.* Sydney: Freelancer Ltd.
- Freelancer.com. 2022h. *Freelancer Limited FY21 Results. Presentation. FY21.* Sydney: Freelancer Ltd.
- Freelancer.com. 2022i. „Freelancer Local: Find and Hire a Local For Your Task“. Abgerufen 6. April 2022 (<https://www.freelancer.de/local>).
- Freelancer.com. 2022j. „Freelancer Membership Plans, Earn And Save More!“ Abgerufen 11. April 2022 (<https://www.freelancer.com/membership/>).
- Freelancer.com. 2022k. „How to Rate a Freelancer | Project | Freelancer Support“. Abgerufen 2. November 2022 (<https://www.freelancer.com/support/project/how-to-rate-a-freelancer/>).
- Freelancer.com. 2022l. „IOS APP API Expert -- 3 | iPhone | Mobile App Development | Objective C | iPad | Android | Freelancer“. Abgerufen 6. April 2022 (<https://www.freelancer.com/projects/iphone/ios-app-api-expert-33403815>).
- Freelancer.com. 2022m. „Magento Script to Modify MageWorx Advanced Custom Options Values. | Magento | PHP | MySQL | Freelancer“. Abgerufen 31. Mai

- 2022 (<https://www.freelancer.com/projects/magento/magento-script-modify-mageworx-advanced>).
- Freelancer.com. 2022n. „Need Video Journalist / Video Photographer Amsterdam | Video Services | Video Production | Videography | Freelancer“. Abgerufen 6. April 2022 (<https://www.freelancer.com/projects/video-services/need-video-journalist-video-photographer>).
- Freelancer.com. 2022o. „The Preferred Freelancer Program | General | Freelancer Support“. Abgerufen 11. April 2022 (<https://www.freelancer.com/support/freelancer/general/the-preferred-freelancer-program>).
- Frenken, Koen, und Juliet Schor. 2019. „Putting the Sharing Economy into Perspective“. S. 121–35 in *A Research Agenda for Sustainable Consumption Governance*, herausgegeben von O. Mont. Cheltenham/Northampton: Edward Elgar Publishing.
- Frochte, Jörg. 2018. *Maschinelles Lernen: Grundlagen und Algorithmen in Python*. 3. Aufl. München: Carl Hanser Verlag.
- Fry, Tim R. L., und Mark N. Harris. 1996. „A Monte Carlo Study of Tests for the Independence of Irrelevant Alternatives Property“. *Transportation Research Part B: Methodological* 30(1):19–30. doi: 10.1016/0191-2615(95)00019-4.
- Fry, Tim R. L., und Mark N. Harris. 1998. „Testing for Independence of Irrelevant Alternatives: Some Empirical Results“. *Sociological Methods & Research* 26(3):401–23. doi: 10.1177/0049124198026003005.
- Fryer, Roland G. 2007. „Belief Flipping in a Dynamic Model of Statistical Discrimination“. *Journal of Public Economics* 91(5):1151–66. doi: <https://doi.org/10.1016/j.jpubeco.2006.05.015>.
- Fryer, Roland, und Matthew O. Jackson. 2008. „A Categorical Model of Cognition and Biased Decision Making“. *The B.E. Journal of Theoretical Economics* 8(1):Article 6. doi: <https://doi.org/10.2202/1935-1704.1357>.
- Galenianos, Manolis, und Philipp Kircher. 2009. „Directed Search with Multiple Job Applications“. *Journal of Economic Theory* 144(2):445–71. doi: <https://doi.org/10.1016/j.jet.2008.06.007>.
- Gallagher, Andrew C., und Tsuhan Chen. 2009. „Understanding Images of Groups of People“. S. 256–63 in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, herausgegeben von Institute of Electrical and Electronics Engineers. New York: IEEE.
- Galperin, Hernan. 2021. „“This Gig Is Not for Women”: Gender Stereotyping in Online Hiring“. *Social Science Computer Review* 39(6):1089–1107. doi: <https://doi.org/10.1177/089443931989575>.
- Galperin, Hernan, Guillermo Cruces, und Catrihel Greppi. 2017. *Gender Interactions in Wage Bargaining: Evidence from an Online Field Experiment*. SSRN Research Paper. 3056508. Los Angeles/La Plata: University of Southern California/Universidad Nacional de La Plata.
- Galperin, Hernan, und Catrihel Greppi. 2017. *Geographical Discrimination in the Gig Economy*. SSRN Research Paper. 2922874. Los Angeles/La Plata: University of Southern California/Universidad Nacional de La Plata.

- Ge, Yanbo, Christopher R. Knittel, Don MacKenzie, und Stephen Zoepf. 2016. *Racial and Gender Discrimination in Transportation Network Companies. NBER Working Paper. 22776*. Cambridge: National Bureau of Economic Research. doi: 10.3386/w22776.
- Ghani, Ejaz, William R. Kerr, und Christopher Stanton. 2014. „Diasporas and Outsourcing: Evidence from oDesk and India“. *Management Science* 60(7):1677–97. doi: <https://doi.org/10.1287/mnsc.2013.1832>.
- Gheorghe, Mihai. 2015. „State of Freelancing in IT and Future Trends“. *International Journal of Economics and Management Engineering* 9(5):1474–78. doi: doi.org/10.5281/zenodo.1338254.
- Giard, Nicole, Sarah Brunsmeier, Paul Hensen, Marc Hesse, Nils Löken, Zahra Nouri, Mareike Reimann, Katharina D. Schlicher, Martin Schneider, und Julian Schulte. 2021. *Erkenntnisse zur Arbeitsrealität deutscher Crowdworker. Research Report*. Bielefeld: Forschungsschwerpunkt Digitale Zukunft (Universität Bielefeld / Universität Paderborn).
- Goldin, Claudia. 2014. „A Grand Gender Convergence: Its Last Chapter“. *American Economic Review* 104(4):1091–1119. doi: 10.1257/aer.104.4.1091.
- Golomb, Beatrice A., David T. Larence, und Terrence J. Sejnowski. 1990. „Sexnet: A Neural Network Identifies Sex from Human Faces“. *Advances in Neural Information Processing Systems* 3:572–77.
- Gomez-Herrera, Estrella, und Frank Mueller-Langer. 2019. *Is There a Gender Wage Gap in Online Labour Markets? Evidence from over 250,000 Projects and 2.5 Million Wage Bill Proposals. JRC Technical Report. 2019–01*. Seville: European Commission, Joint Research Centre.
- Gorman, Elizabeth H. 2005. „Gender Stereotypes, Same-Gender Preferences, and Organizational Variation in the Hiring of Women: Evidence from Law Firms“. *American Sociological Review* 70(4):702–28. doi: 10.1177/000312240507000408.
- Greef, Samuel, Wolfgang Schroeder, Alexander Akel, Alex Berzel, Oliver D'Antonio, Lukas Kiepe, Benedikt Schreiter, und Hans Joachim Sperling. 2017. *Plattformökonomie und Crowdworking: eine Analyse der Strategien und Positionen zentraler Akteure. Forschungsbericht. 500*. Berlin: Bundesministerium für Arbeit und Soziales (BMAS).
- Greene, William H. 2012. *Econometric Analysis. 7. Aufl.* Harlow: Pearson Education.
- Greenwald, Anthony G., Debbie E. McGhee, und Jordan L. K. Schwartz. 1998. „Measuring Individual Differences in Implicit Cognition: The Implicit Association Test“. *Journal of Personality and Social Psychology* 74(6):1464–80. doi: 10.1037/0022-3514.74.6.1464.
- Günther, Jens, und Matthias Böglmüller. 2015. „Arbeitsrecht 4.0 – Arbeitsrechtliche Herausforderungen in der vierten industriellen Revolution“. *Neue Zeitschrift für Arbeitsrecht* (17):1025–31.
- Guru.com. 2021a. „Guru - Hire Freelancers Online and Find Freelance Jobs Online“. Abgerufen 11. April 2021 (<https://www.guru.com/>).

- Guru.com. 2021b. „Terms of Service - Guru.Com“. Abgerufen 11. April 2021 (<https://www.guru.com/pricing-employer/>).
- Hall, Jonathan V., und Alan B. Krueger. 2018. „An Analysis of the Labor Market for Uber’s Driver-Partners in the United States“. *Industrial and Labor Relations Review* 71(3):705–32. doi: 10.1177/0019793917717222.
- Hannàk, Anikó, Claudia Wagner, David Garcia, Alan Mislove, Markus Strohmaier, und Christo Wilson. 2017. „Bias in Online Freelance Marketplaces: Evidence from TaskRabbit and Fiverr“. S. 1914–33 in *CSCW ’17: Proceedings of the 2017 ACM Conference on Computer Supported Cooperative Work and Social Computing*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.
- Harris, Seth D., und Alan B. Krueger. 2015. *A Proposal for Modernizing Labor Laws for Twenty-First-Century Work: The “Independent Worker” Discussion Paper*. 2015–10. Washington: The Hamilton Project.
- Hausman, Jerry A. 1978. „Specification Tests in Econometrics“. *Econometrica* 46(6):1251–71. doi: 10.2307/1913827.
- Hausman, Jerry, und Daniel McFadden. 1984. „Specification Tests for the Multinomial Logit Model“. *Econometrica* 52(5):1219. doi: 10.2307/1910997.
- Hausmann, Ann-Christin, und Corinna Kleinert. 2014. *Berufliche Segregation auf dem Arbeitsmarkt - Männer- und Frauendomänen kaum verändert. IAB-Kurzbericht. 9/2014*. Nürnberg: Institut für Arbeitsmarkt- und Berufsforschung (IAB).
- Heckman, James J., Lance J. Lochner, und Petra E. Todd. 2006. „Chapter 7: Earnings Functions, Rates of Return and Treatment Effects: The Mincer Equation and Beyond“. S. 307–458 in *Handbook of the Economics of Education*. Bd. 1, herausgegeben von E. Hanushek und F. Welch. Amsterdam [u. a.]: Elsevier/North-Holland.
- Hensel, Isabell. 2020. *Genderaspekte von Plattformarbeit: Stand in Forschung und Literatur. Expertise für den Dritten Gleichstellungsbericht der Bundesregierung*. Berlin: Geschäftsstelle Dritter Gleichstellungsbericht der Bundesregierung.
- Hildenbrand, Hannah-Maria, Christina von Rüden, und Steffen Viete. 2021. *Measuring the Online Platform Economy in Germany. Arbeitspapier. 07/2021*. Wiesbaden: Sachverständigenrat zur Begutachtung der Gesamtwirtschaftlichen Entwicklung.
- Hill, Terrence D., Andrew P. Davis, J. Micah Roos, und Michael T. French. 2020. „Limitations of Fixed-Effects Models for Panel Data“. *Sociological Perspectives* 63(3):357–69. doi: 10.1177/0731121419863785.
- Hobler, Dietmar, Christina Klenner, Svenja Pfahl, Peter Sopp, und Alexandra Wagner. 2017. *Wer leistet unbezahlte Arbeit? Hausarbeit, Kindererziehung und Pflege im Geschlechtervergleich. Aktuelle Auswertungen aus dem WSI GenderDatenPortal. WSI Report. 35*. Düsseldorf: Hans-Böckler-Stiftung, Wirtschafts- und Sozialwissenschaftliches Institut (WSI).
- Hobler, Dietmar, Yvonne Lott, Svenja Pfahl, und Karin Schulze Buschoff. 2020. *Stand der Gleichstellung von Frauen und Männern in Deutschland. WSI*

- Report*. 56. Düsseldorf: Hans-Böckler-Stiftung, Wirtschafts- und Sozialwissenschaftliches Institut (WSI).
- Hong, Yili, und Paul A. Pavlou. 2014. *Is the World Truly „Flat“? Empirical Evidence from Online Labor Markets*. *Fox School of Business Research Paper*. 15–045. Miami/Houston: University of Miami Herbert Business School/University of Houston - C.T. Bauer College of Business.
- Horton, John J. 2010. „Online Labor Markets“. S. 515–22 in *Internet and Network Economics : 6th International Workshop, WINE 2010, Stanford, CA, USA, December, 2010 : Proceedings*, herausgegeben von A. Saberi. Berlin: Springer.
- Horton, John J., und Prasanna Tambe. 2015. „Labor Economists Get Their Microscope: Big Data and Labor Market Analysis“. *Big Data* 3(3):130–37. doi: 10.1089/big.2015.0017.
- Hu, Yifan, Changwei Hu, Thanh Tran, Tejaswi Kasturi, Elizabeth Joseph, und Matt Gillingham. 2021. „What’s in a Name? – Gender Classification of Names with Character Based Machine Learning Models“. *Data Mining and Knowledge Discovery* 35(4):1537–63. doi: 10.1007/s10618-021-00748-6.
- Huws, Ursula, Neil H. Spencer, und Simon Joyce. 2016. *Crowd Work in Europe: Preliminary results from a survey in the UK, Sweden, Germany, Austria and the Netherlands*. *FEPS Studies*. December 2016. Hatfield: University of Hertfordshire.
- IAB. 2018. „Berufe im Spiegel der Statistik“. Abgerufen 14. November 2022 (<https://bisds.iab.de/Default.aspx>).
- IMF. 2022. „Fiscal Monitor“. Abgerufen 2. November 2022 (<https://www.imf.org/en/Publications/FM>).
- Initiative D21 e.V. 2020. *Digital Gender Gap - Lagebild zu Gender(un)gleichheiten in der digitalisierten Welt*. Berlin: Initiative D21 e.V./Kompetenzzentrum Technik-Diversity-Chancengleichheit e. V.
- International Labour Organization. 2021. *The Role of Digital Labour Platforms in Transforming the World of Work*. *World Employment and Social Outlook*. 2021. Genf: International Labour Organization.
- Ipeirotis, Panagiotis G. 2010a. „Analyzing the Amazon Mechanical Turk Marketplace“. *XRDS: Crossroads, The ACM Magazine for Students* 17(2):16. doi: 10.1145/1869086.1869094.
- Ipeirotis, Panagiotis G. 2010b. *Demographics of Mechanical Turk*. *NYU Working Paper*. CEDER-10-01. New York: New York University.
- Jäger, Sebastian, Arndt Allhorn, und Felix Bießmann. 2021. „A Benchmark for Data Imputation Methods“. *Frontiers in Big Data* 4:o. S. doi: 10.3389/fdata.2021.693674.
- Jinnai Yusuke. 2016. *Do Job Applicants also Discriminate Potential Employers? Evidence from the Worlds Largest Online Labor Market*. *Economics & Management Series*. EMS-2016-03. Minami-Uonuma: International University of Japan.

- Kahn, Lawrence M. 1991. „Customer Discrimination and Affirmative Action“. *Economic Inquiry* 29(3):555–71. doi: <https://doi.org/10.1111/j.1465-7295.1991.tb00846.x>.
- Kalleberg, Arne L., und Michael Dunn. 2016. „Good Jobs, Bad Jobs in the Gig Economy“. *Perspectives on Work* 20(2016):10–13, 74–75.
- Karkkainen, Kimmo, und Jungseock Joo. 2021. „FairFace: Face Attribute Dataset for Balanced Race, Gender, and Age for Bias Measurement and Mitigation“. S. 1547–57 in *2021 IEEE Winter Conference on Applications of Computer Vision (WACV)*, herausgegeben von Institute of Electrical and Electronics Engineers. Los Alamitos, California, Washington, Tokyo: IEEE/CPS.
- Kässi, Otto, und Vili Lehdonvirta. 2018. „Online Labour Index: Measuring the Online Gig Economy for Policy and Research“. *Technological Forecasting and Social Change* 137:241–48. doi: 10.1016/j.techfore.2018.07.056.
- Kässi, Otto, und Vili Lehdonvirta. 2019. *Do Digital Skill Certificates Help New Workers Enter the Market? Evidence from an Online Labour Platform. OECD Social, Employment and Migration Working Papers*. 225. Paris: OECD Publishing. doi: 10.31235/osf.io/7tybd.
- Katz, Lawrence F., und Alan B. Krueger. 2019. „The Rise and Nature of Alternative Work Arrangements in the United States, 1995–2015“. *Industrial and Labor Relations Review* 72(2):382–416. doi: 10.1177/0019793918820008.
- Kenney, Martin, und John Zysman. 2016. „The Rise of the Platform Economy“. *Issues in Science and Technology* 32(3):61–69.
- Kim, Taewoon. 2021. „Generalizing MLPs With Dropouts, Batch Normalization, and Skip Connections“. *arXiv preprint arXiv:2108.08186*.
- Kingsley, Sara C., Mary L. Gray, und Siddharth Suri. 2015. „Accounting for Market Frictions and Power Asymmetries in Online Labor Markets: Market Friction and Power in Online Labor Markets“. *Policy & Internet* 7(4):383–400. doi: 10.1002/poi3.111.
- Kirchner, Stefan. 2019. „Arbeiten in der Plattformökonomie: Grundlagen und Grenzen von ‚Cloudwork‘ und ‚Gigwork‘“. *Kölner Zeitschrift für Soziologie und Sozialpsychologie* 71(1):3–25. doi: 10.1007/s11577-019-00587-w.
- Kirchner, Stefan, und Elke Schüßler. 2019. „6 - The Organization of Digital Marketplaces: Unmasking the Role of Internet Platforms in the Sharing Economy“. S. 131–54 in *Organization outside Organizations*, herausgegeben von G. Ahrne und N. Brunsson. Cambridge: Cambridge University Press.
- Kleemann, Frank, Günter Voß, und Kerstin M. Rieder. 2008. „Crowdsourcing und der Arbeitende Konsument“. *Arbeits- und Industriesoziologische Studien* 1(1):29–44. doi: <https://doi.org/10.21241/ssoar.64725>.
- Knowles, John, Nicola Persico, und Petra Todd. 2001. „Racial Bias in Motor Vehicle Searches: Theory and Evidence“. *Journal of Political Economy* 109(1):203–29. doi: <https://doi.org/10.1086/318603>.
- Koopmans, Ruud, Susanne Veit, und Ruta Yemane. 2018. *Ethnische Hierarchien in der Bewerberauswahl: Ein Feldexperiment zu den Ursachen von*

- Arbeitsmarktdiskriminierung. WZB Discussion Paper. SP VI 2018-104.*
Berlin: Wissenschaftszentrum Berlin für Sozialforschung.
- Kuek, Siou C., Cecilia Paradi-Guilford, Toks Fayomi, Saori Imaizumi, Panos Ipeirotis, Patricia Pina, und Manpreet Singh. 2015. *The Global Opportunity in Online Outsourcing. Report.* ACS14228. Washington: World Bank.
- Kühnemann, Heidi. 2021. „Anwendungen des Web Scraping in der amtlichen Statistik“. *AStA Wirtschafts- und Sozialstatistisches Archiv* 15(1):5–25. doi: 10.1007/s11943-021-00280-5.
- Kumar, Neeraj, Alexander C. Berg, Peter N. Belhumeur, und Shree K. Nayar. 2009. „Attribute and Simile Classifiers for Face Verification“. S. 365–72 in *2009 IEEE 12th International Conference on Computer Vision*, herausgegeben von Institute of Electrical and Electronics Engineers. New York: IEEE/CPS.
- Landis, J. Richard, und Gary G. Koch. 1977. „The Measurement of Observer Agreement for Categorical Data“. *Biometrics* 33(1):159–74. doi: 10.2307/2529310.
- Lang, Kevin, und Jee-Yeon K. Lehmann. 2012. *Racial Discrimination in the Labor Market: Theory and Empirics. Working Paper.* 17450. Cambridge: National Bureau of Economic Research.
- Lang, Kevin, und Michael Manove. 2011. „Education and Labor Market Discrimination“. *American Economic Review* 101(4):1467–96. doi: 10.1257/aer.101.4.1467.
- Lang, Kevin, Michael Manove, und William T. Dickens. 2005. „Racial Discrimination in Labor Markets with Posted Wage Offers“. *American Economic Review* 95(4):1327–40. doi: 10.1257/0002828054825547.
- Lange, Fabian. 2007. „The Speed of Employer Learning“. *Journal of Labor Economics* 25(1):1–35. doi: 10.1086/508730.
- Langley, Paul, und Andrew Leyshon. 2017. „Platform Capitalism: The Intermediation and Capitalization of Digital Economic Circulation“. *Finance and Society* 3(1):11–31. doi: 10.2218/finsoc.v3i1.1936.
- Leimeister, Jan Marco, David Durward, und Shkodran Zogaj. 2016. *Crowd worker in Deutschland: eine empirische Studie zum Arbeitsumfeld auf externen Crowdsourcing-Plattformen. Study.* 323. Düsseldorf: Hans-Böckler-Stiftung.
- Leimeister, Jan Marco, Shkodran Zogaj, David Durward, und Ivo Blohm. 2016. *Systematisierung und Analyse von Crowd-Sourcing-Anbietern und Crowd-Work-Projekten. Study.* 324. Düsseldorf: Hans-Böckler-Stiftung.
- Lepanjuuri, Katriina, Robert Wishart, und Peter Cornick. 2018. *The Characteristics of Those in the Gig Economy.* London: Department for Business, Energy and Industrial Strategy (United Kingdom), NatCen Social Research.
- Leung, Ming D., und Sharon Koppman. 2018. „Taking a Pass: How Proportional Prejudice and Decisions Not to Hire Reproduce Gender Segregation“. *American Journal of Sociology* 124(3):762–813. doi: <https://doi.org/10.1086/700677>.

- Leung, Weiwen, Zheng Zhang, Daviti Jibuti, Jinhao Zhao, Maximilian Klein, Casey Pierce, Lionel Robert, und Haiyi Zhu. 2020. „Race, Gender and Beauty: The Effect of Information Provision on Online Hiring Biases“. S. 1–11 in *CHI '20: Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.
- Levay, Kevin E., Jeremy Freese, und James N. Druckman. 2016. „The Demographic and Political Composition of Mechanical Turk Samples“. *Sage Open* 6(1). doi: 10.1177/2158244016636433.
- Levenshtein, Vladimir I. 1966. „Binary codes capable of correcting deletions, insertions, and reversals“. *Soviet Physics-Doklady* 10(8):707–10.
- Levin, Jonathan. 2009. „The Dynamics of Collective Reputation“. *The B.E. Journal of Theoretical Economics* 9(1).
- Lingemann, Stefan, und Jörn Otte. 2015. „Arbeitsrechtliche Fragen der ‚Economy on Demand‘“. *Neue Zeitschrift für Arbeitsrecht* (17):1042–47.
- Litman, Leib, Jonathan Robinson, Zohn Rosen, Cheskie Rosenzweig, Joshua Waxman, und Lisa M. Bates. 2020. „The Persistence of Pay Inequality: The Gender Pay Gap in an Anonymous Online Labor Market“. *PLoS ONE* 15(2):e0229383. doi: <https://doi.org/10.1371/journal.pone.0229383>.
- Lorig, Philipp. 2015. „Soloselbstständige Internet-Dienstleister im Niedriglohnbereich: Prekäres Unternehmertum auf Handwerksportalen im Spannungsfeld zwischen Autonomie und radikaler Marktabhängigkeit“. *AIS-Studien* 8(1):55–75. doi: <https://doi.org/10.21241/ssoar.64814>.
- Lott, Yvonne, Dietmar Hobler, Svenja Pfahl, und Eugen Unrau. 2022. *Stand der Gleichstellung von Frauen und Männern in Deutschland. WSI Report. 72*. Düsseldorf: Hans Böckler Stiftung.
- Lundberg, Shelly J. 1991. „The Enforcement of Equal Opportunity Laws Under Imperfect Information: Affirmative Action and Alternatives“. *Quarterly Journal of Economics* 106(1):309–26. doi: <https://doi.org/10.2307/2937919>.
- Lundberg, Shelly J., und Richard Startz. 1983. „Private Discrimination and Social Intervention in Competitive Labor Market“. *American Economic Review* 73(3):340–47.
- Lundberg, Shelly, und Richard Startz. 2007. „Information and Racial Exclusion“. *Journal of Population Economics* 20(3):621–42. doi: <https://doi.org/10.1007/s00148-005-0060-9>.
- Maier, Michael F., und Steffen Viete. 2017. *Plattformbasierte Erwerbsarbeit: Stand der empirischen Forschung. Forschungsbericht. 498*. Berlin: Bundesministerium für Arbeit und Soziales (BMAS).
- Makinen, Erno, und Roope Raisamo. 2008. „Evaluation of Gender Classification Methods with Automatically Detected and Aligned Faces“. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 30(3):541–47. doi: 10.1109/TPAMI.2007.70800.
- Mankiw, N. Gregory, und Mark P. Taylor. 2018. *Grundzüge der Volkswirtschaftslehre. 7. Aufl.* Stuttgart, Freiburg: Schäffer-Poeschel.

- Marshall, Ray. 1974. „The Economics of Racial Discrimination: A Survey“. *Journal of Economic Literature* 12(3):849–71.
- Martin, Nicole, Stefan Lessmann, und Stefan Voss. 2008. „Crowdsourcing: Systematisierung praktischer Ausprägungen und verwandter Konzepte.“ in *Multikonferenz Wirtschaftsinformatik 2008*, herausgegeben von M. Bichler, T. Hess, H. Kremar, U. Lechner, F. Matthes, A. Picot, B. Speitkamp, und P. Wolf. Berlin: GITO-Verlag.
- Marvit, Moshe Z. 2014. „How Crowdworkers Became the Ghosts in the Digital Machine“. *The Nation* (February 24).
- McFadden, Daniel. 1974a. „Chapter 4: Conditional logit analysis of qualitative choice behavior“. S. 105–42 in *Frontiers in Econometrics*, herausgegeben von P. Zarembka. New York: Academic Press.
- McFadden, Daniel. 1974b. „The measurement of urban travel demand“. *Journal of Public Economics* 3(4):303–28. doi: [https://doi.org/10.1016/0047-2727\(74\)90003-6](https://doi.org/10.1016/0047-2727(74)90003-6).
- Milgrom, Paul, und Sharon Oster. 1987. „Job Discrimination, Market Forces, and the Invisibility Hypothesis“. *Quarterly Journal of Economics* 102(3):453–76. doi: <https://doi.org/10.2307/1884213>.
- Mill, Roy. 2011. *Hiring and Learning in Online Global Labor Markets*. NET Institute Working Paper. 11–17. Stanford: Stanford University.
- Müller, Andreas C., und Sarah Guido. 2017. *Einführung in Machine Learning mit Python: Praxiswissen Data Science*. Sebastopol: O'Reilly.
- Muthukumar, Vidya, Tejaswini Pedapati, Nalini Ratha, Prasanna Sattigeri, Chai-Wah Wu, Brian Kingsbury, Abhishek Kumar, Samuel Thomas, Aleksandra Mojsilovic, und Kush R. Varshney. 2019. „Color-Theoretic Experiments to Understand Unequal Gender Classification Accuracy From Face Images“. S. 2286–95 in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, herausgegeben von Institute of Electrical and Electronics Engineers. New York: IEEE.
- Nardinelli, Clark, und Curtis Simon. 1990. „Customer Racial Discrimination in the Market for Memorabilia: The Case of Baseball“. *Quarterly Journal of Economics* 105(3):575–95. doi: <https://doi.org/10.2307/2937891>.
- OECD. 2016. *New Forms of Work in the Digital Economy*. OECD Digital Economy Papers. 260. Paris: OECD Publishing.
- Oettinger, Gerald S. 1996. „Statistical Discrimination and the Early Career Evolution of the Black- White Wage Gap“. *Journal of Labor Economics* 14(1):52–78. doi: <https://doi.org/10.1086/209803>.
- Ohnemus, Jörg, Daniel Erdsiek, und Steffen Viète. 2016. *Nutzung von Crowdworking durch Unternehmen: Ergebnisse einer ZEW-Unternehmensbefragung*. Forschungsbericht. 473. Berlin: Bundesministerium für Arbeit und Soziales (BMAS).
- Online Labour Observatory. 2022. „The Online Labour Index 2020“. Abgerufen 21. Dezember 2022 (<http://onlinelabourobservatory.org/oli-demand/>).

- Pallais, Amanda. 2014. „Inefficient Hiring in Entry-Level Labor Markets“. *American Economic Review* 104(11):3565–99. doi: 10.1257/aer.104.11.3565.
- Parrett, Matthew. 2011. „Customer Discrimination in Restaurants: Dining Frequency Matters“. *Journal of Labor Research* 32(2):87–112. doi: <https://doi.org/10.1007/s12122-011-9107-8>.
- Penner, Andrew M. 2008. „Race and Gender Differences in Wages: The Role of Occupational Sorting at the Point of Hire“. *Sociological Quarterly* 49(3):597–614. doi: <https://doi.org/10.1111/j.1533-8525.2008.00129.x>.
- Peopleperhour.com. 2019. „Terms and Conditions - People Per Hour (PPH)“. Abgerufen 11. April 2021 (<https://www.peopleperhour.com/static/terms>).
- Peopleperhour.com. 2021. „PeoplePerHour.Com - Hire Freelancers Online & Find Freelance Work“. Abgerufen 11. April 2021 (<https://www.peopleperhour.com/>).
- Pesole, Annarosa, Maria Cesira Urzi Brancati, Enrique Fernandez Macias, Federico Biagi, und Ignacio Gonzalez Vazquez. 2018. *Platform Workers in Europe Evidence from the COLLEEM Survey. JRC Science for Policy Report. JRC112157*. Luxembourg: Publications Office of the European Union. doi: 10.2760/742789.
- Peters, Michael. 2007. *Unobservable heterogeneity in directed search. Working Paper*. Vancouver: Vancouver School of Economics.
- Petit, Pascale. 2007. „The Effects of Age and Family Constraints on Gender Hiring Discrimination: A Field Experiment in the French Financial Sector“. *Labour Economics* 14(3):371–91. doi: <https://doi.org/10.1016/j.labeco.2006.01.006>.
- Phelps, Edmund S. 1972. „The Statistical Theory of Racism and Sexism“. *American Economic Review* 62(4):659–61.
- Pinkston, Joshua C. 2003. „Screening Discrimination and the Determinants of Wages“. *Labour Economics* 10(6):643–58. doi: [https://doi.org/10.1016/S0927-5371\(03\)00049-6](https://doi.org/10.1016/S0927-5371(03)00049-6).
- Pinkston, Joshua C. 2006. „A Test of Screening Discrimination with Employer Learning“. *Industrial and Labor Relations Review* 59(2):267–84. doi: <https://doi.org/10.1177/001979390605900205>.
- Pongratz, Hans J., und Sarah Bormann. 2017. „Online-Arbeit auf Internet-Plattformen. Empirische Befunde zum Crowdfunding in Deutschland“. *Arbeits- und Industriesoziologische Studien* 10(2):158–81. doi: <https://doi.org/10.21241/ssoar.64850>.
- RatSWD. 2022. „Ethikleitlinien/-kodices“. Abgerufen 23. Dezember 2022 (<https://www.konsortswd.de/ratswd/best-practice-forschungsethik/ethikleitlinien-kodices/>).
- Reid, D. A., S. Samangoeei, C. Chen, M. S. Nixon, und A. Ross. 2013. „Soft Biometrics for Surveillance: An Overview“. S. 327–52 in *Handbook of Statistics*. Bd. 31, herausgegeben von C. R. Rao und V. Govindaraju. Amsterdam [u. a.]: Elsevier/North-Holland.
- Rhue, Lauren. 2018. „An Overview of Crowd-Based Markets and Racial Discrimination“. in *AMCIS 2018 Proceedings - Social Technical and Social*

- Inclusion Issues (SIGSI)*, herausgegeben von Association for Information Systems. Atlanta: Association for Information Systems.
- Richter, Gerrit, Tobias Wolfram, und Charlotte Weber. 2022. *Die Statistische Methodik von Civey. Methodenbericht*. Berlin: Civey.
- Rochet, Jean-Charles, und Jean Tirole. 2003. „Platform Competition in Two-Sided Markets“. *Journal of the European Economic Association* 1(4):990–1029. doi: 10.1162/154247603322493212.
- Rooth, Dan-Olof. 2007. *Implicit Discrimination in Hiring: Real World Evidence. IZA Discussion Paper*. 2764. Bonn: Institute for the Study of Labor (IZA).
- Rosén, Åsa. 2003. „Search, Bargaining, and Employer Discrimination“. *Journal of Labor Economics* 21(4):807–29. doi: <https://doi.org/10.1086/377018>.
- Ross, Joel, Andrew Zaldivar, Lilly Irani, und Bill Tomlinson. 2010. „Who Are the Crowdworkers?: Shifting Demographics in Amazon Mechanical Turk“. S. 2863–72 in *CHI EA '10: CHI '10 Extended Abstracts on Human Factors in Computing Systems*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.
- Rothe, Rasmus, Radu Timofte, und Luc van Gool. 2015. „DEX: Deep EXpectation of Apparent Age from a Single Image“. S. 10–15 in *2015 IEEE International Conference on Computer Vision Workshop (ICCVW)*, herausgegeben von Institute of Electrical and Electronics Engineers. New York: IEEE.
- Roussille, Nina. 2022. *The Central Role of the Ask Gap in Gender Pay Inequality. Working Paper*. Cambridge: Massachusetts Institute of Technology (MIT).
- Rubin, Donald B. 1976. „Inference and missing data“. *Biometrika* 63(3):581–92. doi: 10.1093/biomet/63.3.581.
- Sasaki, Masaru. 1999. „An Equilibrium Search Model with Coworker Discrimination“. *Journal of Labor Economics* 17(2):377–407. doi: <https://doi.org/10.1086/209925>.
- Schmidt, Florian A. 2016. *Arbeitsmärkte in der Plattformökonomie – Zur Funktionsweise und den Herausforderungen von Crowdwork und Gigwork. Gute Gesellschaft Soziale Demokratie #2017 plus*. Bonn: Friedrich Ebert Stiftung.
- Schneider-Dörr, Andreja. 2019. *Erwerbsarbeit in der Plattformökonomie. Eine kritische Einordnung von Umfang, Schutzbedürftigkeit und arbeitsrechtlichen Herausforderungen. Working Paper Forschungsförderung*. 116. Düsseldorf: Hans-Böckler-Stiftung.
- Schor, Juliet B., und William Attwood-Charles. 2017. „The “Sharing” Economy: Labor, Inequality, and Social Connection on for-Profit Platforms“. *Sociology Compass* 11(8):e12493. doi: 10.1111/soc4.12493.
- Schwartzstein, Joshua. 2014. „Selective Attention and Learning“. *Journal of the European Economic Association* 12(6):1423–52. doi: <https://doi.org/10.1111/jeea.12104>.
- Scrapy Developers. 2022. „Scrapy 2.7 documentation“. Abgerufen 5. Januar 2023 (<https://docs.scrapy.org/en/latest/index.html#>).


- SEC. 2019. „Form F-1 - Fiverr International Ltd.“ Abgerufen 10. April 2021 (<https://www.sec.gov/Archives/edgar/data/1762301/000104746919003139/a2238508zf-1.htm>).
- Serfling, Oliver. 2018. *Crowdworking Monitor Nr. 1*. Kleve: Rhine-Waal University of Applied Science; Bundesministerium für Arbeit und Soziales (BMAS).
- Serfling, Oliver. 2019. *Crowdworking Monitor Nr. 2*. Kleve: Rhine-Waal University of Applied Science; Bundesministerium für Arbeit und Soziales (BMAS).
- Shi, Shouyong. 2009. „Directed Search for Equilibrium Wage–Tenure Contracts“. *Econometrica* 77(2):561–84. doi: <https://doi.org/10.3982/ECTA7870>.
- Silberzahn, Raphael, Eric L. Uhlmann, und Lei Zhu. 2014. „Pay as she goes: For stereotypically male jobs, women tend to be hired by the hour“. S. 16273 in *Academy of Management Proceedings*. Bd. 2014, herausgegeben von Academy of Management. Briarcliff Manor, New York: Academy of Management.
- Sokolova, Marina, und Guy Lapalme. 2009. „A Systematic Analysis of Performance Measures for Classification Tasks“. *Information Processing & Management* 45(4):427–37. doi: [10.1016/j.ipm.2009.03.002](https://doi.org/10.1016/j.ipm.2009.03.002).
- Srnicek, Nick. 2017. *Platform Capitalism*. Cambridge, Malden: Polity Press.
- Staab, Philipp. 2016. *Falsche Versprechen: Wachstum im digitalen Kapitalismus*. Hamburg: Hamburger Edition HIS.
- Stanton, Christopher T., und Catherine Thomas. 2016. „Landing the First Job: The Value of Intermediaries in Online Hiring“. *Review of Economic Studies* 83(2):810–54. doi: [10.1093/restud/rdv042](https://doi.org/10.1093/restud/rdv042).
- Statistisches Bundesamt. 2022a. „Bildungsstand“. Abgerufen 7. Mai 2022 (https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Bildung-Forschung-Kultur/Bildungsstand/_inhalt.html).
- Statistisches Bundesamt. 2022b. „Gender Pay Gap 2021: Frauen verdienen pro Stunde weiterhin 18 % weniger als Männer“. Abgerufen 8. März 2022 (https://www.destatis.de/DE/Presse/Pressemitteilungen/2022/03/PD22_088_621.html).
- Stephany, Fabian, Michael Dunn, Steven Sawyer, und Vili Lehdonvirta. 2020. „Distancing Bonus Or Downscaling Loss? The Changing Livelihood of Us Online Workers in Times of COVID-19“. *Tijdschrift Voor Economische En Sociale Geografie* 111(3):561–73. doi: [10.1111/tesg.12455](https://doi.org/10.1111/tesg.12455).
- Stephany, Fabian, Otto Kässi, Uma Rani, und Vili Lehdonvirta. 2021. „Online Labour Index 2020: New Ways to Measure the World’s Remote Freelancing Market“. *Big Data & Society* 8(2):1–7. doi: [10.1177/20539517211043240](https://doi.org/10.1177/20539517211043240).
- Sundararajan, Arun. 2017. *The Sharing Economy: The End of Employment and the Rise of Crowd-Based Capitalism*. Cambridge, London: MIT Press.
- Swaminathan, Avinash, Mridul Chaba, Deepak K. Sharma, und Yogesh Chaba. 2020. „Gender Classification Using Facial Embeddings: A Novel Approach“. *Procedia Computer Science* 167:2634–42. doi: [10.1016/j.procs.2020.03.342](https://doi.org/10.1016/j.procs.2020.03.342).
- Thurow, Lester C. 1975. *Generating Inequality*. New York: Basic Books.

- Toptal.com. 2021a. „Frequently Asked Questions“. Abgerufen 11. April 2021 (<https://www.toptal.com/faq>).
- Toptal.com. 2021b. „Stats and Figures - Toptal.Com“. Abgerufen 11. April 2021 (<https://www.toptal.com/about#stats>).
- UNESCO. 2012. *International Standard Classification of Education (ISCED) 2011*. Montreal: UNESCO Institute for Statistics.
- UNSECO. 2016. „ISCED Mappings“. Abgerufen 2. November 2022 (<http://uis.unesco.org/en/isced-mappings>).
- Upwork.com. 2020a. „Upwork Legal Center“. Abgerufen 11. April 2021 (<https://www.upwork.com/legal#fees>).
- Upwork.com. 2020b. „Upwork’s Work Diary: What It Is and Why Use It“. Abgerufen 15. April 2022 (<https://community.upwork.com/t5/Hiring-Resources/Upwork-s-Work-Diary-What-It-Is-and-Why-Use-It/m-p/735273#M40>).
- Urzi Brancati, Maria C., Annarosa Pesole, und Enrique Fernandez-Macias. 2019. *Digital Labour Platforms in Europe: Numbers, Profiles, and Employment Status of Platform Workers*. JRC Technical Reports. JRC117330. Luxembourg: Publications Office of the European Union.
- Urzi Brancati, Maria C., Annarosa Pesole, Enrique Fernández-Macías, European Commission, und Joint Research Centre. 2020. *New Evidence on Platform Workers in Europe: Results from the Second COLLEEM Survey*. JRC Science for Policy Report. JRC118570. Luxembourg: Publications Office of the European Union.
- Vallas, Steven, und Juliet B. Schor. 2020. „What Do Platforms Do? Understanding the Gig Economy“. *Annual Review of Sociology* 46(1):273–94. doi: 10.1146/annurev-soc-121919-054857.
- Vogel, Paul, und Eric Hilgendorf. 2019. „Big Data in den Sozial-, Verhaltens- und Wirtschaftswissenschaften: Datenzugang und Forschungsdatenmanagement“. *RatSWD Output* 4(6). doi: 10.17620/02671.39.
- Weltbank. 2022a. „Labor force, female (% of total labor force) | Data“. Abgerufen 20. Dezember 2022 (<https://data.worldbank.org/indicator/SL.TLF.TOTL.FE.ZS>).
- Weltbank. 2022b. „Population, female (% of total population) | Data“. Abgerufen 20. Dezember 2022 (<https://data.worldbank.org/indicator/SP.POP.TOTL.FE.ZS>).
- Wooldridge, Jeffrey M. 2002. *Econometric Analysis of Cross Section and Panel Data*. Cambridge, London: MIT Press.
- Wu, Wenying, Pavlos Protopapas, Zheng Yang, und Panagiotis Michalatos. 2020. „Gender Classification and Bias Mitigation in Facial Images“. S. 106–14 in *WebSci ’20: 12th ACM Conference on Web Science*, herausgegeben von Association for Computing Machinery. New York: Association for Computing Machinery.
- Zhang, Zhifei, Yang Song, und Heirong Qi. 2022. „UTKFace Dataset“. Abgerufen 20. Oktober 2022 (<https://susanqq.github.io/UTKFace/>).

- Ziegert, Jonathan C., und Paul J. Hanges. 2005. „Employment Discrimination: The Role of Implicit Attitudes, Motivation, and a Climate for Racial Bias“. *Journal of Applied Psychology* 90(3):553–62. doi: 10.1037/0021-9010.90.3.553.
- Zysman, John, und Martin Kenney. 2017. „Intelligent Tools and Digital Platforms: Implications for Work and Employment“. *Intereconomics* 52(6):329–34. doi: 10.1007/s10272-017-0699-y.

Anhang

Anhang Abbildung 1: Beispiel einer anonymisierten Projektausschreibung eines Fixed Price Jobs auf freelancer.com

 [Log In](#) [Sign Up](#) [Post a Project](#)

Magento script to modify MageWorx Advanced custom options values. COMPLETED **BUDGET \$10-30 USD**

Freelancer > Jobs > Magento > Magento script to modify MageWorx Advanced custom options values.



Hi, I'm looking for anyone who can create a

PHP script (will be run by cron or console) which will read the CSV file and to modify 2-3 elements in the mysql table and send me a report by mail with products which are not found in the site.

The idea is to modify the prices and quantity in products with MageWorx Advanced custom options.

The products are with custom options SKU which is same as in the CSV file and I need to modify the price and quantity.

Skills: [Magento](#), [PHP](#), [MySQL](#)

About the Client:
5.0 ★★★★★ (32 reviews)  Sofia, Bulgaria 




Project ID: #32611186

Looking to make some money? PROJECT COMPLETED

Your email address
 [Apply for similar jobs](#)




- ✓ Set your budget and timeframe
- ✓ Get paid for your work
- ✓ Outline your proposal
- ✓ It's free to sign up and bid on jobs

Awarded to:




 **Freelancer:in A**  **\$30 USD in 1 day**
5.0 ★★★★★ (78 Reviews)
6.1 

i am ready to start now to do Magento customization
Have read your description of project very carefully.
I'm a professional developer with 2 year experience as you can see my profile.

3 freelancers are bidding on average \$60 for this job

 **Freelancer:in B**  **\$99 USD in 1 day**
4.9 ★★★★★ (94 Reviews)
6.2 

Hello Sir, I am Adobe Certified Expert having 6Y+ experience. Please check out our past projects and their reviews as all our clients are satisfied. Let's initiate a chat. I am available right now to start the work. H [\[More \]](#)

 **Freelancer:in C**  **\$50 USD in 3 days**
4.9 ★★★★★ (60 Reviews)
5.6 

I can write PHP script - to update price and quantity - for you.

Should I do it as a module fired by the command: bin/magento or an independent script?

Post a project like this

Other jobs from this client

- ▶ Pets dating site - 2 (\$30-250 USD)
- ▶ Finish Magento Supplier module. (\$30-250 USD)
- ▶ Magento Product cost,supplier and profit per order. (\$100-400 USD)
- ▶ Magento Facebook Retarget Ads (\$30-250 USD)
- ▶ Install and enable PHP Profiler and debug a code error (\$10-30 USD)

< Previous Job Next Job >

Similar jobs

- ▶ Migration from Siteground to GoDaddy in 5 days (€30-250 EUR)
- ▶ http://TeluguIndi.com (₹1500-12500 INR)
- ▶ need WordPress website (\$750-1500 USD)
- ▶ Sync sql database to wocommerce site (\$250-750 USD)
- ▶ Magento 2 - Fix Google Analytics and Ads conversions not working (min \$50 USD / hour)
- ▶ Looking for a web developer for SaaS app development. (\$25-50 USD / hour)
- ▶ Additions to the Laravel project and import data and interfaces for display (\$30-250 USD)
- ▶ I have a project on online banking - 2 (₹400-750 INR / hour)
- ▶ Need Full-Time Expert WordPress Developer (Long-Term) (\$15-25 USD / hour)
- ▶ Website development (₹1500-12500 INR)
- ▶ Ony Latins (\$30-250 USD)
- ▶ IBD and FRM to SQL small work (\$10-30 USD)
- ▶ develop company website (\$10-30 USD)
- ▶ Magento 2 extended adjustment (€30-250 EUR)
- ▶ Ubuntu server expert (\$8-15 USD / hour)
- ▶ Need A Magento 2 Developer (NO PAKISTANI) (\$8-15 AUD / hour)
- ▶ Build me a APP(2way)+WEBSITE (₹15000-100000 INR)
- ▶ Extracting of database to csv format (\$250-750 USD)
- ▶ Build a plug-in for magento (\$250-750 USD)
- ▶ Mobile App required for Magento 2 project (₹1500-12500 INR)

Anhang Abbildung 2: Beispiel einer anonymisierten Projektausschreibung eines Contests auf freelancer.com

freelancer.com How It Works Browse Jobs Log In Sign Up Post a Contest

Freelancer > Contest > Caricature & Cartoons > Create a logo

Create a logo

Status: Open Prize: \$50 Entries Received: 214

Contest Brief



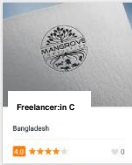
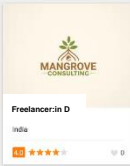

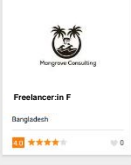

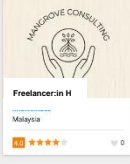
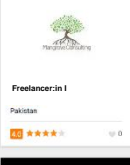

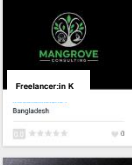
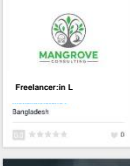
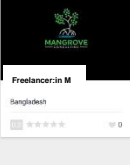
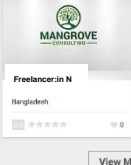
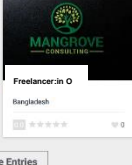

I'm looking for a logo to be made for my new consulting company. The company name is Mangrove Consulting. I would like the logo to have mangroves drawn around the name Mangrove Consulting, with baby fish, sharks, octopus, barracudas, crabs, and other sea animals around it. It should feel professional, but interesting. I would like for this to be drawn, not photoshopped.

Recommended Skills

Caricature & Cartoons - Graphic Design - Illustration - Illustrator - Logo Design

[Enter This Contest](#)

Top entries from this contest

 Freelancer A Bangladesh 4.5 stars	 Freelancer B Bangladesh 4.5 stars	 Freelancer C Bangladesh 4.5 stars	 Freelancer D India 4.5 stars
 Freelancer E Bangladesh 4.5 stars	 Freelancer F Bangladesh 4.5 stars	 Freelancer G India 4.5 stars	 Freelancer H Malaysia 4.5 stars
 Freelancer I Pakistan 4.5 stars	 Freelancer J Serbia 4.5 stars	 Freelancer K Bangladesh 4.5 stars	 Freelancer L Bangladesh 4.5 stars
 Freelancer M Bangladesh 4.5 stars	 Freelancer N Bangladesh 4.5 stars	 Freelancer O Bangladesh 4.5 stars	 Freelancer P Bangladesh 4.5 stars

[View More Entries](#)

Public Clarification Board

Freelancer B: Hi, can you rate my entry #91 as the feedback? Thank you in advance (23 hours ago)

Contest Winner: Good start. Can you add a small fish, shark, and stingray to it? (21 hours ago)

Freelancer B: hi, can you check my entry #167. Thank you (9 hours ago)

Freelancer D: please chek #46 (20 hours ago)

Freelancer D: please chek #57 (21 hours ago)

Freelancer E: hi (23 hours ago)

[Show more comments](#)

Similar Contests

- Create a business logo by callumbentf \$113 USD
- Design A Logo by Richard D. \$250 USD
- Make me a Web3 / Metaverse logo by Noah L. \$100 USD
- New branding by Marie-Audrey G. \$96 USD
- Political Caricature Cartoon by Dave K. \$100 USD

[View more](#)

Completed Contests

- 15 second animated video by Hans Peter C. \$55 USD
- Brand development / logo by Anthony M. \$57 USD
- Logo for Buvrito food track by Korvad \$30 USD

Quelle: Freelancer.com (2022)

Anhang Abbildung 3: Beispiel einer Projektausschreibung eines Local Jobs auf freelancer.com

Log In Sign Up Post a Project

OPEN

Need video journalist / video photographer Amsterdam

BUDGET \$500-1000 USD

Freelancer > Jobs > Video Services > Need video journalist / video photographer Amsterdam

Post a project like this

[< Previous Job](#) [Next Job >](#)

Similar jobs

- I need a videographer (Hereford, United Kingdom £250-750 GBP)
- Best Hoof Video (\$750-1500 USD)
- Edit a sample video for social media (\$250-750 AUD)
- I need a video editor who has a storyblocks account (\$2-8 USD / hour)
- Build a Website and Instagram Profile (\$2-8 USD / hour)
- Render AfterEffects File (\$10-30 USD)
- Shooting some commentary of new product at exhibition and editing in Düsseldorf – 2 (デュッセルドルフ, ドイツ \$250-750 USD)
- videographer for an african traditional wedding (London, United Kingdom £18-36 GBP / hour)
- Drone Videographer for Youtube Vlog (Valletta, Malta €250-750 EUR)
- Make a Video For My YouTube Channel (\$30-250 AUD)
- Video maker for new product launch (₹600-1500 INR)
- Product Video (\$250-750 USD)
- Make a short video or GIF (\$250-750 CAD)
- Clickbank or maxweb marketer (\$30-250 USD)
- Need a video editing from a ski season in Sun Peaks and Revelstoke (\$30-250 CAD)
- Video Work -- 2 (Melbourne, Australia \$250-750 AUD)

Searching for a video journalist / video photographer for 30 minute corporate interview in Amsterdam. Must be experienced, professional and very presentable.

You are expected to bring your own equipment, set up easy / small lighting for an interview in an office, put a microphone on the subject and film a 20 min video from a fixed tripod.

The subject will receive read from his own script, so you will not do the interviewing yourself, only the light, sound and camerawork.

Total time "on set" will be one hour.

The interview is done in a professional corporate environment, so please dress and present yourself accordingly.

Skills: [Video Services](#), [Video Production](#), [Videography](#)

Location: Amsterdam, Netherlands



See more: software chat video pay per minute, need flv swf play video, need create company demo video, video searching site, need help organizing pics video, transcribe video text per minute, scripte video searching, need some-one create youtube video, need webmaster photographer glamour model, video pay per minute, need software upload batch video youtube, video chat billed minute, average promotion video cost per minute, need journalist write, how much data does a 30 minute video use, how many mb is a 30 minute video, 30 minute workout video no equipment, how long does it take to edit a 30 minute video, 30 minute walking workout video

About the Employer:
0.0 ★★★★★ (0 reviews)  OSLO, Norway     

Project ID: #333402890

Quelle: Freelancer.com (2022n)

Anhang Tabelle 1: Vorauswahl der Plattformen, markiert ist das jeweilige Ausscheidungskriterium

Nr.	Plattform	Schritt 1: Freelancing- Marktplatz	Schritt 2: Aktivität	Schritt 3: Geografische Ausrichtung	Schritt 4: Tätigkeitsspektrum
1	99Designs				X
2	99freelas			X	
3	appen.com	X			
4	aquent.de				X
5	Axiom			X	
6	Clarity.fm				X
7	clearvoice.com				X
8	Clickworker	X			
9	codeable.io				X
10	CoinWorker		X		
11	Creads			X	
12	Crew	X			
13	Crowdsorce	X			
14	Crowdspring.com				X
15	Designcrowd.com	X			
16	designhill.com				X
17	Diagnose.me				X
18	E-Work	X			
19	Easytask		X		
20	Envato	X			
21	eYeka				X
22	fiverr.com				
23	fivesquid.com				
24	Fobo	X			
25	freelance.de			X	
26	freelancer.com				
27	Freelanceria			X	
28	freelancermap.de			X	
29	Geniuzz		X		
30	gopillar.com				X
31	gulp.de			X	
32	guru.com				
33	Hopwork		X		
34	Image Rights	X			
35	Jovoto.com	X			
36	Kreanod			X	
37	Lancetalent			X	
38	Lass-andere-schreiben			X	
39	Lionbridge	X			
40	Local solo		X		
41	Microtask.com	X			
42	Mila	X			
43	MyLittleJob		X		
44	Napisze prace			X	
45	Onsite.io			X	
46	Pass brains	X			
47	peopleperhour.com				
48	servicescape.com				X
49	Starbytes			X	
50	Stomanie	X			
51	TaskFarm	X			
52	toptal.com				
53	Twago			X	
54	Ukululu		X		
55	upwork.com				
56	Viedit				X
57	Voices				X
58	Vsprace.cz			X	
59	Vsprace.sk			X	
60	writeraccess.com				X
	Verbleibende Samplegröße nach jeweiligem Schritt	44	37	21	7

Quelle: Eigene Recherche und Darstellung.

Anhang Tabelle 2: Zur Verfügung stehende Informationen über Freelancer:innen auf den jeweiligen Plattformen

Zur Verfügung stehende Informationen über den:die Freelancer:in aus Sicht der Auftraggebenden		Fiverr.com	Fivesquid.com	Freelancer.com	Guru.com	Peopleperhour.com	Toptal.com	Upwork.com
Basisinformationen zur Person	Profilbild	X	X	X	X	X	-	X
	Name	X	X	X	X	X	-	X
	Herkunft (Stadt, Land)	X	X	X	X	X	-	X
	Freitextfeld	X	X	X	X	X	-	X
	⌀-Bewertung und Anzahl (Sternerating)	X	X	X	X	X	-	X
	Freitext Einzelbewertungen	X	X	X	X	X	-	X
	Angabe von Skills	X	-	X	X	X	-	X
	Mitglied seit	X	-	X	X	-	-	-
	Sprachen	X	X	-	-	X	-	X
	Externe Erfahrung (z. B. Zertifikate/Bildung)	X	-	X	-	-	-	X
Weitere Informationen	Entlohnung (Stundenlohn/Paketpreis)	X	X	X	X	X	-	X
	Letzte Lieferung/Login	X	X	X	-	X	-	X
	kumulierte Anzahl Aufträge und Auftragsvolumen (Stunden/Geld)	-	-	X	X	X	-	X
	Abschlussrate der Aufträge	-	-	X	-	-	-	X
	Zeitgerechte Lieferung	-	-	X	-	-	-	-
	Lieferung innerhalb Budget	-	-	X	-	-	-	-
	Wiederbeauftragungsquote	-	-	X	-	-	-	-
	Verifications (Identity, Payment, Phone, E-Mail, Social Media)	-	-	X	(X)	-	-	-
	Durchschn. Antwortzeit	X	-	-	-	X	-	-

Quelle: Eigene Recherche und Darstellung.

Anhang Tabelle 3: Zur Verfügung stehende Informationen über Auftraggebende auf den jeweiligen Plattformen

Zur Verfügung stehende Informationen über Auftraggebende aus Sicht der Freelancer:innen		Fiverr.com	Fivesquid.com	Freelancer.com	Guru.com	Peopleperhour.com	Toptal.com	Upwork.com
Basisinformationen zur Person	Profilbild	X	X	-	X	X	-	-
	Name	X	X	-	X	X	-	-
	Herkunft (Stadt, Land)	X	X	X	X	X	-	X
	Bewertung/Weiterempfehlung	X	X	X	X	X	-	-
	kumulierte Anzahl an veröffentlichten Aufträgen und Volumen	-	-	X	X	X	-	X
	Mitglied seit	-	-	X	X	-	-	X
	Sprache	-	X	-	-	-	-	-
Freitext im Profil	-	X	-	-	-	-	-	
Weitere Informationen	Anteil beauftragter Projekte an ausgeschriebenen Projekten	-	-	-	X	-	-	X
	Verifications (Identity, Payment, Phone, E-Mail, Social Media)	-	X	X	-	-	-	-
	Ausstehende Rechnungen	-	-	-	X	-	-	-
	Durchschnittliches Zahlungsziel	-	-	-	X	-	-	-
	Anzahl beauftragter Freelancer	-	-	-	-	X	-	-

Quelle: Eigene Recherche und Darstellung.

Anhang Tabelle 4: Nutzendenzahlen der Plattformen

Plattform	Gründungsjahr	Anzahl registrierter Freelancer:innen - kumuliert	Anzahl registrierter Auftraggebende - kumuliert	Anzahl vermittelte Aufträge - kumuliert	Verhältnis Auftraggebende/ Freelancer:innen	Verhältnis Aufträge/ Freelancer:innen	Verhältnis Aufträge/ Auftraggebenden
Fiverr.com	2010	830.000	5.500.000	50.000.000	6,6	60,2	9,1
Fivesquid.com	2011	-	-	-	-	-	-
Freelancer.com	2009	50.000.000	-	19.000.000	-	0,4	-
Guru.com	1998	3.000.000	-	1.000.000	-	0,3	-
Peopleperhour.com	2007	3.000.000	1.000.000	-	0,3	-	-
Toptal.com	2010	750.000	10.000	30.000	0,0	0,0	3,0
Upwork.com	1999	12.000.000	5.000.000	3.000.000 p.a.	0,4	-	-

Quelle: SEC (2019); Freelancer.com (2021b); Guru.com (2021a); Peopleperhour.com (2021); Toptal.com (2021b); Faircrowd.work (2019), eigene Darstellung und Berechnung.

Anhang Tabelle 5: Registrierungsprozess und Kostenstruktur auf den Plattformen

Plattform	Registrierung	Kostenstruktur für Freelancer:innen		Kostenstruktur für Auftraggebende
		Provision	Mitgliedschaft	
Fiverr.com	- Kostenfreie Registrierung	- 20 % vom Auftragswert		- 5 % des Auftragsvolumens
	- E-Mail-Adresse und Ortsangabe			- +2 \$ Fixgebühr bei Aufträgen <50 \$
Fivesquid.com	- Kostenfreie Registrierung	- 10-20 % vom Auftragswert (abhängig vom Volumen)	- Pro Seller für 20 GBP (einmalig)	- 2,7-8 % vom Auftragswert (abhängig vom Volumen)
	- E-Mail-Adresse und Ortsangabe			
Freelancer.com	- Kostenfreie Registrierung	- Fixpreis-Aufträge: 10 % des Auftragswerts oder 5 \$	- Basic 4,95 \$ p. M.	- Fixpreis-Aufträge: 3 % des Auftragswerts min. 3 \$
	- E-Mail-Adresse, Nutzendename, Passwort	- Stunden-Aufträge: 10 % des Zahlungswertes	- Plus 9,95 \$ p. M.	- Stunden-Aufträge: 3 % des Zahlungswertes
			- Professional 29,95 \$ p. M.	
			- Premier 69,95 \$ p. M.	
Guru.com	- Kostenfreie Registrierung	- Job Fee 5-9 % vom Auftragswert	- Basic+ 11,95 \$	- Zahlungsgebühr 2,9 % vom Zahlungswert
	- E-Mail-Adresse, Nutzendename, Passwort		- Professional 21,95 \$	
			- Business 33,95 \$	
			- Executive 49,95 \$	
Peopleperhour.com	- Kostenfreie Registrierung	- 3,5-20 % vom Auftragswert (abhängig vom Volumen)		- 0,6 GBP +10 % des Zahlungswertes
	- E-Mail-Adresse, Nutzendename, Passwort			
	- Vor Zugriff auf Plattform muss Profil vollständig ausgefüllt werden.			
	- Fast Track Fee (schnelle Bearbeitung der Bewerbung) 9,95-14,95\$			
Toptal.com	- Bewerbung ist kostenfrei			- 500 \$ Einlage zu Beginn
	- 5-stufiger Bewerbungsprozess der 2-5 Wochen dauert und den nur rund 3% der Bewerber abschließen			
	1. Sprach- und Persönlichkeitstests			
	2. Fähigkeitentest			
	3. Bewerbungsgespräch			
	4. Testprojekte			
Upwork.com	- Kostenfreie Registrierung	- 5-20 % vom Auftragswert (abhängig vom Volumen)	- Plus 14,99 \$ p. M.	- 3 % Zahlungsgebühr
	- E-Mail-Adresse, Nutzendename, Passwort			- Plus Membership 49,99 \$ p. M.

Quelle: Eigene Darstellung; Fiverr.com (2020), Fivesquid.com (2020); Upwork.com (2020a); Freelancer.com (2022f, 2022j); Guru.com (2021b); Peopleperhour.com (2019); Toptal.com (2021a).

Anhang Tabelle 6: Übersichtstabelle zu den Variablen der Freelancer:innen

Variable	Mittelwert	Median	Standard- abweichung	Min	Max	
Abhängige Variablen						
<i>Beauftrag (Dummy)</i>	0,073	0,000	0,260	0,000	1,000	
<i>Angebotspreis (EUR)</i>	104,8	45,6	128,2	1,2	1.809,8	
Zentrale unabhängige Variable						
<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	0,238	0,000	0,426	0,000	1,000	
<i>Rang (1-21)</i>	9,7	9,0	5,7	1,0	21,0	
Kontrollvariablen						
Bidlist	<i>Lieferzeit (Tage)</i>	4,4	3,4	4,4	1,0	300,0
	<i>Rating (0-5)</i>	4,0	4,9	1,9	0,0	5,0
	<i>Bewertungen (Anzahl)</i>	190,1	29,0	448,9	0,0	5.787,0
	<i>Kum. Plattformeinkommen (0-10)</i>	4,6	5,2	2,8	0,0	10,0
	<i>Entwickeltes Land (Dummy)</i>	0,069	0,000	0,253	0,000	1,000
	<i>Schwellenland (Dummy)</i>	0,806	1,000	0,396	0,000	1,000
	<i>Entwicklungsland (Dummy)</i>	0,126	0,000	0,332	0,000	1,000
Performance	<i>Auftragsabschlussrate (%)</i>	84,9	98,0	31,6	0,0	100,0
	<i>Einhaltung des Budgets (%)</i>	79,6	92,0	31,6	0,0	100,0
	<i>Einhaltung der Lieferzeit (%)</i>	79,5	92,0	31,6	0,0	100,0
	<i>Wiederbeauftragungquote (%)</i>	11,0	10,0	9,6	0,0	100,0
Weitere plattformgenerierte Variablen	<i>Weiterempfehlungen (Anzahl)</i>	17,6	3,0	42,7	0,0	852,0
	<i>Verifizierungsindex (0-1)</i>	0,7	0,7	0,2	0,2	1,0
Externe Variablen	<i>Plattformerfahrung (Jahre)</i>	4,4	4,0	3,7	0,0	21,0
	<i>Absolvierte Tests (Anzahl)</i>	1,7	1,0	1,7	0,0	6,0
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>	0,470	0,000	0,499	0,000	1,000
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>	0,808	1,000	0,394	0,000	1,000
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>	0,056	0,000	0,230	0,000	1,000
	<i>Bildungsniveau Mittel (Dummy)</i>	0,033	0,000	0,177	0,000	1,000
	<i>Bildungsniveau Niedrig (Dummy)</i>	0,661	1,000	0,473	0,000	1,000
	<i>Zertifikate (Anzahl)</i>	0,6	0,0	0,8	0,0	3,0
	<i>Erfahrung (Anzahl)</i>	1,0	1,0	1,0	0,0	3,0
	<i>Publikationen (Anzahl)</i>	0,3	0,0	0,8	0,0	17,0

Tabelle basiert auf dem bereinigten Datensatz mit 31.316 Angeboten.

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 7: Charakteristika der Freelancer:innen nach dem Geschlecht für die Tätigkeitskategorie „Websites, IT & Software“

Tätigkeitskategorie: Websites, IT & Software		Gesamt	Frauen	Männer	Differenz (F-M)
Variable					
Abhängige Variablen					
	<i>Beauftragt (Dummy)</i>	0,076 (0,266)	0,066 (0,248)	0,079 (0,269)	-0,013 **
	<i>Angebotspreis (EUR)</i>	120,0 (137,3)	128,7 (140,5)	118,3 (136,5)	10,5 ***
Zentrale unabhängige Variable					
	<i>Rang (1-21)</i>	9,4 (5,7)	10,0 (5,6)	9,3 (5,7)	0,7 ***
Kontrollvariablen					
Bidlist	<i>Lieferzeit (Tage)</i>	5,0 (5,2)	5,1 (4,5)	4,9 (5,3)	0,2 *
	<i>Rating (0-5)</i>	4,0 (1,9)	3,9 (1,9)	4,0 (1,9)	-0,1 **
	<i>Bewertungen (Anzahl)</i>	118,4 (279,0)	124,0 (287,9)	117,2 (277,1)	6,8
	<i>Kum. Plattformeinkommen (0-10)</i>	4,4 (2,8)	4,5 (2,8)	4,4 (2,8)	0,1
	<i>Entwickeltes Land (Dummy)</i>	0,065 (0,247)	0,065 (0,246)	0,066 (0,247)	-0,001
	<i>Schwellenland (Dummy)</i>	0,826 (0,379)	0,838 (0,368)	0,823 (0,382)	0,015 *
	<i>Entwicklungsland (Dummy)</i>	0,109 (0,312)	0,097 (0,296)	0,111 (0,315)	-0,014 **
Performance	<i>Auftragsabschlussrate (%)</i>	85,7 (29,9)	84,4 (31,3)	86,0 (29,6)	-1,6 **
	<i>Einhaltung des Budgets (%)</i>	81,2 (30,5)	79,2 (31,3)	81,6 (30,3)	-2,4 ***
	<i>Einhaltung der Lieferzeit (%)</i>	80,8 (30,4)	78,5 (31,5)	81,3 (30,1)	-2,7 ***
	<i>Wiederbeauftragungsquote (%)</i>	11,6 (10,4)	10,9 (9,7)	11,8 (10,6)	-0,9 ***
Weitere plattformgenerierte Variablen	<i>Weiterempfehlungen (Anzahl)</i>	13,1 (31,7)	17,7 (34,6)	12,1 (31,0)	5,6 ***
	<i>Verifizierungsindex (0-1)</i>	0,7 (0,2)	0,7 (0,2)	0,7 (0,2)	0,0 ***
	<i>Plattformerfahrung (Jahre)</i>	4,6 (4,0)	3,9 (3,5)	4,7 (4,1)	-0,8 ***
	<i>Absolvierte Tests (Anzahl)</i>	1,7 (1,8)	1,5 (1,7)	1,7 (1,8)	-0,2 ***
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>	0,531 (0,499)	0,406 (0,491)	0,556 (0,497)	-0,151 ***
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>	0,833 (0,373)	0,708 (0,455)	0,859 (0,348)	-0,150 ***
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>	0,649 (0,477)	0,650 (0,477)	0,649 (0,477)	0,001
	<i>Bildungsniveau Mittel (Dummy)</i>	0,031 (0,174)	0,037 (0,188)	0,030 (0,171)	0,007 *
	<i>Bildungsniveau Niedrig (Dummy)</i>	0,060 (0,238)	0,073 (0,259)	0,057 (0,233)	0,015 ***
	<i>Zertifikate (Anzahl)</i>	0,6 (0,9)	0,5 (0,8)	0,6 (0,9)	-0,1 ***
	<i>Erfahrung (Anzahl)</i>	1,0 (1,0)	0,8 (0,9)	1,0 (1,0)	-0,2 ***
	<i>Publikationen (Anzahl)</i>	0,2 (0,6)	0,3 (0,7)	0,2 (0,6)	0,0
Anzahl an Beobachtungen		14.598	2.509	12.089	

Angegeben ist der Mittelwert und in Klammern die Standardabweichung.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 8: Charakteristika der Auftraggebenden und Aufträge nach dem Geschlecht der Freelancer:innen für die Tätigkeitskategorie „Websites, IT & Software“

Variable	Gesamt	Frauen	Männer	Differenz (F-M)
Auftraggebende				
Rating (0-5)	3,5 (2,3)	3,4 (2,3)	3,5 (2,3)	-0,1
Bewertungen (Anzahl)	18,2 (47,8)	17,1 (47,7)	18,5 (47,8)	-1,4
Entwickeltes Land (Dummy)	0,658 (0,474)	0,651 (0,477)	0,660 (0,474)	-0,009
Schwellenland (Dummy)	0,316 (0,465)	0,328 (0,470)	0,313 (0,464)	0,015
Entwicklungsland (Dummy)	0,026 (0,159)	0,021 (0,142)	0,027 (0,162)	-0,006 *
Verifizierungsindex (0-1)	0,7 (0,3)	0,7 (0,3)	0,7 (0,3)	0,0
Aufträge				
Budget Minimum (EUR)	41,6 (64,9)	45,4 (68,5)	40,8 (64,1)	4,6 ***
Budget Maximum (EUR)	3.200,6 (54.810,0)	1.792,6 (39.896,8)	3.492,8 (57.418,9)	-1.700,3
Stundenbasierter Auftrag (Dummy)	0,125 (0,331)	0,126 (0,332)	0,125 (0,331)	0,001
Anzahl an Beobachtungen	14.598	2.509	12.089	
Angegeben ist der Mittelwert und in Klammern die Standardabweichung				
Statistische Signifikanz: *10%, **5%, ***1%-Level				

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 9: Charakteristika der Freelancer:innen nach dem Geschlecht für die Tätigkeitskategorie „Design, Media & Architecture“

Tätigkeitskategorie: Design, Media & Architecture		Gesamt	Frauen	Männer	Differenz (F-M)
Variable					
Abhängige Variablen					
	<i>Beauftragt (Dummy)</i>	0,068 (0,251)	0,061 (0,240)	0,070 (0,256)	-0,009
	<i>Angebotspreis (EUR)</i>	87,0 (103,3)	81,0 (96,1)	89,5 (106,0)	-8,5 ***
Zentrale unabhängige Variable					
	<i>Rang (1-21)</i>	10,5 (5,8)	11,3 (5,6)	10,2 (5,8)	1,1 ***
Kontrollvariablen					
Bidlist	<i>Lieferzeit (Tage)</i>	3,3 (3,1)	2,9 (2,7)	3,5 (3,2)	-0,7 ***
	<i>Rating (0-5)</i>	4,5 (1,4)	4,6 (1,2)	4,4 (1,5)	0,1 ***
	<i>Bewertungen (Anzahl)</i>	453,0 (749,8)	409,8 (505,7)	471,0 (830,0)	-61,2 ***
	<i>Kum. Plattformeinkommen (0-10)</i>	5,8 (2,5)	6,0 (2,3)	5,7 (2,6)	0,3 ***
	<i>Entwickeltes Land (Dummy)</i>	0,044 (0,205)	0,049 (0,215)	0,042 (0,200)	0,007
	<i>Schwellenland (Dummy)</i>	0,839 (0,368)	0,926 (0,262)	0,802 (0,398)	0,124 ***
	<i>Entwicklungsland (Dummy)</i>	0,117 (0,322)	0,025 (0,157)	0,156 (0,363)	-0,131 ***
Performance	<i>Auftragsabschlussrate (%)</i>	92,2 (23,0)	93,6 (19,8)	91,6 (24,1)	2,0 ***
	<i>Einhaltung des Budgets (%)</i>	86,3 (22,8)	86,4 (19,4)	86,3 (24,1)	0,2
	<i>Einhaltung der Lieferzeit (%)</i>	85,9 (22,9)	86,2 (19,4)	85,8 (24,2)	0,4
	<i>Wiederbeauftragungsquote (%)</i>	10,8 (7,4)	9,9 (6,2)	11,2 (7,8)	-1,2 ***
Weitere plattformgenerierte Variablen	<i>Weiterempfehlungen (Anzahl)</i>	34,2 (68,3)	38,3 (51,8)	32,5 (74,1)	5,8 ***
	<i>Verifizierungsindex (0-1)</i>	0,8 (0,2)	0,7 (0,1)	0,8 (0,2)	-0,1 ***
	<i>Plattformerfahrung (Jahre)</i>	5,1 (3,3)	4,5 (2,5)	5,4 (3,6)	-0,9 ***
	<i>Absolvierte Tests (Anzahl)</i>	1,8 (1,6)	1,4 (1,2)	2,0 (1,7)	-0,7 ***
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>	0,364 (0,481)	0,212 (0,409)	0,427 (0,495)	-0,215 ***
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>	0,959 (0,198)	0,975 (0,157)	0,953 (0,213)	0,022 ***
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>	0,689 (0,463)	0,660 (0,474)	0,701 (0,458)	-0,041 ***
	<i>Bildungsniveau Mittel (Dummy)</i>	0,028 (0,166)	0,034 (0,181)	0,026 (0,159)	0,008 *
	<i>Bildungsniveau Niedrig (Dummy)</i>	0,040 (0,196)	0,061 (0,240)	0,031 (0,173)	0,030 ***
	<i>Zertifikate (Anzahl)</i>	0,7 (0,8)	0,6 (0,7)	0,7 (0,8)	-0,1 ***
	<i>Erfahrung (Anzahl)</i>	1,0 (0,9)	0,9 (0,8)	1,1 (0,9)	-0,1 ***
	<i>Publikationen (Anzahl)</i>	0,3 (0,6)	0,3 (0,6)	0,3 (0,6)	-0,1 ***
Anzahl an Beobachtungen		6.624	1.947	4.677	

Angegeben ist der Mittelwert und in Klammern die Standardabweichung.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 10: Charakteristika der Auftraggebenden und Aufträge nach dem Geschlecht der Freelancer:innen für die Tätigkeitskategorie „Design, Media & Architecture“

Variable	Gesamt	Frauen	Männer	Differenz (F-M)
Auftraggebende				
Rating (0-5)	2,7 (2,5)	2,6 (2,5)	2,8 (2,5)	-0,2 ***
Bewertungen (Anzahl)	16,7 (55,2)	16,4 (60,7)	16,7 (52,8)	-0,3
Entwickeltes Land (Dummy)	0,685 (0,465)	0,667 (0,471)	0,693 (0,461)	-0,025 **
Schwellenland (Dummy)	0,290 (0,454)	0,309 (0,462)	0,282 (0,450)	0,027 **
Entwicklungsland (Dummy)	0,025 (0,156)	0,024 (0,152)	0,025 (0,157)	-0,002
Verifizierungsindex (0-1)	0,6 (0,3)	0,6 (0,3)	0,6 (0,3)	0,0 ***
Aufträge				
Budget Minimum (EUR)	34,9 (57,2)	33,5 (54,4)	35,5 (58,3)	-2,0
Budget Maximum (EUR)	10.276,5 (100.053,4)	6.323,8 (78.272,1)	11.922,0 (107.796,4)	-5.598,2 **
Stundenbasierter Auftrag (Dummy)	0,079 (0,270)	0,053 (0,225)	0,090 (0,286)	-0,037 ***
Anzahl an Beobachtungen	6.624	1.947	4.677	
Angegeben ist der Mittelwert und in Klammern die Standardabweichung				
Statistische Signifikanz: *10%, **5%, ***1%-Level				

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 11: Charakteristika der Freelancer:innen nach dem Geschlecht für die Tätigkeitskategorie „Writing & Content“

Tätigkeitskategorie: Writing & Content		Gesamt	Frauen	Männer	Differenz (F-M)
Variable					
Abhängige Variablen					
	<i>Beauftragt (Dummy)</i>	0,068 (0,251)	0,072 (0,259)	0,065 (0,247)	0,007
	<i>Angebotspreis (EUR)</i>	78,8 (112,2)	69,9 (101,8)	83,5 (117,1)	-13,6 ***
Zentrale unabhängige Variable					
	<i>Rang (1-21)</i>	10,0 (5,8)	10,6 (5,6)	9,7 (5,9)	0,9 ***
Kontrollvariablen					
Bidlist	<i>Lieferzeit (Tage)</i>	3,8 (3,6)	3,5 (3,1)	3,9 (3,8)	-0,4 ***
	<i>Rating (0-5)</i>	3,7 (2,1)	3,7 (2,1)	3,7 (2,1)	0,0
	<i>Bewertungen (Anzahl)</i>	158,7 (334,2)	127,8 (245,4)	175,2 (372,0)	-47,4 ***
	<i>Kum. Plattformeinkommen (0-10)</i>	4,2 (2,9)	4,1 (2,8)	4,2 (3,0)	-0,1 *
	<i>Entwickeltes Land (Dummy)</i>	0,102 (0,303)	0,135 (0,342)	0,085 (0,279)	0,050 ***
	<i>Schwellenland (Dummy)</i>	0,734 (0,442)	0,731 (0,443)	0,736 (0,441)	-0,005
	<i>Entwicklungsland (Dummy)</i>	0,163 (0,370)	0,134 (0,341)	0,179 (0,384)	-0,046 ***
Performance	<i>Auftragsabschlussrate (%)</i>	79,3 (36,7)	79,4 (37,3)	79,2 (36,4)	0,2
	<i>Einhaltung des Budgets (%)</i>	73,3 (35,6)	73,2 (36,1)	73,3 (35,3)	-0,1
	<i>Einhaltung der Lieferzeit (%)</i>	74,1 (36,0)	73,8 (36,7)	74,2 (35,7)	-0,4
	<i>Wiederbeauftragungsquote (%)</i>	10,6 (9,4)	10,4 (9,6)	10,7 (9,2)	-0,2
Weitere plattformgenerierte Variablen	<i>Weiterempfehlungen (Anzahl)</i>	14,8 (28,5)	15,8 (28,1)	14,3 (28,7)	1,4 *
	<i>Verifizierungsindex (0-1)</i>	0,6 (0,2)	0,6 (0,2)	0,7 (0,2)	-0,1 ***
	<i>Plattformerfahrung (Jahre)</i>	3,8 (3,4)	3,4 (3,1)	4,0 (3,6)	-0,6 ***
	<i>Absolvierte Tests (Anzahl)</i>	1,6 (1,7)	1,3 (1,5)	1,7 (1,8)	-0,5 ***
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>	0,390 (0,488)	0,415 (0,493)	0,377 (0,485)	0,039 ***
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>	0,766 (0,423)	0,817 (0,386)	0,739 (0,439)	0,078 ***
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>	0,674 (0,469)	0,645 (0,479)	0,689 (0,463)	-0,045 ***
	<i>Bildungsniveau Mittel (Dummy)</i>	0,037 (0,188)	0,034 (0,182)	0,038 (0,191)	-0,004
	<i>Bildungsniveau Niedrig (Dummy)</i>	0,056 (0,230)	0,064 (0,245)	0,052 (0,222)	0,012 *
	<i>Zertifikate (Anzahl)</i>	0,7 (0,9)	0,6 (0,9)	0,7 (0,9)	-0,2 ***
	<i>Erfahrung (Anzahl)</i>	0,9 (0,9)	0,8 (1,0)	1,0 (0,9)	-0,1 ***
	<i>Publikationen (Anzahl)</i>	0,4 (1,1)	0,2 (0,9)	0,4 (1,2)	-0,2 ***
Anzahl an Beobachtungen		5.603	1.950	3.653	

Angegeben ist der Mittelwert und in Klammern die Standardabweichung.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 12: Charakteristika der Auftraggebenden und Aufträge nach dem Geschlecht der Freelancer:innen für die Tätigkeitskategorie „Writing & Content“

Variable	Gesamt	Frauen	Männer	Differenz (F-M)
Auftraggebende				
Rating (0-5)	2,7 (2,5)	2,7 (2,5)	2,7 (2,5)	0,0
Bewertungen (Anzahl)	27,5 (105,1)	28,4 (112,0)	27,0 (101,2)	1,4
Entwickeltes Land (Dummy)	0,579 (0,494)	0,570 (0,495)	0,584 (0,493)	-0,014
Schwellenland (Dummy)	0,386 (0,487)	0,396 (0,489)	0,381 (0,486)	0,015
Entwicklungsland (Dummy)	0,035 (0,183)	0,034 (0,182)	0,035 (0,184)	-0,001
Verifizierungsindex (0-1)	0,7 (0,3)	0,7 (0,3)	0,7 (0,3)	0,0 **
Aufträge				
Budget Minimum (EUR)	37,8 (63,4)	33,8 (57,2)	39,9 (66,3)	-6,1 ***
Budget Maximum (EUR)	2.658,6 (49.920,9)	2.203,1 (45.249,6)	2.901,8 (52.248,1)	-698,7
Stundenbasierter Auftrag (Dummy)	0,157 (0,364)	0,146 (0,353)	0,163 (0,369)	-0,017
Anzahl an Beobachtungen	5.603	1.950	3.653	
Angegeben ist der Mittelwert und in Klammern die Standardabweichung				
Statistische Signifikanz: *10%, **5%, ***1%-Level				

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 13: Regressionsergebnisse zur Untersuchung des Zusammenhangs zwischen Rängen und den unabhängigen und Kontrollvariablen

Abhängige Variable: Rang (1-21)		1	2	3	4	5
<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>		0,940 *** (0,075)	0,979 *** (0,072)	0,963 *** (0,072)	0,863 *** (0,073)	0,853 *** (0,073)
Bidlist	<i>Rating (0-1)</i>		0,732 *** (0,124)	1,016 *** (0,148)	0,647 *** (0,152)	0,627 *** (0,152)
	<i>Bewertungen (Anzahl in 100)</i>		-0,093 *** (0,006)	-0,094 *** (0,006)	-0,047 *** (0,007)	-0,051 *** (0,007)
	<i>Kum. Plattformeinkommen (0-1)</i>		-6,664 *** (0,188)	-6,552 *** (0,191)	-5,274 *** (0,224)	-5,251 *** (0,225)
	<i>Schwellenland (Dummy)</i>		0,160 (0,123)	0,155 (0,123)	0,120 (0,123)	0,060 (0,123)
	<i>Entwicklungsland (Dummy)</i>		-0,124 (0,145)	-0,110 (0,146)	0,070 (0,145)	0,019 (0,146)
Performance	<i>Auftragsabschlussrate (%)</i>			0,076 (0,267)	0,056 (0,269)	-0,014 (0,269)
	<i>Einhaltung des Budgets (%)</i>			0,302 (0,351)	0,438 (0,350)	0,470 (0,351)
	<i>Einhaltung der Lieferzeit (%)</i>			-0,793 ** (0,359)	-0,564 (0,357)	-0,574 (0,358)
	<i>Wiederbeauftragungsquote (%)</i>			-1,064 *** (0,358)	-0,156 (0,361)	-0,189 (0,361)
Weitere plattform- generierte Variablen	<i>Weiterempfehlungen (Anzahl in 100)</i>				-1,366 *** (0,093)	-1,312 *** (0,093)
	<i>Verifizierungsindex (0-1)</i>				1,020 *** (0,210)	0,911 *** (0,213)
	<i>Plattformerfahrung (Jahre)</i>				-0,055 *** (0,011)	-0,054 *** (0,011)
	<i>Absolvierte Tests (Anzahl)</i>				-0,155 *** (0,024)	-0,141 *** (0,025)
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>				-1,047 *** (0,068)	-1,021 *** (0,068)
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>				0,331 *** (0,078)	0,326 *** (0,078)
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>					0,462 *** (0,083)
	<i>Bildungsniveau Mittel (Dummy)</i>					-0,214 (0,186)
	<i>Bildungsniveau Niedrig (Dummy)</i>					-0,061 (0,142)
	<i>Zertifikate (Anzahl)</i>					-0,104 ** (0,042)
	<i>Erfahrung (Anzahl)</i>					-0,026 (0,038)
	<i>Publikationen (Anzahl)</i>					-0,129 *** (0,043)
Konstante		9,497 *** (0,037)	12,014 *** (0,128)	12,188 *** (0,139)	11,711 *** (0,173)	11,692 *** (0,177)
Anzahl an Angeboten		31.316	31.316	31.316	31.316	31.316
R ²		0,005	0,119	0,120	0,136	0,137
R ² Adj		0,005	0,119	0,120	0,135	0,137

Angegeben sind die jeweiligen Regressionskoeffizienten mit cluster robusten Standardfehlern.
 Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 14: Übersichtstabelle zu den Variablen der Auftraggebenden und Aufträge nach Tätigkeitskategorien

Tätigkeitskategorie	Variable	Mittelwert	Median	Standard- abweichung	Min	Max
Insgesamt	Auftraggebende					
	Rating (0-5)	3,1	5,0	2,4	0,0	5,0
	Bewertungen (Anzahl)	19,6	2,0	65,9	0,0	1.024,0
	Entwickeltes Land (Dummy)	0,646	1,000	0,478	0,000	1,000
	Schwellenland (Dummy)	0,326	0,000	0,469	0,000	1,000
	Entwicklungsland (Dummy)	0,028	0,000	0,166	0,000	1,000
	Verifizierungsindex (0-1)	0,7	0,8	0,3	0,2	1,0
	Aufträge					
	Budget Minimum (EUR)	40,8	20,7	65,2	1,2	320,0
	Budget Maximum (EUR)	5.701,9	155,6	74.108,4	1,6	999.999,0
	Stundenbasierter Auftrag (Dummy)	0,130	0,000	0,336	0,000	1,000
Websites, IT & Software	Auftraggebende					
	Rating (0-5)	3,5	5,0	2,3	0,0	5,0
	Bewertungen (Anzahl)	18,2	3,0	47,8	0,0	623,0
	Entwickeltes Land (Dummy)	0,658	1,000	0,474	0,000	1,000
	Schwellenland (Dummy)	0,316	0,000	0,465	0,000	1,000
	Entwicklungsland (Dummy)	0,026	0,000	0,159	0,000	1,000
	Verifizierungsindex (0-1)	0,7	0,8	0,3	0,2	1,0
	Aufträge					
	Budget Minimum (EUR)	41,6	23,8	64,9	1,2	320,0
	Budget Maximum (EUR)	3.200,6	169,5	54.810,0	2,8	999.999,0
	Stundenbasierter Auftrag (Dummy)	0,125	0,000	0,331	0,000	1,000
Design, Media & Architecture	Auftraggebende					
	Rating (0-5)	2,7	4,9	2,5	0,0	5,0
	Bewertungen (Anzahl)	16,7	1,0	55,2	0,0	662,0
	Entwickeltes Land (Dummy)	0,685	1,000	0,465	0,000	1,000
	Schwellenland (Dummy)	0,290	0,000	0,454	0,000	1,000
	Entwicklungsland (Dummy)	0,025	0,000	0,156	0,000	1,000
	Verifizierungsindex (0-1)	0,6	0,8	0,3	0,2	1,0
	Aufträge					
	Budget Minimum (EUR)	34,9	19,4	57,2	1,2	299,8
	Budget Maximum (EUR)	10.276,5	156,8	100.053,4	4,7	999.999,0
	Stundenbasierter Auftrag (Dummy)	0,079	0,000	0,270	0,000	1,000
Writing & Content	Auftraggebende					
	Rating (0-5)	2,7	4,8	2,5	0,0	5,0
	Bewertungen (Anzahl)	27,5	1,0	105,1	0,0	1.009,0
	Entwickeltes Land (Dummy)	0,579	1,000	0,494	0,000	1,000
	Schwellenland (Dummy)	0,386	0,000	0,487	0,000	1,000
	Entwicklungsland (Dummy)	0,035	0,000	0,183	0,000	1,000
	Verifizierungsindex (0-1)	0,7	0,8	0,3	0,2	1,0
	Aufträge					
	Budget Minimum (EUR)	37,8	17,7	63,4	1,2	320,0
	Budget Maximum (EUR)	2.658,6	53,7	49.920,9	1,6	999.999,0
	Stundenbasierter Auftrag (Dummy)	0,157	0,000	0,364	0,000	1,000

Der Wert 999.999 beim maximalen Budget wurde eingetragen, sofern beim Auftrag keine Obergrenze angegeben wurde.

Tabelle basiert auf dem bereinigten Datensatz mit 31.316 Angeboten.

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 15: Ergebnisse der bedingten logistischen Regression zur Analyse der Beauftragungswahrscheinlichkeit mit Kontrollvariablen

Abhängige Variable: Beauftrag (Dummy)		5	6	7	8
Zentrale unabhängige Variablen					
	<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	-0,052 (0,100)	-0,045 (0,100)	-0,039 (0,101)	-0,038 (0,101)
	<i>Rang (1-21)</i>	-0,080 *** (0,008)	-0,076 *** (0,008)	-0,078 *** (0,008)	-0,079 *** (0,008)
	<i>Geschlecht x Rang</i>	0,007 (0,010)	0,007 (0,010)	0,009 (0,010)	0,009 (0,010)
Kontrollvariablen					
Bidlist	<i>Angebotspreis (in 100 EUR)</i>	-0,252 *** (0,047)	-0,262 *** (0,048)	-0,261 *** (0,049)	-0,260 *** (0,049)
	<i>Lieferzeit (Tage)</i>	-0,036 *** (0,008)	-0,033 *** (0,008)	-0,030 *** (0,008)	-0,029 *** (0,008)
	<i>Rating (0-1)</i>	0,564 *** (0,099)	-0,113 (0,107)	-0,210 * (0,109)	-0,210 * (0,109)
	<i>Bewertungen (Anzahl in 100)</i>	0,026 *** (0,005)	0,026 *** (0,005)	0,031 *** (0,005)	0,032 *** (0,005)
	<i>Kum. Plattformeinkommen (0-1)</i>	-0,892 *** (0,221)	-0,927 *** (0,222)	-0,844 *** (0,237)	-0,852 *** (0,237)
	<i>Schwellenland (Dummy)</i>	-0,485 *** (0,085)	-0,474 *** (0,086)	-0,422 *** (0,087)	-0,423 *** (0,088)
	<i>Entwicklungsland (Dummy)</i>	-0,239 ** (0,101)	-0,258 ** (0,102)	-0,281 *** (0,103)	-0,280 *** (0,104)
Performance	<i>Auftragsabschlussrate (%)</i>		0,896 *** (0,215)	0,671 *** (0,217)	0,675 *** (0,217)
	<i>Einhaltung des Budgets (%)</i>		0,153 (0,256)	0,193 (0,262)	0,174 (0,262)
	<i>Einhaltung der Lieferzeit (%)</i>		0,564 ** (0,266)	0,489 * (0,271)	0,511 * (0,271)
	<i>Wiederbeauftragungsquote (%)</i>		0,597 ** (0,235)	0,486 ** (0,244)	0,477 * (0,244)
Weitere plattform- generierte Variablen	<i>Weiterempfehlungen (Anzahl in 100)</i>			0,117 ** (0,051)	0,113 ** (0,051)
	<i>Verifizierungsindex (0-1)</i>			0,397 ** (0,164)	0,385 ** (0,166)
	<i>Plattformerfahrung (Jahre)</i>			-0,024 *** (0,009)	-0,023 *** (0,009)
	<i>Absolvierte Tests (Anzahl)</i>			-0,037 ** (0,018)	-0,035 * (0,018)
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>			0,503 *** (0,052)	0,498 *** (0,053)
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>			0,373 *** (0,081)	0,371 *** (0,081)
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>				-0,065 (0,062)
	<i>Bildungsniveau Mittel (Dummy)</i>				-0,090 (0,134)
	<i>Bildungsniveau Niedrig (Dummy)</i>				-0,091 (0,114)
	<i>Zertifikate (Anzahl)</i>				0,009 (0,031)
	<i>Erfahrung (Anzahl)</i>				0,025 (0,028)
	<i>Publikationen (Anzahl)</i>				-0,056 (0,034)
Anzahl an Angeboten		31.316	31.316	31.316	31.316
Anzahl an Aufträgen		2.274	2.274	2.274	2.274
Log-Likelihood		-5.572	-5.485	-5.412	-5.409
Likelihood Ratio Test (zum Nullmodell)		366,1 ***	543,1 ***	699,9 ***	706,0 ***
Likelihood Ratio Test (zum vorherigen Modell)		-	174,4 ***	147,0 ***	4,8

Angegeben sind die jeweiligen Regressionskoeffizienten der bedingten logistischen Regression.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 16: Ergebnisse der bedingten logistischen Regression zur Analyse der Beauftragungswahrscheinlichkeit auf Ebene der Tätigkeitskategorien

Modell 8 - Tätigkeitskategorien		Gesamt	Websites, IT & Software	Design, Media & Architecture	Writing & Content
Abhängige Variable: Beauftragte (Dummy)					
Zentrale unabhängige Variablen					
	<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	-0,038 (0,101)	0,030 (0,166)	0,232 (0,225)	-0,349 (0,221)
	<i>Rang (1-21)</i>	-0,079 *** (0,008)	-0,074 *** (0,012)	-0,086 *** (0,019)	-0,102 *** (0,022)
	<i>Geschlecht x Rang</i>	0,009 (0,010)	-0,005 (0,017)	-0,019 (0,021)	0,059 *** (0,022)
Kontrollvariablen					
Bidlist	<i>Angebotspreis (in 100 EUR)</i>	-0,260 *** (0,049)	-0,422 *** (0,069)	-0,265 * (0,137)	-0,152 (0,121)
	<i>Lieferzeit (Tage)</i>	-0,029 *** (0,008)	-0,055 *** (0,012)	0,000 (0,022)	0,026 (0,017)
	<i>Rating (0-1)</i>	-0,210 * (0,109)	-0,164 (0,149)	0,385 (0,365)	-0,929 *** (0,272)
	<i>Bewertungen (Anzahl in 100)</i>	0,032 *** (0,005)	0,050 *** (0,013)	0,028 *** (0,008)	0,040 ** (0,019)
	<i>Kum. Plattformeinkommen (0-1)</i>	-0,852 *** (0,237)	-0,885 *** (0,329)	-1,820 *** (0,667)	-0,302 (0,586)
	<i>Schwellenland (Dummy)</i>	-0,423 *** (0,088)	-0,194 (0,133)	-0,424 * (0,240)	-0,861 *** (0,181)
	<i>Entwicklungsland (Dummy)</i>	-0,280 *** (0,104)	-0,042 (0,158)	-0,040 (0,271)	-0,887 *** (0,215)
Performance	<i>Auftragsabschlussrate (%)</i>	0,675 *** (0,217)	0,679 ** (0,306)	1,341 ** (0,642)	1,091 ** (0,510)
	<i>Einhaltung des Budgets (%)</i>	0,174 (0,262)	0,141 (0,359)	-0,391 (0,824)	0,072 (0,628)
	<i>Einhaltung der Lieferzeit (%)</i>	0,511 * (0,271)	0,450 (0,368)	-0,040 (0,830)	0,683 (0,630)
	<i>Wiederbeauftragungsquote (%)</i>	0,477 * (0,244)	0,407 (0,327)	0,472 (0,713)	1,151 ** (0,554)
Weitere plattform-generierte Variablen	<i>Weiterempfehlungen (Anzahl in 100)</i>	0,113 ** (0,051)	-0,131 (0,137)	0,197 *** (0,062)	-0,018 (0,245)
	<i>Verifizierungsindex (0-1)</i>	0,385 ** (0,166)	0,576 ** (0,238)	0,269 (0,411)	0,392 (0,398)
	<i>Plattformerfahrung (Jahre)</i>	-0,023 *** (0,009)	-0,017 (0,012)	-0,084 *** (0,025)	0,016 (0,023)
	<i>Absolvierte Tests (Anzahl)</i>	-0,035 * (0,018)	-0,042 (0,026)	-0,021 (0,044)	-0,052 (0,048)
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>	0,498 *** (0,053)	0,525 *** (0,076)	0,511 *** (0,124)	0,306 ** (0,128)
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>	0,371 *** (0,081)	0,337 *** (0,121)	1,084 *** (0,400)	0,181 (0,179)
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>	-0,065 (0,062)	-0,015 (0,086)	-0,125 (0,148)	0,002 (0,159)
	<i>Bildungsniveau Mittel (Dummy)</i>	-0,090 (0,134)	-0,345 (0,219)	0,321 (0,297)	0,006 (0,308)
	<i>Bildungsniveau Niedrig (Dummy)</i>	-0,091 (0,114)	-0,162 (0,159)	-0,105 (0,306)	0,012 (0,276)
	<i>Zertifikate (Anzahl)</i>	0,009 (0,031)	-0,031 (0,046)	0,093 (0,072)	-0,003 (0,076)
	<i>Erfahrung (Anzahl)</i>	0,025 (0,028)	-0,028 (0,040)	0,072 (0,068)	0,014 (0,070)
	<i>Publikationen (Anzahl)</i>	-0,056 (0,034)	-0,023 (0,058)	0,130 (0,095)	-0,165 ** (0,078)
Anzahl an Angeboten		31.316	14.598	6.624	5.603
Anzahl an Aufträgen		2.274	1.115	448	380
Anzahl beauftragter Frauen		502	165	119	141
Likelihood Ratio Test (zum Nullmodell)		706,0 ***	307,8 ***	179,8 ***	186,2 ***

Angegeben sind die jeweiligen Regressionskoeffizienten der bedingten logistischen Regression.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 17: Ergebnisse der Fixed Effect Regression zur Analyse der Angebotspreise mit Kontrollvariablen

Abhängige Variable: log(Angebotspreis (in 100 EUR))		1	2	3	4	5
Zentrale unabhängige Variable						
	<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	-0,023 *** (0,007)	-0,016 ** (0,007)	-0,014 ** (0,007)	0,008 (0,006)	0,008 (0,006)
Kontrollvariablen						
Bidlist	<i>Rang (1-21)</i>		-0,007 *** (0,001)	-0,007 *** (0,001)	-0,005 *** (0,001)	-0,005 *** (0,001)
	<i>Lieferzeit (Tage)</i>		0,029 *** (0,005)	0,029 *** (0,005)	0,028 *** (0,005)	0,028 *** (0,005)
	<i>Rating (0-1)</i>		-0,129 *** (0,015)	-0,158 *** (0,016)	-0,140 *** (0,016)	-0,139 *** (0,016)
	<i>Bewertungen (Anzahl in 100)</i>		-0,011 *** (0,001)	-0,011 *** (0,001)	-0,012 *** (0,001)	-0,012 *** (0,001)
	<i>Kum. Plattformeinkommen (0-1)</i>		0,383 *** (0,030)	0,373 *** (0,031)	0,261 *** (0,034)	0,260 *** (0,034)
	<i>Schwellenland (Dummy)</i>		-0,127 *** (0,012)	-0,128 *** (0,012)	-0,133 *** (0,012)	-0,130 *** (0,012)
	<i>Entwicklungsland (Dummy)</i>		-0,146 *** (0,014)	-0,150 *** (0,014)	-0,162 *** (0,014)	-0,159 *** (0,014)
Performance	<i>Auftragsabschlussrate (%)</i>			-0,124 *** (0,027)	-0,156 *** (0,027)	-0,153 *** (0,027)
	<i>Einhaltung des Budgets (%)</i>			0,065 ** (0,032)	0,035 (0,031)	0,035 (0,031)
	<i>Einhaltung der Lieferzeit (%)</i>			0,104 *** (0,032)	0,072 ** (0,032)	0,070 ** (0,032)
	<i>Wiederbeauftragungsquote (%)</i>			0,149 *** (0,037)	0,057 * (0,034)	0,057 * (0,034)
Weitere plattform-generierte Variablen	<i>Weiterempfehlungen (Anzahl in 100)</i>				0,038 *** (0,008)	0,036 *** (0,008)
	<i>Verifizierungsindex (0-1)</i>				0,330 *** (0,022)	0,331 *** (0,022)
	<i>Plattformerfahrung (Jahre)</i>				0,001 (0,001)	0,001 (0,001)
	<i>Absolvierte Tests (Anzahl)</i>				0,017 *** (0,002)	0,017 *** (0,003)
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>				0,009 (0,007)	0,008 (0,007)
	<i>Erfahrung in Tätigkeitskategorie (Dummy)</i>				0,008 (0,010)	0,008 (0,010)
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>					-0,017 ** (0,007)
	<i>Bildungsniveau Mittel (Dummy)</i>					-0,017 (0,016)
	<i>Bildungsniveau Niedrig (Dummy)</i>					0,008 (0,014)
	<i>Zertifikate (Anzahl)</i>					-0,014 *** (0,004)
	<i>Erfahrung (Anzahl)</i>					0,013 *** (0,003)
	<i>Publikationen (Anzahl)</i>					0,015 *** (0,004)
Konstante		-0,669 *** (0,002)	-0,664 *** (0,038)	-0,682 *** (0,041)	-0,842 *** (0,038)	-0,846 *** (0,038)
Fixed Effects auf Auftragsebene		✓	✓	✓	✓	✓
Anzahl an Angeboten		31.316	31.316	31.316	31.316	31.316
Anzahl an Aufträgen		2.274	2.274	2.274	2.274	2.274
R ² Overall		0,000	0,080	0,081	0,083	0,083
R ² Within		0,000	0,092	0,095	0,111	0,112
F-Test Overall		11,8 ***	367,7 ***	253,0 ***	201,4 ***	153,1 ***

Angegeben sind die jeweiligen Regressionskoeffizienten der Fixed Effect Regression mit cluster robusten Standardfehlern.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Anhang Tabelle 18: Ergebnisse der Fixed Effect Regression zur Analyse der Angebotspreise auf Ebene der Tätigkeitskategorien

Modell 5 - Tätigkeitskategorien		Gesamt	Websites, IT & Software	Design, Media & Architecture	Writing & Content
Abhängige Variable: log(Angebotspreis (in 100 EUR))					
Zentrale unabhängige Variable					
	<i>Geschlecht (Dummy: 1=Frau, 0=Mann)</i>	0,008 (0,006)	0,027 *** (0,009)	0,049 *** (0,013)	-0,029 ** (0,014)
Kontrollvariablen					
Bidlist	<i>Rang (1-21)</i>	-0,005 *** (0,001)	-0,003 ** (0,001)	-0,006 *** (0,002)	-0,005 ** (0,003)
	<i>Lieferzeit (Tage)</i>	0,028 *** (0,005)	0,016 *** (0,005)	0,069 *** (0,013)	0,053 *** (0,006)
	<i>Rating (0-1)</i>	-0,139 *** (0,016)	-0,106 *** (0,020)	-0,201 *** (0,055)	-0,170 *** (0,043)
	<i>Bewertungen (Anzahl in 100)</i>	-0,012 *** (0,001)	-0,012 *** (0,002)	-0,010 *** (0,001)	-0,016 *** (0,004)
	<i>Kum. Plattformeinkommen (0-1)</i>	0,260 *** (0,034)	0,295 *** (0,043)	0,374 *** (0,083)	0,223 *** (0,085)
	<i>Schwellenland (Dummy)</i>	-0,130 *** (0,012)	-0,075 *** (0,016)	-0,074 ** (0,032)	-0,255 *** (0,029)
	<i>Entwicklungsland (Dummy)</i>	-0,159 *** (0,014)	-0,114 *** (0,020)	-0,145 *** (0,038)	-0,229 *** (0,031)
	Performance	<i>Auftragsabschlussrate (%)</i>	-0,153 *** (0,027)	-0,035 (0,033)	-0,438 *** (0,102)
<i>Einhaltung des Budgets (%)</i>		0,035 (0,031)	-0,026 (0,039)	0,292 *** (0,103)	-0,063 (0,084)
<i>Einhaltung der Lieferzeit (%)</i>		0,070 ** (0,032)	0,075 * (0,040)	0,041 (0,088)	0,185 ** (0,086)
<i>Wiederbeauftragungsquote (%)</i>		0,057 * (0,034)	0,088 ** (0,044)	0,316 *** (0,098)	-0,255 *** (0,090)
Weitere plattform-generierte Variablen	<i>Weiterempfehlungen (Anzahl in 100)</i>	0,036 *** (0,008)	0,031 ** (0,014)	0,033 *** (0,009)	0,133 *** (0,033)
	<i>Verifizierungsindex (0-1)</i>	0,331 *** (0,022)	0,162 *** (0,029)	0,572 *** (0,059)	0,370 *** (0,051)
	<i>Plattformerfahrung (Jahre)</i>	0,001 (0,001)	-0,001 (0,001)	-0,001 (0,003)	0,007 ** (0,003)
	<i>Absolvierte Tests (Anzahl)</i>	0,017 *** (0,003)	0,020 *** (0,003)	0,023 *** (0,005)	-0,003 (0,007)
	<i>Kostenpflichtige Mitgliedschaft (Dummy)</i>	0,008 (0,007)	-0,032 *** (0,010)	-0,026 * (0,014)	0,098 *** (0,019)
	<i>Erfahrung in Tätigkeitskategorie (Dumm)</i>	0,008 (0,010)	0,058 *** (0,016)	-0,050 (0,040)	-0,042 ** (0,020)
Externe Variablen	<i>Bildungsniveau Hoch (Dummy)</i>	-0,017 ** (0,007)	-0,016 (0,010)	-0,011 (0,017)	-0,052 *** (0,019)
	<i>Bildungsniveau Mittel (Dummy)</i>	-0,017 (0,016)	-0,002 (0,023)	0,069 * (0,038)	-0,136 *** (0,037)
	<i>Bildungsniveau Niedrig (Dummy)</i>	0,008 (0,014)	0,039 ** (0,018)	-0,074 ** (0,034)	-0,018 (0,038)
	<i>Zertifikate (Anzahl)</i>	-0,014 *** (0,004)	-0,021 *** (0,005)	0,005 (0,010)	-0,027 *** (0,010)
	<i>Erfahrung (Anzahl)</i>	0,013 *** (0,003)	0,016 *** (0,004)	-0,012 (0,008)	0,023 *** (0,009)
	<i>Publikationen (Anzahl)</i>	0,015 *** (0,004)	0,004 (0,007)	0,009 (0,011)	0,028 *** (0,006)
Konstante	-0,846 *** (0,038)	-0,678 *** (0,042)	-1,193 *** (0,086)	-1,134 *** (0,073)	
Fixed Effects auf Auftragsebene		✓	✓	✓	✓
Anzahl an Angeboten		31.316	14.598	6.624	5.603
Anzahl an Aufträgen		2.274	1.115	448	380
R ² Overall		0,083	0,063	0,192	0,107
R ² Within		0,112	0,078	0,261	0,184
F-Test Overall		153,1 ***	47,4 ***	90,7 ***	48,7 ***

Angegeben sind die jeweiligen Regressionskoeffizienten der Fixed Effect Regression mit cluster robusten Standardfehlern.

Statistische Signifikanz: *10%, **5%, ***1%-Level

Quelle: Eigene Berechnungen und Darstellung.

Eidesstattliche Versicherung

Hiermit versichere ich, dass ich die als Dissertation vorgelegte Abhandlung in keinem anderen Verfahren zur Erlangung des Doktorgrades oder als Prüfungsarbeit für eine akademische oder staatliche Prüfung eingereicht habe, dass ich die vorgelegte Abhandlung selbständig verfasst, keine anderen als die von mir angegebenen Quellen und Hilfsmittel benutzt und die den benutzten Werken wörtlich oder inhaltlich entnommenen Stellen kenntlich gemacht habe.

Ort und Datum, gez. Benedikt Runschke

Erklärung zur Vermittlung

Hiermit erkläre ich, dass die Gelegenheit zum vorliegenden Promotionsverfahren nicht kommerziell vermittelt worden ist und dass ich insbesondere keine Organisation eingeschaltet habe, die gegen Entgelt Betreuer und Betreuerinnen für die Anfertigung von Dissertationen sucht oder die der Doktorandin oder dem Doktoranden obliegenden Pflichten hinsichtlich der Prüfungsleistungen ganz oder teilweise erledigt.

Ort und Datum, gez. Benedikt Runschke

Lebenslauf

Bildung

- Seit 10/2021 Promotionsstudium
Institut für Sozialwissenschaften Abt.
Wirtschaftswissenschaften der Rheinland-
Pfälzischen Technischen Universität Kaiserslautern
Landau
- 10/2014 – 11/2017 Master of Science Economics
Universität zu Köln
- Schwerpunkte: Wachstum und Ungleichheit,
Arbeitsmarktökonomik, angewandte Ökonometrie
 - Abschlussarbeit: „Composition effects, tasks or
institutional factors? What could explain increasing
residual wage inequality, a review.“
- 04/2011 – 09/2014 Bachelor of Science Volkswirtschaftslehre
Rheinische Friedrich-Wilhelms-Universität Bonn
- Schwerpunkte: Arbeitsmarktökonomik, Geldpolitik
 - Abschlussarbeit: „Lohnkompression und Arbeitszeiten –
der Einfluss von Gewerkschaften auf die
durchschnittlichen Arbeitszeiten im Rahmen eines Right-
to-Manage Modells.“
- 08/2009 – 07/2010 Allgemeine Hochschulreife
Berufsbildende Schule Gerolstein

Berufserfahrung

- Seit 09/2022 Senior Researcher
WifOR Institute Darmstadt
- 09/2018 – 08/2022 Researcher
WifOR Institute Darmstadt
- 11/2017 – 06/2018 Researcher
Corpus Sireo Real Estate Köln
- 07/2013 – 11/2017 Werkstudent im Controlling
Corpus Sireo Real Estate Köln