

**sofia**

Sonderforschungsgruppe  
Institutionenanalyse

## **Auswirkungen des Decoy-Effekts auf die Algorithm Aversion**

Marco Lorenz

sofia-Diskussionsbeiträge 22-3, Darmstadt 2022

ISBN: 978-3-947850-01-3

sofia-Diskussionsbeiträge  
zur Institutionenanalyse  
Nr. 22-3

ISSN 1437-126X

ISBN 978-3-947850-01-3

# **Auswirkungen des Decoy-Effekts auf die Algorithm Aversion**

Marco Lorenz

Göttingen, Juli 2022

## Abstract

Limitationen im menschlichen Entscheidungsprozess schränken das technologische Potenzial von Algorithmen ein, was auch als „Algorithm Aversion“ bezeichnet wird. In dieser Studie wird anhand eines Laborexperiments mit Probanden untersucht, ob ein seit 1982 unter dem Namen „Decoy-Effekt“ bekanntes Phänomen geeignet ist, die Algorithm Aversion abzubauen. Bei zahlreichen analogen Produkten, wie Autos, Getränken oder Zeitungsabos, hat der Decoy-Effekt bekanntermaßen einen starken Einfluss auf das menschliche Entscheidungsverhalten. Überraschenderweise werden die Entscheidungen zwischen Prognosen von Menschen und Robo-Advisors (Algorithmen), die in dieser Studie untersucht werden, durch den Decoy-Effekt überhaupt nicht beeinflusst. Dies gilt sowohl von vornherein als auch nach dem Beobachten von Prognosefehlern.

## Keywords

Algorithm aversion, Decoy effect, Robo-advisors, Technology adoption, Human-computer interaction, Experiments, Behavioral economics.

## JEL classification

D81, D83, D91, G41, O30.

## Funding

Dieses Forschungsprojekt wurde durch das Reinhard Selten-Stipendium der Gesellschaft für experimentelle Wirtschaftsforschung e.V. gefördert. Die Fördermittel wurden ausschließlich zur Vergütung der Probanden im Laborexperiment benutzt.

## Autor

**Marco Lorenz**, Georg August University Göttingen, Faculty of Economic Sciences, Platz der Göttinger Sieben 3, D-37073 Göttingen, Germany, Tel.: +49 1522 6672 503; E-Mail: [marco.lorenz@stud.uni-goettingen.de](mailto:marco.lorenz@stud.uni-goettingen.de)

## Inhalt

<b>1 Einführung</b> .....	<b>5</b>
<b>2 Literaturüberblick</b> .....	<b>8</b>
2.1 Decoy-Effekt .....	8
2.2 Algorithm Aversion .....	10
2.3 Hypothesen.....	12
<b>3 Experimentelles Design</b> .....	<b>16</b>
3.1 Teilnehmende.....	16
3.2 Aufgabenstellung.....	17
3.3 Ablauf .....	18
3.4 Die Algorithmen.....	19
3.5 Strategien .....	21
3.6 Methoden .....	24
<b>4 Ergebnisse</b> .....	<b>26</b>
4.1 Allgemein .....	26
4.2 Unterschiede zwischen den Treatments .....	28
4.3 Reaktionen auf Fehler .....	30
<b>5 Diskussion</b> .....	<b>33</b>
<b>6 Zusammenfassung</b> .....	<b>37</b>
<b>7 Literatur</b> .....	<b>39</b>
<b>8 Anhang</b> .....	<b>43</b>
8.1 Anhang A: Instruktionen.....	43
8.2 Anhang B: Kontrollfragen.....	49
8.3 Anhang C: Bildschirmgestaltung.....	50

## Tabellen

Tabelle 1: Verteilung in der Kontrollgruppe bei Ariely (2009).....	8
Tabelle 2: Verteilung unter Einfluss des Decoy-Effekts bei Ariely (2009) .....	9
Tabelle 3: Kursbildungsmechanismus, Prognosen der Algorithmen .....	
und Vergütung in Abhängigkeit von gewählter Strategie.....	22
Tabelle 4: Durchschnittliche Vergütung in Abhängigkeit von der Häufigkeit,....	
mit der der Algorithmus ausgewählt wurde .....	27
Tabelle 5: Gegenüberstellung der Treatments.....	28
Tabelle 6: Reaktionen auf Prognosefehler durch einen Algorithmus.....	31
Tabelle 7: Reaktionen auf eigene Prognosefehler .....	32
Tabelle 8: Einflussfaktoren auf die Aktienkursbildung der Z-Aktie.....	43
Tabelle 9: Einflussfaktoren auf die Aktienkursbildung der Z-Aktie.....	46
Tabelle 10: Eigenschaften der Algorithmen.....	47

## Abbildungen

Abbildung 1: Grundsätzlicher Aufbau des Experiments .....	13
Abbildung 2: Verteilung der Fakultäten der Probanden in den Treatments... ..	16
Abbildung 3: Verteilung der Geschlechter der Probanden in den Treatments ..	17
Abbildung 4: Gegenüberstellung der Treatments.....	28
Abbildung 5: Gegenüberstellung der Entscheidungen zugunsten des	
Target-Algorithmus zwischen den Treatments je Spielrunde ...	30
Abbildung 6: Vergleich der Entscheidungen zugunsten des Target-Produkts	
vor und nach Hinzufügen eines Decoys in verschiedenen	
Studien .....	34
Abbildung 7: Bildschirmgestaltung in Treatment 1 (Kontrollgruppe) .....	50
Abbildung 8: Bildschirmgestaltung in Treatment 2 (Decoy-Effekt).....	51

# 1

## Einführung

Erhebliche Fortschritte im Bereich der Künstlichen Intelligenz (KI) ebnen aktuell den Weg für zahlreiche vielversprechende Geschäftsmodelle. Allerdings zeigen viele Menschen Vorbehalte gegenüber automatisierten Verfahren. Diese Vorbehalte werden auch als "Algorithm Aversion" bezeichnet.<sup>1</sup>

Algorithmen oder KI, die mit stochastischen Prozessen arbeiten, können nicht ausschließlich zutreffende Vorhersagen, z. B. über die Entwicklung an Kapitalmärkten, abgeben. Sobald Nutzer dies erkennen, entwickeln sie häufig Misstrauen gegenüber der Technologie und verzichten auf ihren Einsatz (Dietvorst, Simmons & Massey, 2015). Diese Problemlage tritt auch dann auf, wenn Nutzer sich entscheiden müssen, ob sie auf ihr eigenes Urteilsvermögen oder auf einen Algorithmus vertrauen. Selbst wenn deutliche Hinweise darauf vorliegen, dass es ihnen kaum möglich sein wird, auf Dauer bessere Entscheidungen zu treffen als ein Algorithmus, vertrauen viele Nutzer eher auf sich selbst.

Die Algorithm Aversion führt dazu, dass sich vielversprechende Technologien am Markt nicht so durchsetzen, wie man es in Anbetracht ihrer Leistungsfähigkeit und Kostenvorteile erwarten würde. Im Finanzbereich fällt es beispielsweise vielen Nutzern schwer, Vertrauen in automatisierte Vermögensverwalter, so genannte „Robo-Advisors“, zu entwickeln, obwohl ihr Einsatz zur Vermeidung kostspieliger Fehler beitragen kann (Back, Morana & Spann, 2021). Um diese Problematik einzudämmen, müssen Maßnahmen zum Abbau der Algorithm Aversion identifiziert und ergriffen werden.

Eine experimentelle Studie mit diesem Themenschwerpunkt untersucht die Möglichkeit der Einflussnahme auf den algorithmischen Output durch den Nutzer selbst. Dietvorst, Simmons und Massey (2018) geben einigen Probanden die Möglichkeit, die Prognosen eines Algorithmus im Nachgang um ein paar Prozentpunkte nach unten oder oben anzupassen. Durch diese Möglichkeit der Einflussnahme erhöht sich die Nutzungsbereitschaft signifikant. Interessanterweise tritt der Effekt selbst dann auf, wenn die Möglichkeiten zur Anpassung gering gehalten werden. Der Artikel legt nahe, dass man die Aversion abschwächen kann, indem man Menschen Einflussmöglichkeiten auf die Prognosen des Algorithmus gibt, sei es auch nur in begrenztem Ausmaß.

In weiteren Studien wurden unter anderem das Verkürzen der Antwortzeiten (Efendić, Van de Calseyde & Evans, 2020) oder die Berücksichtigung der Prognosen sachkundiger Menschen durch den Algorithmus (Kawaguchi, 2021) als Maßnahmen identifiziert, durch die die Algorithm Aversion verringert werden kann. Außerdem scheinen auch eine präzisere Darstellung des algorithmischen Outputs, z. B. durch Hinzufügen zusätzlicher Nachkommastellen (Kim, Giroux

---

1 Für einen detaillierten Überblick über die Literatur zur Algorithm Aversion siehe z. B. Mahmud et al. (2022), Burton, Stein & Jensen (2020) oder Jussupow, Benbasat & Heinzl (2020).

& Lee, 2021), und die Angabe von Informationen über das Vorgehen und die Genauigkeit eines Algorithmus (Ben David, Resheff & Tron, 2021) hierfür geeignet zu sein.

Die aufgeführten Maßnahmen reduzieren die Algorithm Aversion allerdings nur in begrenztem Ausmaß. Außerdem beinhalten sie teilweise das Risiko, dass sich die Prognosequalität des Algorithmus nach der Einflussnahme durch den Menschen verringert (vgl. Kawaguchi, 2021; Dietvorst, Simmons & Massey, 2018). Folglich ist es nach wie vor eine wichtige Aufgabe der Forschung, effektive Möglichkeiten zum Abbau der Algorithm Aversion aufzudecken, die keine Verschlechterung der Prognosequalität des Algorithmus mit sich bringen.

Diese Studie greift deshalb eine Idee von Huber, Payne & Puto (1982) auf, die den menschlichen Entscheidungsprozess unter Unsicherheit anhand ökonomischer Experimente untersucht haben. Ihre Studie zeigt, dass die Möglichkeit des Vergleichens zwischen mehreren Optionen den menschlichen Entscheidungsfindungsprozess massiv beeinflussen kann. Eine Option findet unter Umständen deutlich größeren Anklang, wenn ein mit ihr vergleichbares, aber erkennbar schlechteres Angebot hinzugefügt wird. Dieses Phänomen wird auch als „Decoy-Effekt“ bezeichnet (siehe Kapitel 2.1). In zahlreichen Replikationen hat sich gezeigt, dass der Decoy-Effekt bei der Auswahl zwischen verschiedenen Gebrauchsgegenständen (Ariely & Wallsten, 1995), Dienstleistungen (Park & Kim, 2005) und sogar Lotterien (Kroll & Vogt, 2012; Herne, 1999) dazu führen kann, dass Subjekte ihr Entscheidungsverhalten ändern. Dies legt nahe, dass der Decoy-Effekt sich auch auf weitere Entscheidungssituationen auswirken kann.

In den bisherigen Studien zur Algorithm Aversion wurde den Entscheidungsträgern in der Regel nur ein einziger Algorithmus zur Verfügung gestellt, auf dessen Einsatz sie entweder setzen oder verzichten konnten (vgl. z. B. Dietvorst, Simmons & Massey, 2015). Mit zunehmendem technologischem Fortschritt sinkt die Übertragbarkeit dieses experimentellen Designs auf die Praxis. Tatsächlich können wir in der Praxis bereits heute bei vielen Aufgaben, wie nicht zuletzt der Vermögensverwaltung, zwischen mehreren Algorithmen auswählen, die sich in ihrer Leistungsfähigkeit unterscheiden.

Die Wahlmöglichkeit zwischen mehreren Algorithmen könnte dazu führen, dass sich ein Decoy-Effekt einstellt, und zwar immer dann, wenn ein Algorithmus in mindestens einem Kriterium offensichtlich besser und in keinem anderen Kriterium schlechter ist als ein anderer Algorithmus. Der objektiv überlegene Algorithmus würde in diesem Fall aus Nutzersicht zusätzlich an Attraktivität gewinnen, auch gegenüber alternativen Verfahren, bei denen kein Algorithmus zum Einsatz kommt.

Der große Vorteil dieses Ansatzes gegenüber bereits identifizierten Maßnahmen zum Abbau der Algorithm Aversion liegt darin, dass der überlegene Algorithmus überhaupt nicht manipuliert werden müsste. Dies bedeutet, dass die Nutzungsbereitschaft der Entscheidungsträger erhöht werden könnte, ohne die

Leistungsfähigkeit oder Nutzerfreundlichkeit des Algorithmus beeinträchtigen zu müssen. In dieser Studie soll deshalb anhand eines ökonomischen Experiments untersucht werden, ob sich der Decoy-Effekt zur Reduzierung der Algorithm Aversion eignet. Dabei wird der Einfluss des Decoy-Effekts auf die Nutzungsbereitschaft eines Algorithmus sowohl von vornherein als auch nach dem Beobachten von Fehlern des Algorithmus untersucht.



## 2

### Literaturüberblick

#### 2.1

##### Decoy-Effekt

Der Decoy-Effekt (auch asymmetrischer Dominanzeffekt) wurde vor etwa 40 Jahren erstmalig entdeckt. Huber, Payne & Puto (1982) lassen in einem ökonomischen Experiment 150 Studierende zwischen verschiedenen Autos, Restaurants, Biersorten, Lotterien, Filmen und Fernsehgeräten auswählen. Sie stellen fest, dass das Hinzufügen eines so genannten Decoys, der mit dem als Target bezeichneten Angebot vergleichbar und diesem eindeutig unterlegen ist, dazu führen kann, dass das Target deutlich häufiger ausgewählt wird als eine dritte Option, der so genannte Competitor.

Der Decoy-Effekt wird von Ariely (2009) am Beispiel von Abo-Angeboten der Zeitschrift „The Economist“ anschaulich illustriert. Der Autor teilt 200 Studierende auf zwei Treatments auf und bittet sie jeweils um eine Einschätzung, welches Zeitungsabonnement sie auswählen würden, wenn sie sich zwischen mehreren Angeboten entscheiden müssten. Im ersten Treatment (Kontrollgruppe) können die Studierenden zwischen den Angeboten „Digital“ (59 USD) und „Print + Digital“ (125 USD) wählen. Es zeigt sich, dass 68 Studierende das Angebot „Digital“ und die übrigen 32 Studierende das Angebot „Print + Digital“ bevorzugen. Wenn diese 100 Studenten die Abos tatsächlich abschließen würden, würde dies also für The Economist zu einem Gesamtumsatz von 8.012 USD führen (siehe Tabelle 1).

Tabelle 1: Verteilung in der Kontrollgruppe bei Ariely (2009)

Angebot	Digital	Print + Digital
Preis	59 USD	125 USD
Anzahl Käufer	68	32
Umsatz je Angebot	4.012 USD	4.000 USD
<b>Umsatz gesamt</b>	<b>8.012 USD</b>	

Im zweiten Treatment (Decoy-Effekt) wird neben den bereits bekannten Angeboten „Digital“ (59 USD) sowie „Print + Digital“ (125 USD) außerdem das Angebot „Print“ (125 USD) hinzugefügt. Obwohl das Angebot „Print“ kein einziges Mal ausgewählt wird, hat es einen massiven Einfluss auf den theoretisch erzielten Umsatz von „The Economist“. In der zweiten Gruppe entscheiden sich nun nur noch 16 Studierende für das Angebot „Digital“, während 84 Studierende das Angebot „Print + Digital“ bevorzugen. Der Gesamtumsatz läge nun bei 11.444 USD (siehe Tabelle 2).

Tabelle 2: Verteilung unter Einfluss des Decoy-Effekts bei Ariely (2009)

Angebot	Digital	Print + Digital
Preis	59 USD	125 USD
Anzahl Käufer	16	84
Umsatz je Angebot	944 USD	10.500 USD
<b>Umsatz gesamt</b>		<b>11.444 USD</b>

Das Angebot „Print“ wird im zweiten Treatment hinzugefügt, um das Entscheidungsverhalten hin zum Angebot „Print + Digital“ zu lenken. Es wird in diesem Kontext deshalb als *Decoy* bezeichnet, während das Angebot „Print + Digital“, das nach Hinzufügen des Decoys an Beliebtheit gewinnt, *Target* genannt wird. Das Angebot „Digital“ ist wiederum der *Competitor* von „Print“. Man spricht in diesem Kontext auch davon, dass das Target den Decoy asymmetrisch dominiert. Die Begriffe Decoy, Target und Competitor sind bis heute in der Literatur zum Decoy-Effekt verbreitet.

Ariely führt die massiven Unterschiede im Auswahlverhalten zwischen den Optionen „Digital“ und „Digital + Print“ auf das Hinzufügen des Decoys „Print“ zurück. Im ersten Treatment mussten die Studierenden zwei Optionen miteinander vergleichen, die in unterschiedlichen Dimensionen einander überlegen sind. Bereits die Bezeichnung der Option „Print + Digital“ lässt vermuten, dass diese Option zusätzliche Konsummöglichkeiten bietet. Allerdings ist sie der Option „Digital“ hinsichtlich des Preises offensichtlich unterlegen. Es obliegt der individuellen Beurteilung, ob der Mehrwert in der Dimension „Konsummöglichkeiten“ des Angebots „Print + Digital“ höher zu bewerten ist als der Mehrwert in der Dimension „Preis“ des Angebots „Digital“. Dementsprechend ergibt sich ein gemischtes Bild.

Im zweiten Treatment hingegen führt die Vergleichbarkeit der Angebote „Print + Digital“ und „Print“ dazu, dass die Subjekte eine Heuristik anwenden. Obwohl auch hier sämtliche Entscheidungen ausschließlich zugunsten der Optionen „Digital“ und „Print + Digital“ ausfallen, ersetzen sie die Frage, welche dieser beiden Optionen vorteilhaft ist, durch einen Vergleich der Optionen „Print + Digital“ und „Print“. Zum gleichen Preis bietet das Target „Print + Digital“ eindeutig mehr Konsummöglichkeiten als der Decoy „Print“. Da das Target dem Decoy eindeutig überlegen ist, gewinnt es an Attraktivität, und das auch gegenüber dem Competitor „Digital“, dessen relative Vorteilhaftigkeit gegenüber anderen Optionen nach wie vor nicht zu bestimmen ist.

Park & Kim (2005) werfen die Frage auf, ob sich der Decoy-Effekt auch einstellt, wenn zwei Decoys angeboten werden. Der erste Decoy wird in diesem Fall nur vom Target asymmetrisch dominiert. Er ist mit dem Competitor nicht ohne Weiteres zu vergleichen. Der zweite Decoy hingegen wird sowohl vom Target als auch vom Competitor asymmetrisch dominiert. Es zeigt sich, dass das Target in

diesem Fall nur dann an Attraktivität gewinnt, wenn die Teilnehmenden gebeten werden, zunächst jede der vier Optionen für sich zu bewerten. Wenn sie die Optionen sofort miteinander vergleichen sollen, stellt sich kein Decoy-Effekt ein.

Frederick, Lee & Baskin (2014) werfen die Frage auf, durch welche Maßnahmen sich ein Decoy-Effekt am besten hervorrufen lässt. Sie vergleichen die Effektivität von drei Arten der Darstellung der Produktdimensionen: Der Darstellung in Zahlenform, der Darstellung in Bildform sowie des physischen Erlebens der Unterschiede durch das Subjekt selbst (z. B. durch den Geschmackssinn). Sie stellen fest, dass sich der Decoy-Effekt nur dann einstellt, wenn die Produktdimensionen als niedergeschriebene Zahlen, beispielsweise in Form unterschiedlich hoher Ratings, repräsentiert werden. Auch Yang & Lynn (2014) gelangen zu dem Fazit, dass qualitativ-verbale Beschreibungen sowie bildliche Darstellungen nicht besonders gut geeignet sind, um einen asymmetrischen Dominanzeffekt zu erzeugen. Die beiden untersuchten Maßnahmen führen lediglich in 11 von 91 Vergleichen über 23 verschiedene Produktklassen zu signifikanten Decoy-Effekten.

Crosetto & Gaudeul (2016) untersuchen die Robustheit des Decoy-Effekts. Sie führen hierfür als zusätzliche Dimension den so genannten „monetären Indikator“ ein. Die Autoren gestalten den monetären Indikator so, dass ein Auswählen des Targets höhere Kosten mit sich bringt als ein Auswählen des Competitors. Sie variieren, wie viel höher die Kosten für das Auswählen des Targets im Vergleich zum Competitor sind. Es zeigt sich, dass die Präferenz für das Target weiterhin bestehen bleibt, solange es bis zu 8% teurer als der Competitor ist.

Zu guter Letzt hat der Decoy-Effekt auch einen nachgewiesenen Einfluss auf die Risikopräferenz und das soziale Verhalten von Individuen. Kroll & Vogt (2012) lassen Probanden zwischen verschiedenen Lotterien mit kleinen oder großen Beträgen auswählen. Es zeigt sich, dass das Hinzufügen eines Decoys in allen Fällen dazu führt, dass die Risikobereitschaft der Teilnehmenden zunimmt. Wang et al. (2018) lassen ihre Probanden eine abgewandelte Form des „Prisoners Dilemma“ spielen, in der zu den bekannten Optionen „cooperate“ und „defect“ die dritte Option „reward“ als Decoy hinzugefügt wird. Es lässt sich beobachten, dass der Decoy dazu führt, dass Probanden deutlich häufiger kooperieren und dadurch auch ihren durchschnittlichen Gewinn im Vergleich zu einer Kontrollgruppe erhöhen.

## 2.2

### Algorithm Aversion

Leistungsunterschiede von Algorithmen und Menschen bei der Bewältigung gleichartiger Aufgabenstellungen werden bereits seit den 1950er-Jahren untersucht (Meehl, 1955). In den vergangenen Jahren wurde die Reaktion der Nutzer auf Prognosen und Ratschläge von Algorithmen und Menschen näher betrachtet. Önkal et al. (2009) haben in einer experimentellen Studie festgestellt, dass

dieselben Empfehlungen in geringerem Ausmaß befolgt werden, wenn man Probanden in den Glauben versetzt, sie kämen von einem Algorithmus, als wenn man ihnen erzählt, die Empfehlungen kämen von einem sachkundigen Menschen. Auch wenn der Begriff der Algorithm Aversion zum damaligen Zeitpunkt noch nicht etabliert war, wurde die Studie im Nachgang vielfach als Nachweis der Algorithm Aversion gedeutet.

Sechs Jahre später haben Dietvorst, Simmons & Massey (2015) festgestellt, dass Fehler eines Algorithmus zu einem größeren Vertrauensverlust führen als Fehler eines Menschen. Ihre Probanden konnten eine Prognoseaufgabe entweder an einen Algorithmus oder an einen Menschen delegieren. Bei den Probanden, die in Proberunden dem Algorithmus beim Begehen vom Fehlern zusehen konnten, war in den darauffolgenden vergüteten Runden eine verstärkte Ablehnungshaltung gegenüber dem Algorithmus auszumachen. Zur Bezeichnung dieses Phänomens wurde der Begriff „Algorithm Aversion“ in seiner ursprünglichen Form geprägt. Heutzutage wird der Begriff sowohl für eine generelle Ablehnungshaltung gegenüber Algorithmen als auch für eine Ablehnungshaltung erst nach dem Beobachten von Fehlern eines Algorithmus benutzt (Filiz et al., 2021a).

Aufbauende Studien haben unter anderem gezeigt, dass Algorithm Aversion in unterschiedlichen Fachgebieten, wie beispielsweise dem Rechtswesen (Ireland, 2020), der Vermögensverwaltung (Niszczoła & Kaszás, 2020), der Medizin (Lennartz et al., 2021) oder der Poesie (Köbis & Mossink, 2021), gleichermaßen zu beobachten ist. Ihr Ausmaß scheint dennoch vom Kontext der Aufgabenstellungen abzuhängen (Filiz et al., 2021a; Castelo, Bos & Lehmann, 2019).

Die Algorithm Aversion kann unabhängig davon auftreten, ob als Alternative zum Algorithmus die eigenständige Durchführung einer Aufgabe, die Delegation an einen Experten oder die Delegation an einen Laien zur Verfügung steht (Germann & Merkle, 2020). Als eine der Hauptursachen der Algorithm Aversion wurden unrealistische Erwartungen an die Genauigkeit eines Algorithmus ausgemacht (Rebitschek, Gigerenzer & Wagner, 2021). Befragte vermuten die Fehlerquoten von Algorithmen häufig in Bereichen, die derart niedrig sind, dass sie in der Praxis nicht zu erreichen sind. Dies erklärt auch teilweise, warum das Vertrauen in Algorithmen nach fehlerhaften Prognosen so rapide sinkt (Dietvorst, Simmons & Massey, 2015).

Weiterhin wurde gezeigt, dass Entscheidungsträger Vorbehalte gegenüber Algorithmen haben, da sie diesen im Gegensatz zu Menschen nicht zutrauen, im Zeitverlauf dazuzulernen und ihre Prognosequalität sukzessive zu verbessern (Berger et al., 2020). Im Einklang damit steht die Erkenntnis, dass auch das so genannte „Uniqueness Neglect“ ein Treiber der Algorithm Aversion sein kann. Es beschreibt den Umstand, dass Entscheidungssituationen oft als neuartig und nicht vergleichbar betrachtet werden, weswegen einem spezialisierten Algorithmus keine sinnvolle Entscheidung zugetraut wird (Pezzo & Beckstead, 2020; Longoni, Bonezzi & Morewedge, 2019). Außerdem scheinen Menschen eine stärkere emotionale Bindung zu Mitmenschen aufzubauen als zu Algorithmen,

was ebenfalls dazu führt, dass sie die Zusammenarbeit mit Algorithmen meiden (Leyer & Schneider, 2019).

Yeomans et al. (2019) führen die Algorithm Aversion auch teilweise auf eine Überschätzung der eigenen Prognosefähigkeiten (Overconfidence) zurück. Indem Menschen die Erfolgsaussichten bei eigener Durchführung einer Aufgabe zu hoch einschätzen, bewerten sie auch den Mehrwert durch den Einsatz eines Algorithmus falsch. Es hat sich gezeigt, dass Lerneffekte, hervorgerufen durch sich wiederholende Aufgabenstellungen sowie klares Feedback über die eigene Leistung und die eines Algorithmus, dazu beitragen können, die Aversion in begrenztem Ausmaß zu reduzieren (Filiz et al., 2021b). Passend dazu wurde beobachtet, dass die Algorithm Aversion zwar mit zunehmender digitaler Kompetenz der Entscheidungsträger zurückgeht (Wang, Harper & Zhu, 2020), allerdings mit zunehmender Fachexpertise der Entscheidungsträger auf dem Gebiet der Prognoseaufgabe steigt (Allen & Choudhury, 2021; Gaube et al., 2021).

In der Praxis führt die Algorithm Aversion dazu, dass sich vielversprechende Innovationen, die auf dem Einsatz von Algorithmen und KI basieren, am Markt nicht so durchsetzen, wie man es in Anbetracht ihrer Vorzüge erwarten würde. Wenn es gelingt, die Algorithm Aversion zu überwinden, können umfangreiche Kosteneinsparungen oder die Erschließung neuer digitaler Geschäftsmodelle ermöglicht werden. In den letzten Jahren hat sich die Forschung deshalb zunehmend der Suche nach Maßnahmen gewidmet, die geeignet sind, das Vertrauen der Entscheidungsträger in die Technologie und damit auch ihre Nutzungsbereitschaft zu erhöhen (Ben David, Resheff & Tron, 2021; Kawaguchi, 2021; Kim, Giroux & Lee, 2021; Efendić, Van de Calseyde & Evans, 2020; Dietvorst, Simmons & Massey, 2018). Die identifizierten Maßnahmen reduzieren die Algorithm Aversion jedoch stets nur zu einem kleinen Teil und bringen darüber hinaus neue Probleme, wie eine Verschlechterung der Prognosequalität (Kawaguchi, 2021; Dietvorst, Simmons & Massey, 2018), mit sich.


## 2.3 Hypothesen

Am Beispiel eines Investment-Experiments soll untersucht werden, ob ein Decoy-Effekt die Entscheidung für oder gegen die Verwendung eines Algorithmus beeinflussen kann. Dabei wird das in Kapitel 2.1 beschriebene experimentelle Design von Ariely (2009) in den Kontext einer Investmententscheidung mit automatisierten Vermögensverwaltern, so genannten Robo-Advisors, übertragen. In Treatment 1 (Kontrollgruppe) können Subjekte die Prognoseaufgabe eigenständig durchführen oder an einen Algorithmus mit einer Erfolgsquote in Höhe von 70% delegieren. In Treatment 2 (Decoy-Effekt) können Subjekte die Prognoseaufgabe eigenständig durchführen, an einen Algorithmus mit einer Erfolgsquote in Höhe von 70% delegieren, oder an einen zweiten Algorithmus mit einer Erfolgsquote in Höhe von 60% delegieren. Der Algorithmus mit einer Erfolgsquote in Höhe von 70% wird im weiteren Verlauf auch als „Robo-

Advisor A“ bzw. „Algorithmus A“ und der Algorithmus mit einer Erfolgsquote in Höhe von 60% als „Robo-Advisor B“ bzw. „Algorithmus B“ bezeichnet.

Durch das Hinzufügen des zweiten Algorithmus wird ein Decoy-Effekt hergestellt (Abbildung 1). Algorithmus A fungiert in dieser Studie als *Target*. Algorithmus B stellt den *Decoy* dar, der die Attraktivität des Targets (Algorithmus A) erhöhen könnte. Die eigenständige Bewältigung der Prognoseaufgabe durch die Probanden selbst ist in diesem Fall der *Competitor*. Das Experiment geht über zehn Runden (siehe Kapitel 3.2).

Abbildung 1: Grundsätzlicher Aufbau des Experiments



Vergangene Studien haben gezeigt, dass Wirtschaftssubjekte dazu neigen, menschliches Urteilsvermögen der Beratung durch einen Algorithmus vorzuziehen (vgl. bspw. Alemanni et al., 2020; Promberger & Baron, 2006). Bei Entscheidungen zwischen Algorithmen und dem eigenen Urteilsvermögen kann dieser Effekt durch ein Überschätzen der eigenen Prognosefähigkeiten (Overconfidence) zusätzlich verstärkt werden (vgl. Filiz et al., 2021b). Dies ist insofern interessant, als die Wahrscheinlichkeit, durch menschliches Urteilsvermögen ein Ergebnis zu erzielen, das dem eines spezialisierten Algorithmus auch nur nahekommt, äußerst gering ist. In Anbetracht der vorherigen Forschungsergebnisse ist nichtsdestotrotz davon auszugehen, dass auch in dieser Studie ein Großteil der Probanden ungeachtet der Vorzüge des Algorithmus auf die eigene Durchführung der Aufgabe setzen wird.

**Hypothese 1:** Nicht alle Probanden entscheiden sich durchgängig für einen Algorithmus.

Die Teilnehmenden im Treatment 1 (Kontrollgruppe) müssen sich zwischen dem leistungsstärkeren Robo-Advisor A mit einer Erfolgsquote von 70% (Target) und der eigenständigen Vermögensverwaltung (Competitor) entscheiden. Im Treatment 2 (Decoy-Effekt) wird der Robo-Advisor B mit einer Erfolgsquote von 60% als Decoy hinzugefügt, der mit Robo-Advisor A vergleichbar und ihm klar unterlegen ist.

Von einem rein mathematischen Standpunkt aus betrachtet ist die Entscheidungssituation in beiden Fällen identisch. Es kommt nur darauf an, ob die Erfolgsaussichten bei eigenständiger Durchführung der Prognoseaufgabe höher eingeschätzt werden als bei Wahl des Robo-Advisors A. Robo-Advisor B sollte aufgrund der geringeren Erfolgswahrscheinlichkeit keinen Einfluss auf die Entscheidungen eines Probanden haben, der als streng rationaler Nutzenmaximierer agiert.

Wenn der Decoy-Effekt analog zu der bei Ariely (2009) beobachteten Form zum Tragen kommt, wird die Vergleichbarkeit des Robo-Advisors A mit Robo-Advisor B hinsichtlich der Dimension „Erfolgsquote“ im zweiten Treatment allerdings dazu führen, dass deutlich mehr Entscheidungen zugunsten der Delegation an den überlegenen Algorithmus und entgegen der selbständigen Durchführung der Prognoseaufgabe ausfallen.

**Hypothese 2:** Der Anteil der Entscheidungen zugunsten des Target-Algorithmus fällt höher aus, wenn ein weiterer Algorithmus als Decoy eingeführt wird.

Ein zentraler Aspekt der Algorithm Aversion liegt in der Reaktion auf misslungene Urteile. Wie in dieser Studie stehen auch die Probanden von Dietvorst, Simmons & Massey (2015) vor der Wahl, ob sie eine Prognoseaufgabe eigenständig durchführen oder an einen Algorithmus delegieren möchten. Ein Teil der Probanden hat dabei die Möglichkeit, den Algorithmus bereits vorab bei seiner Tätigkeit (und folglich auch zwangsläufig beim Begehen von Fehlern) zu beobachten. Die Autoren untersuchen, inwiefern dies das Entscheidungsverhalten der Probanden beeinflusst. Dabei stellen sie fest, dass Probanden, die den Algorithmus beim Abgeben unzutreffender Prognosen beobachten konnten, tatsächlich deutlich häufiger in den folgenden Runden auf ihr eigenes Urteilsvermögen als auf den Algorithmus setzen, obwohl der Algorithmus immer noch die höhere Erfolgsquote aufweist. Interessanterweise stellt sich der Effekt nach dem Beobachten misslungener Prognosen eines Menschen nicht im gleichen Ausmaß ein. Diese Erkenntnis wird von Bogert, Schechter & Watson (2021)

bestätigt, die ebenfalls zu dem Schluss kommen, dass Wirtschaftssubjekte sensibler auf Fehler eines Algorithmus reagieren als auf Fehler eines Menschen.

In dieser Studie soll untersucht werden, ob sich die Algorithm Aversion nach fehlerhaften Prognosen auch dann einstellt, wenn mehrere Algorithmen zur Verfügung stehen. Die Erweiterung des Angebots an Algorithmen in Treatment 2 (Decoy-Effekt) könnte dazu führen, dass der Effekt abgeschwächt wird, da die Probanden nun noch eine zusätzliche Alternative zur Auswahl haben. Selbst wenn sie nicht mehr ausreichend Vertrauen in denjenigen Algorithmus haben, der eine unzutreffende Prognose abgegeben hat, müssen sie sich nicht zwangsläufig vom Einsatz von Algorithmen in Gänze verabschieden, sondern können einfach den zweiten Algorithmus benutzen. Darüber hinaus könnte das sich einstellende Misstrauen in den Algorithmus durch die zusätzliche Information, dass es sich nichtsdestotrotz um einen - relativ zum anderen Algorithmen betrachtet - leistungsstarken Algorithmus handelt, abgeschwächt werden. Das würde bedeuten, dass die Abkehr von Algorithmen als Entscheidungshilfen nach einer fehlerhaften Prognose nicht mehr so stark ausgeprägt ist, wenn mehrere Algorithmen zur Verfügung stehen.

**Hypothese 3:** Der Anteil der Probanden, die nach einer fehlerhaften Prognose eines Algorithmus auch in der Folge auf einen Algorithmus setzen, fällt in Treatment 2 (Decoy-Effekt) signifikant höher aus als in Treatment 1 (Kontrollgruppe).

Darauf aufbauend könnte auch die Reaktion auf eigene unpassende Prognosen variieren, wenn mehrere Algorithmen als Alternativen zur Verfügung stehen. Durch ein breiteres Angebot und die zusätzlichen Informationen zur relativen Leistungsfähigkeit könnte sich im Gegensatz zur Studie von Dietvorst, Simmons & Massey (2015) die Bereitschaft erhöhen, die anfängliche Ablehnungshaltung gegenüber Algorithmen nach fehlerhaften eigenen Prognosen doch noch aufzugeben.

**Hypothese 4:** Der Anteil der Probanden, die nach einer fehlerhaften eigenen Prognose in der Folge zu einem Algorithmus wechseln, fällt in Treatment 2 (Decoy-Effekt) signifikant höher aus als in Treatment 1 (Kontrollgruppe).



### 3 Experimentelles Design

#### 3.1 Teilnehmende

Zur Beantwortung der Forschungsfragen wird ein ökonomisches Experiment mit Studierenden der Ostfalia Hochschule für angewandte Wissenschaften durchgeführt. Insgesamt 160 Studierende werden zu diesem Zweck zwischen dem 20.04.2022 und 28.04.2022 in das Ostfalia Labor für experimentelle Wirtschaftsforschung eingeladen. Sie tragen sich eigenständig für einen von 28 Terminen á jeweils circa einer halben Stunde ein. Die Probanden machen während der Bearbeitung einen konzentrierten Eindruck. Sie erzielen eine durchschnittliche Vergütung in Höhe von 5,95 EUR, die in Anbetracht des Zeitaufwands angemessen erscheint, um einen effektiven Anreiz bei der Entscheidungsfindung zu schaffen.

Die Probanden sind im Schnitt 23,6 Jahre alt und befinden sich durchschnittlich im fünften Semester ihres Studiums. 37 Probanden (22%) haben bereits an ökonomischen Experimenten teilgenommen, für 123 Probanden (78%) ist dies die erste Teilnahme. Die Probanden werden gleichmäßig auf zwei Treatments aufgeteilt: Eine Treatmentgruppe, in der ein Decoy eingeführt wird, sowie eine Kontrollgruppe. Um eine Verzerrung der Ergebnisse zu vermeiden, wird auf eine gleichmäßige Verteilung hinsichtlich der Fakultäten und Geschlechter geachtet (Abbildungen 2 und 3).

Abbildung 2: Verteilung der Fakultäten der Probanden in den Treatments





Abbildung 3: Verteilung der Geschlechter der Probanden in den Treatments



## 3.2

### Aufgabenstellung

Die Probanden müssen eine Aufgabe aus dem Bereich der Vermögensverwaltung bewältigen. Im Verlauf von zehn Spielrunden muss jeweils eine Entscheidung getroffen werden, ob ein zugewiesenes Anfangsbudget an Experimentalwährung (10 ECU) in voller Höhe in eine Aktie („Z-Aktie“) investiert oder in voller Höhe gespart werden soll. Am Ende des Spiels wird das kumulierte Guthaben aus den einzelnen Spielrunden umgerechnet und den Probanden als Vergütung ausgezahlt.

Ziel der Teilnehmenden ist es also, ihr Guthaben zu maximieren. Dafür können sie ihr Budget in den zehn Spielrunden jeweils entweder selbst verwalten oder einem Robo-Advisor (Treatment 1) bzw. einem von zwei Robo-Advisors (Treatment 2) anvertrauen, die das Budget an ihrer Stelle investieren oder sparen. Die detaillierten Instruktionen befinden sich in Anhang A.

Wenn das Budget in die Aktie investiert wird, kann der Rundengewinn aufgrund von Kursschwankungen über oder unter dem anfänglichen Budget in Höhe von 10 ECU liegen. Wenn der Kurs der Aktie innerhalb einer Runde beispielsweise um 10% steigt und 10 ECU in die Aktie investiert wurden, werden dem Guthaben 11 ECU gutgeschrieben. Wenn der Kurs der Aktie innerhalb einer Runde um 10% fällt und 10 ECU in die Aktie investiert wurden, werden dem Guthaben 9 ECU gutgeschrieben. Erfolgt die Entscheidung hingegen für das Sparen, so werden dem Guthaben der Probanden stets exakt 10 ECU gutgeschrieben.

Vor dem Treffen der Investmententscheidung sollten die Probanden sich also ein Bild davon machen, ob der Kurs der Aktie ihrer Einschätzung nach in der jeweiligen Runde steigen oder fallen wird. Wenn der Kurs steigt, ist es die gewinnmaximierende Strategie, in die Aktie zu investieren. Wenn der Kurs fällt, ist es die gewinnmaximierende Strategie, zu sparen.

Zur Hilfestellung werden vor jeder Spielrunde die aktuellen Werte vier fundamentaler Einflussfaktoren bekanntgegeben, die in Kombination mit einem Zufallseinfluss den Kursverlauf bestimmen. In den Instruktionen ist detailliert beschrieben, in welchen Bereichen sich die Werte der Einflussfaktoren bewegen können. Außerdem erhalten die Probanden Einsicht in die Verteilung der Werte der fundamentalen Einflussfaktoren und des Zufallseinflusses in zehn Runden Kurshistorie. Anhand der Informationen können sie sich ein ungefähres Bild von den Zusammenhängen und der aktuellen Entwicklung machen. Die Werte der Einflussfaktoren in jeder Spielrunde wurden einmalig als Zufallsprozess generiert.

Die Teilnehmenden im Treatment 1 (Kontrollgruppe) werden vor die Wahl gestellt, ob sie die Vermögensverwaltung eigenständig durchführen oder an den Robo-Advisor A mit einer Erfolgsquote von 70% delegieren wollen. Das heißt, der Algorithmus trifft in durchschnittlich 7 von 10 Spielrunden diejenige Entscheidung (investieren oder sparen), die das Guthaben der Probanden maximiert. Im zweiten Treatment (Decoy-Effekt) steht den Probanden zusätzlich zur eigenständigen Durchführung und zum Robo-Advisor A auch der Robo-Advisor B mit einer Erfolgsquote von 60% zur Verfügung.

Die Erfolgswahrscheinlichkeiten der Algorithmen werden neben anderen Produktdimensionen in Tabellenform in den Instruktionen präsentiert. Damit wird der Empfehlung von Frederick, Lee & Baskin (2014) gefolgt, die festgestellt hatten, dass die Darstellung von Produktdimensionen in Zahlenform besonders gut geeignet ist, um einen Decoy-Effekt hervorzurufen.

### **3.3 Ablauf**

Das Experiment ist in der Experimentalssoftware z-Tree implementiert (vgl. Fischbacher, 2007) und wird im Ostfalia Labor für experimentelle Wirtschaftsforschung durchgeführt. Die Probanden nehmen von einem Bildschirmarbeitsplatz aus am Experiment teil und erhalten die Instruktionen in Papierform. Das Experiment wird durchgängig von einem Spielleiter begleitet. Somit wird gewährleistet, dass Teilnehmende sich die erforderliche Zeit tatsächlich nehmen, keine unerlaubten Hilfsmittel einsetzen und nicht von externen Störfaktoren beeinflusst werden.

Die Probanden lesen zunächst die Instruktionen für ihr jeweiliges Treatment. Anschließend erscheinen Kontrollfragen am Bildschirm, um zu überprüfen, ob sie die Aufgabe verstanden und alle relevanten Informationen korrekt erfasst haben (siehe Anhang B). Im zweiten Treatment wird hierdurch entsprechend sichergestellt, dass sich ein Decoy-Effekt einstellt.

Das Experiment startet schließlich damit, dass den Probanden zur Orientierung ein Einblick in zehn Runden Kurshistorie sowie in die Werte der Einflussfaktoren für die aktuelle Runde gegeben wird (siehe Anhang C). An dieser Stelle treffen

die Probanden erstmalig die Entscheidung, ob sie die Investmentaufgabe in der aktuellen Spielrunde eigenständig durchführen oder an den Robo-Advisor A (Treatment 1) bzw. den Robo-Advisor A oder den Robo-Advisor B (Treatment 2) delegieren möchten. Sofern sich die Probanden für die eigenständige Bewältigung der Aufgabe entscheiden, müssen sie sich weiterhin festlegen, ob sie ihr Budget in der aktuellen Runde in die Aktie investieren (Erwartung: Kurs steigt) oder sparen (Erwartung: Kurs fällt). Damit ist die erste Spielrunde beendet.

Zu Beginn jeder neuen Spielrunde erhalten die Probanden einen Einblick in die Entwicklung des Aktienkurses und der Einflussfaktoren in den vergangenen zehn Spielrunden sowie in die aktuellen Werte der fundamentalen Einflussfaktoren. Außerdem wird stets die Veränderung ihres kumulierten Guthabens in der vergangenen Spielrunde angezeigt. Hieran können die Probanden erkennen, ob in der abgelaufenen Spielrunde die optimale Investitionsentscheidung getroffen wurde oder ein Prognosefehler vorlag. Die Probanden können in jeder Spielrunde erneut entscheiden, ob sie die Investmentaufgabe eigenständig durchführen oder den Algorithmus (Treatment 1) bzw. einen der beiden Algorithmen (Treatment 2) benutzen möchten.

Nach Abschluss der zehnten Spielrunde werden die Probanden über ihre Vergütung informiert. Zunächst beantworten sie noch einen kurzen Fragebogen, anhand dessen demographische Informationen abgefragt werden. Die erfassten Daten sollen dazu beitragen, bestehende Zusammenhänge in den Entscheidungen der Probanden besser einordnen zu können und eventuelle neue Zusammenhänge ans Tageslicht zu bringen.

Anschließend erfolgt die Auszahlung. Vom kumulierten Guthaben am Ende der zehnten Spielrunde werden 95 ECU abgezogen. Die verbliebenen ECU werden im Verhältnis 1 ECU = 1 EUR umgetauscht und den Probanden als Vergütung ausgezahlt. Je höher das kumulierte Guthaben aus den zehn vergüteten Spielrunden ausfällt, desto höher ist auch die Auszahlung für die Probanden.

### 3.4

#### Die Algorithmen

Beide Robo-Advisors ziehen die Werte der fundamentalen Einflussfaktoren heran, um eine Prognose abzugeben, wie sich der Aktienkurs entwickelt. Sagt ihr Modell einen steigenden Kurs vorher, so investieren sie das Vermögen der Probanden in die Aktie, andernfalls sparen sie es. Die Formel, auf die die Algorithmen zurückgreifen, ist so gestaltet, dass sie in der Mehrzahl der Spielrunden die für die Probanden vorteilhafte Entscheidung treffen, jedoch auch gelegentlich danebenliegen. Um die Reaktionen der Probanden auf fehlerhafte Prognosen zu analysieren, ist es maßgeblich, dass im Experiment Algorithmen zum Einsatz kommen, deren Vorhersagen nicht immer zutreffen.

Robo-Advisor A verwendet exakt die Gleichung, die hinter dem Kursbildungsmechanismus steckt. Er setzt stets die aktuellen Werte der Einflussfaktoren in

die Formel ein und trifft auf dieser Grundlage eine Prognose. Lediglich die Höhe des Zufallseinflusses, der als fünfter Einflussfaktor fungiert, ist Robo-Advisor A nicht bekannt. Er rechnet deshalb stets mit dem Erwartungswert des Zufallseinflusses (0). Der Zufallseinfluss führt dazu, dass die Prognosen des Algorithmus nur in 70% der Fälle zur finanziell vorteilhaften Entscheidung (investieren oder sparen) führen. In 30% der Fälle kehrt der Zufallseinfluss die Richtung der Aktienkursentwicklung um, die die vier bekannten Einflussfaktoren nahelegen.

Robo-Advisor B greift auf das gleiche Vorgehen zurück. Allerdings sind diesem Algorithmus auch die Werte des Einflussfaktors B nicht bekannt, weswegen er für Einflussfaktor B stets mit dem Mittelwert der Spannweite in Höhe von 15 (siehe Instruktionen im Anhang A) rechnet. Die Verwendung näherungsweise Formeln zur Prognose zukünftiger Werte ist ein etabliertes Vorgehen, wenn Algorithmen relevante Informationen fehlen (vgl. Rencher & Schaalje, 2008).

Die Formel hinter dem Kursbildungsmechanismus der Z-Aktie lautet:

$$0,8 \times \text{Einflussfaktor A} + 0,2 \times \text{Einflussfaktor B} - 0,4 \times \text{Einflussfaktor C} + 0,04 \times \text{Einflussfaktor D} + \text{Zufallseinfluss}$$

Die von Algorithmus A verwendete Formel lautet:

$$0,8 \times A + 0,2 \times B - 0,4 \times C + 0,04 \times D + 0$$

Die von Algorithmus B verwendete Formel lautet:

$$0,8 \times A + 0,2 \times 15 - 0,4 \times C + 0,04 \times D + 0$$

Der Kursbildungsmechanismus und die Vorgehensweise der Algorithmen sind in Tabelle 3 dargestellt. Sie werden im Folgenden am Beispiel der Spielrunde 5 veranschaulicht. In Spielrunde 5 beträgt Einflussfaktor A 12, Einflussfaktor B beträgt 9, Einflussfaktor C beträgt 7, Einflussfaktor D beträgt 30 und der Zufallseinfluss beträgt -1 (siehe Tabelle 3 - Bereich „Werte der Einflussfaktoren“).

Der Kurs der Z-Aktie nimmt also folgenden Wert an:

$$0,8 \times 12 + 0,2 \times 9 - 0,4 \times 7 + 0,04 \times 30 + (-1) = 8,80 \text{ ECU}$$

Probanden, die in dieser Spielrunde ihr Rundenbudget investieren, bekommen 8,80 ECU gutgeschrieben. Probanden, die ihr Rundenbudget sparen, bekommen stets 10,00 ECU gutgeschrieben. In dieser Runde ist es also ratsam, das Rundenbudget in Höhe von 10 ECU zu sparen, anstatt es in die Z-Aktie zu investieren. Das Delta beträgt -1,20 ECU (siehe Tabelle 3 - Bereich „Ertrag in ECU“).

Algorithmus A verwendet in dieser Spielrunde folgende Gleichung:

$$0,8 \times 12 + 0,2 \times 9 - 0,4 \times 7 + 0,04 \times 30 + 0 = 9,80 \text{ ECU}$$

Sein Modell sagt also hervor, dass durch Investieren kein höherer Rundengewinn als durch Sparen (+10,00 ECU) erzielt werden kann. Das prognostizierte Delta zwischen Investieren und Sparen beträgt -0,20 ECU. Sofern dieses Delta einen negativen Betrag hat, also ein Aktienkurs in Höhe von < 10 ECU prognostiziert wird, spart der Algorithmus das Rundenbudget der Probanden. Ihrem Guthaben werden bei Wahl des Algorithmus A in Spielrunde 5 folglich 10 ECU gutgeschrieben.

Algorithmus B rechnet wie folgt:

$$0,8 \times 12 + 0,2 \times 15 - 0,4 \times 7 + 0,04 \times 30 + 0 = 11,00 \text{ ECU}$$

Sein Modell sagt also hervor, dass durch Investieren ein höherer Rundengewinn als durch Sparen (+10,00 ECU) erzielt werden kann. Das prognostizierte Delta zwischen Investieren und Sparen beträgt +1,00 ECU. Sofern dieses Delta einen positiven Betrag hat oder exakt 0 beträgt, also ein Aktienkurs in Höhe von  $\geq 10$  ECU prognostiziert wird, investiert der Algorithmus das Rundenbudget der Probanden in die Z-Aktie. Der tatsächliche Kurs am Ende der Runde beträgt allerdings lediglich 8,80 ECU. Dem Guthaben der Probanden, die in Spielrunde 5 auf Algorithmus B setzen, werden folglich 8,80 ECU gutgeschrieben (siehe Tabelle 3 - Bereich „Erfolg der Algorithmen“).

### 3.5 Strategien

Den Probanden stehen im Wesentlichen drei Strategien zur Verfügung. Zum einen können sie die Robo-Advisors vernachlässigen und die Vermögensverwaltung in allen zehn Spielrunden eigenständig durchführen. Ihre Vergütung ist dann stark vom Erfolg ihrer Prognosen abhängig. Auf Grundlage der durch einen Zufallsprozess generierten Werte der fundamentalen Einflussfaktoren wird sie zwischen 0,36 EUR (im Falle von zehn falschen Prognosen) und 9,68 EUR (im Falle von zehn korrekten Prognosen) liegen (siehe Tabelle 3 – Bereich „Vergütungsstruktur“).

Wenn Probanden in allen zehn Spielrunden sparen, so beträgt ihre Vergütung 5,00 EUR (10 Runden  $\times$  10 ECU – 95 ECU). Wenn Probanden in allen zehn Runden in die Z-Aktie investieren, erhalten sie 5,04 EUR.

Tabelle 3: Kursbildungsmechanismus, Prognosen der Algorithmen und Vergütung in Abhängigkeit von gewählter Strategie

Spiellrunde	1	2	3	4	5	6	7	8	9	10	Summe	Vergütung*
<b>Werte der Einflussfaktoren</b>												
Einflussfaktor A	13	11	6	8	12	11	6	11	10	15	-	-
Einflussfaktor B	15	13	17	18	9	14	20	18	16	11	-	-
Einflussfaktor C	6	8	2	1	7	6	5	8	5	9	-	-
Einflussfaktor D	19	27	35	32	30	23	24	22	23	21	-	-
Zufallseinfluss	0	1	0	-2	-1	0	2	1	-1	0	-	-
<b>Ertrag in ECU</b>												
Investieren	11,76 ECU	10,28 ECU	8,80 ECU	8,88 ECU	8,80 ECU	10,12 ECU	9,76 ECU	11,08 ECU	9,12 ECU	11,44 ECU	100,04 ECU	-
Sparen	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	100,00 ECU	-
Delta (Invest. - Sparen)	+1,76 ECU	+0,28 ECU	-1,20 ECU	-1,12 ECU	-1,20 ECU	+0,12 ECU	-0,24 ECU	+1,08 ECU	-0,88 ECU	+1,44 ECU	-	-
<b>Optimale Strategie</b>												
Investieren	Investieren	Investieren	Sparen	Sparen	Sparen	Investieren	Sparen	Investieren	Sparen	Investieren	-	-
<b>Erfolg der Algorithmen</b>												
Kursprognose Algo. A	11,76 ECU	9,28 ECU	8,80 ECU	10,88 ECU	9,80 ECU	10,12 ECU	7,76 ECU	10,08 ECU	10,12 ECU	11,44 ECU	-	-
Kursprognose Algo. B	11,76 ECU	9,68 ECU	8,40 ECU	10,28 ECU	11,00 ECU	10,32 ECU	6,76 ECU	9,48 ECU	9,92 ECU	12,24 ECU	-	-
Prognose Delta durch Algorithmus A	+1,76 ECU	-0,72 ECU	-1,20 ECU	+0,88 ECU	-0,20 ECU	+0,12 ECU	-2,24 ECU	+0,08 ECU	+0,12 ECU	+1,44 ECU	-	-
Prognose Delta durch Algorithmus B	+1,76 ECU	-0,32 ECU	-1,60 ECU	+0,28 ECU	+1,00 ECU	+0,32 ECU	-3,24 ECU	-0,52 ECU	-0,08 ECU	+2,24 ECU	-	-
<b>Vorgehen Algorithmen A</b>												
Investieren	Investieren	Sparen	Investieren	Investieren	Sparen	Investieren	Sparen	Investieren	Investieren	Investieren	-	-
<b>Vorgehen Algorithmen B</b>												
Investieren	Investieren	Sparen	Investieren	Investieren	Investieren	Investieren	Sparen	Investieren	Sparen	Investieren	-	-
<b>Vergütungsstruktur</b>												
Nur falsche Prognosen	10,00 ECU	10,00 ECU	8,80 ECU	8,88 ECU	8,80 ECU	10,00 ECU	9,76 ECU	10,00 ECU	9,12 ECU	10,00 ECU	95,36 ECU	0,36 €
Nur korrekte Prognosen	11,76 ECU	10,28 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,12 ECU	10,00 ECU	11,08 ECU	10,00 ECU	11,44 ECU	104,68 ECU	9,68 €
Immer Sparen	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	10,00 ECU	100,00 ECU	5,00 €
Immer Investieren	11,76 ECU	10,28 ECU	8,80 ECU	8,88 ECU	8,80 ECU	10,12 ECU	9,76 ECU	11,08 ECU	9,12 ECU	11,44 ECU	100,04 ECU	5,04 €
Bei Wahl Algorithmus A	11,76 ECU	10,00 ECU	10,00 ECU	8,88 ECU	10,00 ECU	10,12 ECU	10,00 ECU	11,08 ECU	9,12 ECU	11,44 ECU	102,40 ECU	7,40 €
Bei Wahl Algorithmus B	11,76 ECU	10,00 ECU	10,00 ECU	8,88 ECU	8,80 ECU	10,12 ECU	10,00 ECU	10,00 ECU	10,00 ECU	11,44 ECU	101,00 ECU	6,00 €

\*Die Vergütung ergibt sich aus dem kumulierten Guthaben am Ende der 10. Spielrunde abzüglich 95 ECU, umgetauscht im Verhältnis 1 ECU = 1 EUR (siehe Anhang A).

In drei von zehn Runden wird der Aktientrend, den die fundamentalen Einflussfaktoren nahelegen, durch den in seiner Höhe vorab unbekanntem Zufallseinfluss umgekehrt. Folglich ist nicht davon auszugehen, dass den Probanden ein Erspielen der maximal möglichen Vergütung gelingt. Wenn Probanden stets die Entscheidung treffen, die der Verlauf der Einflussfaktoren impliziert, liegt ihre Vergütung für die zehn zufällig gestalteten Kursrunden bei 7,40 EUR. Die Vergütung bei eigenständiger Prognoseabgabe wird also vermutlich im Durchschnitt im Bereich zwischen 5,00 EUR (zufällige Vermögensverwaltung) und 7,40 EUR (zielgerichtete Vermögensverwaltung auf Grundlage der Einflussfaktoren) liegen.

Weiterhin können Probanden in allen zehn Spielrunden auf Robo-Advisor A zurückgreifen. In diesem Fall beträgt ihre Vergütung 7,40 EUR, da der Algorithmus den Informationsgehalt der fundamentalen Einflussfaktoren optimal ausnutzt.

Im zweiten Treatment (Decoy-Effekt) können die Probanden darüber hinaus auch durchgängig Robo-Advisor B einsetzen. In diesem Fall liegt ihre Vergütung unter der Vergütung bei Wahl des überlegenen Robo-Advisors A und beträgt 6,00 EUR (siehe Tabelle 3 – Bereich „Vergütungsstruktur“).

Während Probanden den Kursbildungsmechanismus lediglich grob anhand der historischen Daten zur Kursentwicklung abschätzen können, kennen die Algorithmen den exakten Kursbildungsmechanismus und haben außerdem massive Vorteile in der Verknüpfung der gegebenen Informationen. Um die Erfolgswahrscheinlichkeit des Algorithmus A zu erreichen, müssten Probanden sämtliche Informationen aus den zehn Runden Kurshistorie optimal auswerten. Sie müssten dafür jeweils die Auswirkungen aller vier Einflussfaktoren sowie des Zufallseinflusses auf den Aktienkurs analysieren und mithilfe einer äußerst komplexen Regressionsgleichung den Kursbildungsmechanismus herleiten. Anschließend müssten sie in jeder der vergüteten Spielrunden die Werte in die Formel des Kursbildungsmechanismus einsetzen und auf Grundlage des Ergebnisses eine Entscheidung treffen, ob sie ihr Vermögen sparen oder investieren wollen.

Aber selbst, wenn ihnen dies gelingen sollte, wäre der Erwartungswert ihrer Vergütung lediglich gleich hoch wie bei Verwendung des Algorithmus A, der ebenfalls alle vorab verfügbaren Informationen optimal ausnutzt. Um die Erfolgswahrscheinlichkeit des Algorithmus A zu übertreffen, müssten die Probanden darüber hinaus richtig raten, in welchen Spielrunden der vorab in seiner Höhe unbekanntem Zufallseinfluss einen Vorzeichenwechsel beim Aktienkurs verursacht. Um den Algorithmus in diesem Experiment zu schlagen, sind also nicht nur herausragende analytische Fähigkeiten, sondern darüber hinaus auch noch eine große Menge Glück erforderlich. Genau aus diesem Grund ist die Algorithm Aversion in den Fokus von Verhaltensökonomern geraten. Entscheidungen gegen einen Algorithmus, der derart überlegen ist, und die darüber hinaus mit finanziellen Nachteilen verbunden sind, werden oft in den Kontext kognitiver Verzerrungen eingeordnet.



### 3.6 Methoden

Zur Überprüfung der Hypothese 1 (Nicht alle Probanden entscheiden sich durchgängig für einen Algorithmus) werden unabhängig vom Treatment für jeden Probanden die Entscheidungen zugunsten des Target- und Decoy-Algorithmus in allen zehn Spielrunden addiert. Anschließend wird anhand des Einstichproben-t-Tests überprüft, ob sich die Anzahl der Spielrunden, in denen ein durchschnittlicher Proband auf einen Algorithmus setzt, signifikant von 10 aus 10 Spielrunden (100%) unterscheidet. Darüber hinaus wird anhand des Z-Tests ermittelt, ob der Anteil der Probanden, die durchgängig auf den Algorithmus setzen, signifikant von 100% der Probanden (160 von 160) abweicht.

Zur Überprüfung der Hypothese 2 (Der Anteil der Entscheidungen zugunsten des Target-Algorithmus fällt höher aus, wenn ein weiterer Algorithmus als Decoy eingeführt wird) wird in beiden Treatments der Mittelwert der Entscheidungen zugunsten des Target-Algorithmus ermittelt. Anhand des Wilcoxon-Rangsummen-Tests lässt sich anschließend eine Aussage treffen, ob ein signifikanter Unterschied zwischen den Treatments besteht.

Hypothese 3 lautet: Der Anteil der Probanden, die nach einer fehlerhaften Prognose eines Algorithmus auch in der Folge auf einen Algorithmus setzen, fällt in Treatment 2 (Decoy-Effekt) signifikant höher aus als in Treatment 1 (Kontrollgruppe). Hier wird der Chi-Quadrat-Test eingesetzt. Er überprüft, ob sich der Anteil der Entscheidungen zugunsten der Algorithmen zwischen den Treatments signifikant unterscheidet. Für Hypothese 3 werden alle Situationen ausgewählt, in denen ein Proband in einer beliebigen Runde zwischen Spielrunde 1 und Spielrunde 9 die Entscheidung an einen Algorithmus delegiert hat und von diesem nicht die gewinnmaximierende Entscheidung (investieren oder sparen) getroffen wurde, der Algorithmus also einen Fehler begangen hat. Anschließend wird für beide Treatments separat erfasst, in wie vielen Fällen in der darauffolgenden Spielrunde erneut ein Algorithmus ausgewählt wurde und in wie vielen Fällen die Probanden in der folgenden Spielrunde die Investmententscheidung selbst getroffen haben. Die resultierende 2x2-Kontingenztafel (Treatment 1 vs. Treatment 2 bzw. eigene Durchführung vs. Algorithmus) wird dem Chi-Quadrat-Test unterzogen.

Als Ergänzung wird das gleiche Vorgehen jeweils isoliert auf die Reaktionen auf den ersten (zweiten, ..., n-ten) Fehler eines Algorithmus angewandt, den ein Proband beobachtet. Auch hier wird anhand des Chi-Quadrat-Tests überprüft, ob sich die Entscheidungen in der Folgerunde zwischen den Treatments signifikant unterscheiden. Dieses zusätzliche Verfahren hat den Vorteil, dass jeder Proband in jedem Chi-Quadrat-Test nur ein einziges Mal erfasst wird. Dies kann dazu führen, dass mögliche Verzerrungen in den Ergebnissen, z. B. aufgrund von unterschiedlich ausgeprägten Lerneffekten, weniger ins Gewicht fallen.

Hypothese 4 lautet: Der Anteil der Probanden, die nach einer fehlerhaften eigenen Prognose in der Folge zu einem Algorithmus wechseln, fällt in Treatment 2 (Decoy-Effekt) signifikant höher aus als in Treatment 1 (Kontrollgruppe). Zu ihrer Überprüfung wird das gleiche Vorgehen angewandt wie für Hypothese 3, mit dem einzigen Unterschied, dass nun nur die Spielrunden nach fehlerhaften Prognosen der Probanden selbst (anstelle fehlerhafter Prognosen der Algorithmen) herangezogen werden.

## 4 Ergebnisse

### 4.1 Allgemein

160 Probanden treffen je 10 Entscheidungen zwischen eigenständiger Vermögensverwaltung und Delegation der Aufgabe an einen Algorithmus. In Summe werden also 1.600 Entscheidungen beobachtet. Davon entfallen 899 (56,188%) auf die eigenständige Vermögensverwaltung und lediglich 701 (43,813%) auf einen der beiden Algorithmen. Probanden, die ihr Vermögen eigenständig verwalten, investieren ihr Rundenbudget in 577 Fällen (64,182%) in die Z-Aktie und sparen das Budget in 322 Fällen (35,818%).

Die 43,813% der gesamten Entscheidungen, die zugunsten der Algorithmen getroffen werden, unterteilen sich in 679 Entscheidungen (42,438%) zugunsten des Algorithmus A mit einer Erfolgsquote von 70% und 22 Entscheidungen (1,375%) zugunsten des Algorithmus B mit einer Erfolgsquote von 60%. Alter, Geschlecht und Studienrichtung der Probanden haben keinen Einfluss auf die Entscheidung zwischen Algorithmus und eigenständiger Verwaltung des Rundenbudgets. Die Verteilung ist weiterhin auch im zeitlichen Verlauf des Experiments konstant. In jeder einzelnen der zehn Spielrunden entscheiden sich trotz seiner offensichtlichen Vorzüge (siehe Kapitel 3.5) lediglich zwischen 35% (Runde 4) und 49% (Runde 10) der Subjekte für einen Algorithmus. Die Probanden unterliegen eindeutig dem Phänomen der Algorithm Aversion. Lediglich 18 der 160 Probanden setzen durchgängig auf einen Algorithmus ( $p$ -Wert Z-Test  $< 0,001$ ). Der Einstichproben-t-Test untermauert, dass die Probanden weit davon entfernt sind, in allen zehn Spielrunden einen Algorithmus auszuwählen ( $t = -21,376$ ,  $p < 0,001$ ). Das 95%-Konfidenzintervall erstreckt sich zwischen 3,862 und 4,900 von 10 Entscheidungen pro Algorithmus je Proband.

Hinsichtlich der Anzahl korrekter Prognosen sind die Probanden beiden Algorithmen klar unterlegen. Die eigenständige Vermögensverwaltung durch die Probanden führt in 43,604% der Fälle (392 von 899 Entscheidungen) zur gewinnmaximierenden und in 56,396% der Fälle (507 von 899 Entscheidungen) nicht zur gewinnmaximierenden Investmententscheidung. Wie erwartet stellt die Komplexität der Aufgabe die Probanden bei eigenständiger Vermögensverwaltung also vor erhebliche Probleme. Ihre Erfolgsquote liegt sogar unter 50%. Die Erfolgswahrscheinlichkeit des Algorithmus A wurde mit 70% angegeben. Seine Prognosen liegen in 71,429% der tatsächlich beobachteten Fälle (485 von 679 Entscheidungen) richtig. Empfehlungen des Algorithmus B treffen in 63,636% der tatsächlich beobachteten Fälle (14 von 22 Entscheidungen) zu, was ebenfalls zur angegebenen Erfolgswahrscheinlichkeit von 60% passt.

Im Einklang mit diesen Ergebnissen erzielen Probanden, die durchweg eigene Prognosen abgeben, im Durchschnitt eine Vergütung von 5,12 EUR. Die

Vergütung der Probanden, die durchgängig auf einen Algorithmus setzen, liegt im Vergleich dazu bei 7,27 EUR (Tabelle 4). Die lineare Regression ergibt, dass die Vergütung im Durchschnitt mit jeder zusätzlichen Entscheidung für einen der beiden Algorithmen um 19,793 Cent steigt (p-Wert < 0,001).

Tabelle 4: Durchschnittliche Vergütung in Abhängigkeit von der Häufigkeit, mit der der Algorithmus ausgewählt wurde

Anzahl Runden, in denen ein Algorithmus ausgewählt wurde	Anzahl Probanden	Ø Vergütung
0	26	5,12 EUR
1	15	5,65 EUR
2	16	5,91 EUR
3	17	5,60 EUR
4	11	5,16 EUR
5	15	5,14 EUR
6	12	6,16 EUR
7	15	6,79 EUR
8	8	6,84 EUR
9	7	7,08 EUR
10	18	7,27 EUR
	160	5,95 EUR

In Anbetracht dieser Zahlen ist die Ablehnungshaltung gegenüber dem Algorithmus bemerkenswert. Probanden bezahlen ihre Algorithm Aversion im Laufe der zehn Spielrunden mit einer Reduzierung ihrer durchschnittlichen Vergütung um bis zu 1,98 EUR, bzw. bis zu 30%. Dies steht nichtsdestotrotz im Einklang mit vorherigen Studien, bei denen die Algorithm Aversion ebenfalls auftritt, obwohl der Verzicht auf den Algorithmus den Erwartungswert der Vergütung drastisch verringert.

## 4.2 Unterschiede zwischen den Treatments

Von 800 Entscheidungen in der Kontrollgruppe entfallen 338 (42,250%) auf den Target-Algorithmus und 462 (57,750%) auf die eigenständige Vermögensverwaltung. Im Treatment „Decoy-Effekt“ entfallen 341 Entscheidungen (42,625%) auf den Target-Algorithmus, 437 Entscheidungen (54,625%) auf die eigenständige Vermögensverwaltung und 22 Entscheidungen (2,750%) auf den Decoy-Algorithmus (Abbildung 4 und Tabelle 5).

Abbildung 4: Gegenüberstellung der Treatments




Tabelle 5: Gegenüberstellung der Treatments

Treatment	Eigene Prognosen	Algorithmus A	Algorithmus B	Summe Algorithmus
T1 (Kontrollgruppe)	462 (57,750%)	338 (42,250%)	-	338 (42,250%)
T2 (Decoy-Effekt)	437 (54,625%)	341 (42,625%)	22 (2,750%)	363 (45,375%)
Gesamt	899 (56,188%)	679 (42,438%)	22 (1,375%)	701 (43,813%)

Der Anteil der Entscheidungen zugunsten eigener Prognosen geht also im Treatment 2 (Decoy-Effekt) leicht zurück. Es ist jedoch keineswegs so, dass nun mehr Probanden den Target-Algorithmus A auswählen, wie die Theorie zum Decoy-Effekt nahelegt. Von den 25 zusätzlichen Entscheidungen, die im Treatment 2 zugunsten der Algorithmen getroffen werden, entfallen 22 auf den Algorithmus B (Decoy) und lediglich 3 auf den Algorithmus A. Der p-Wert des Wilcoxon-Rangsummentests in Höhe von 0,889 belegt, dass das Hinzufügen des Decoys in Form von Algorithmus B in Treatment 2 zu keiner nennenswerten Erhöhung der Nutzung des Target-Algorithmus A führt.


Es kann allerdings genau so wenig argumentiert werden, dass das Hinzufügen eines Decoys zum Abbau der Algorithm Aversion beiträgt. Wenn man die Entscheidungen zugunsten der beiden Algorithmen aggregiert, ist man immer noch weit von einem signifikanten Unterschied zwischen den beiden Treatments entfernt (p-Wert Wilcoxon-Rangsummentest = 0,530). Der beobachtete Unterschied von 25 Entscheidungen (3,125%) ist zu gering, um einen signifikanten Unterschied auszumachen. Er ist vielmehr auf Ungenauigkeiten in den Entscheidungen der insgesamt elf Probanden zurückzuführen, die trotz der geringeren Erfolgswahrscheinlichkeit einmalig oder mehrfach den Algorithmus B auswählen.

Weitergehende Analysen zeigen, dass sich das Verhalten der Probanden tatsächlich kaum unterscheidet, egal ob ein Decoy eingeführt wird, oder nicht. Einerseits liegt die Anzahl der Probanden, die konsequent eine bestimmte Strategie verfolgen, dicht beieinander. Insgesamt wählen 18 Probanden in allen zehn Spielrunden den Algorithmus aus. Sie verteilen sich gleichmäßig auf beide Treatments (jeweils 9). Von den 26 Probanden, die in keiner einzigen Spielrunde den Algorithmus auswählen, befinden sich 12 in Treatment 1 (Kontrollgruppe) und 14 in Treatment 2 (Decoy-Effekt).

Andererseits sind auch im zeitlichen Verlauf des Spiels keinerlei Unterschiede festzustellen (Abbildung 5). Die Differenz der Häufigkeit, mit der der Target-Algorithmus ausgewählt wird, bewegt sich stets im geringen Bereich von 0% (Runde 7) bis 8,750% (Runde 3).

Passend zu all diesen Erkenntnissen liegen auch die durchschnittlichen Vergütungen in den beiden Treatments dicht beieinander. Die durchschnittliche Vergütung pro Proband beträgt im Treatment 1 (Kontrollgruppe) 6,02 EUR und im Treatment 2 (Decoy-Effekt) 5,89 EUR. Der Unterschied ist im Wilcoxon-Rangsummentest nicht signifikant (p-Wert = 0,371).

Abbildung 5: Gegenüberstellung der Entscheidungen zugunsten des Target-Algorithmus zwischen den Treatments je Spielrunde



## 4.3

### Reaktionen auf Fehler

Von den 1.600 insgesamt abgegebenen Prognosen sind 891 korrekt und 709 fehlerhaft. Letztere unterteilen sich in 507 fehlerhafte Prognosen durch Probanden und 202 fehlerhafte Prognosen durch einen der Algorithmen. Im Folgenden wird die Reaktion auf unzutreffende Prognosen in den ersten neun Spielrunden untersucht, da nur auf diese Spielrunden noch mindestens eine weitere Spielrunde folgt, in der eine Verhaltensänderung möglich ist.

Der Algorithmus gibt in den ersten neun Spielrunden 202 fehlerhafte Prognosen ab: 99 im Treatment 1 (Kontrollgruppe) und 103 im Treatment 2 (Decoy-Effekt). In der Kontrollgruppe bleiben 69,697% der Probanden ungeachtet dessen auch in der nachfolgenden Runde dem Algorithmus treu. 30,303% der Probanden entziehen dem Algorithmus unmittelbar nach einem Fehler das Vertrauen und treffen in der Folgerunde eine eigene Investmententscheidung. Dieses Ergebnis steht im Einklang mit früheren Studien, die festgestellt hatten, dass das menschliche Vertrauen in Algorithmen nach fehlerhaften Prognosen rapide zurückgeht (vgl. Dietvorst, Simmons & Massey, 2015).

Wie werden die Probanden reagieren, wenn einerseits noch ein weiterer Algorithmus zur Verfügung steht, und andererseits aufgrund des Decoy-Effekts zusätzliche Indizien für die Leistungsstärke des Target-Algorithmus A sprechen? Im Treatment 2 (Decoy-Effekt) wählen sogar nur 62,136% der Probanden unmittelbar nachdem sie einen Fehler eines Algorithmus beobachten den Target-

Algorithmus aus. 4,854% der Probanden setzen anschließend auf den Decoy-Algorithmus und 33,010% auf die eigenständige Prognoseabgabe (Tabelle 6).

Tabelle 6: Reaktionen auf Prognosefehler durch einen Algorithmus

Auswahl in Folgerunde	Treatment 1 (Kontrollgruppe)			Treatment 2 (Decoy-Effekt)		
	Eigene Prognosen	Algorithmus A	Algorithmus B	Eigene Prognosen	Algorithmus A	Algorithmus B
Absolut	30	69	-	34	64	5
Prozent	30,303%	69,697%	-	33,010%	62,136%	4,854%

Der erwartete Effekt hat sich also nicht eingestellt. Das Ausmaß der Algorithm Aversion nach Fehlern eines Algorithmus scheint sich unter dem Eindruck eines Decoy-Effekts sogar eher leicht zu verstärken. Der p-Wert im Chi-Quadrat-Test, der alle Entscheidungen aggregiert, liegt bei 0,679, was kein signifikantes Ergebnis ist. Wenn nur die Reaktion auf den ersten (zweiten, ..., n-ten Fehler) eines Algorithmus betrachtet wird, ist der Unterschied zwischen den Treatments nach wie vor nicht signifikant (erster Fehler eines Algorithmus: n = 105, p = 0,781; zweiter Fehler eines Algorithmus: n = 66, p = 0,421; dritter Fehler eines Algorithmus: n = 29, p = 0,453; für mehr als drei Fehler des Algorithmus liegt der Stichprobenumfang bei unter 20 Teilnehmenden).

Eigene Investmententscheidungen der Probanden führen in den ersten neun Spielrunden zu 474 Fehlern: 230 im Treatment 1 (Kontrollgruppe) und 244 im Treatment 2 (Decoy-Effekt). In der Kontrollgruppe behalten 69,130% der Probanden ihre Strategie, eigene Prognosen abzugeben, nach einem Fehler bei. 30,870% wechseln nach eigenen Prognosefehlern in der darauffolgenden Runde hingegen zum Algorithmus. Im Treatment 2 (Decoy-Effekt) sind die Werte fast identisch (Tabelle 7). Hier geben 69,262% der Probanden weiter eigene Prognosen ab, 29,098% setzen auf den Target-Algorithmus und 1,639% auf den Decoy-Algorithmus (Algorithmus gesamt = 30,737%). Auch dieser Unterschied ist im Chi-Quadrat-Test, der alle Entscheidungen aggregiert, eindeutig nicht signifikant (p-Wert = 0,975). Wenn nur die Reaktion auf den ersten (zweiten, ..., n-ten Fehler) eines Probanden selbst betrachtet wird, ist der Unterschied ebenfalls nicht signifikant (erster Fehler eines Probanden: n = 140, p = 0,601; zweiter Fehler eines Probanden: n = 120, p = 0,266; dritter Fehler eines Probanden: n = 95, p = 0,596; vierter Fehler eines Probanden n = 68, p = 0,195; fünfter Fehler eines Probanden n = 32, p = 0,414; für mehr als fünf Fehler eines Probanden liegt der Stichprobenumfang bei unter 20 Teilnehmenden).



Tabelle 7: Reaktionen auf eigene Prognosefehler

Auswahl in Folge- runde	Treatment 1 (Kontrollgruppe)			Treatment 2 (Decoy-Effekt)		
	Eigene Progno- sen	Algorith- mus A	Algo- rith- mus B	Eigene Prognosen	Algorith- mus A	Algorith- mus B
Absolut	159	71	-	169	71	4
Prozent	69,130%	30,870%	-	69,262%	29,098%	1,639%

Es lässt sich also festhalten, dass der Decoy besonders gerne dann genommen wird, wenn eine der anderen beiden Optionen in der vorherigen Runde danebenlag. Das Ausmaß der Algorithm Aversion nach Prognosefehlern bleibt jedoch vom Decoy-Effekt sowohl im Falle von Fehlern des Algorithmus als auch im Falle von Fehlern des Probanden selbst unberührt.


## 5 Diskussion

Stellen Sie sich vor, Sie stehen vor der Entscheidung, ob Sie Ihr privates Vermögen einem neuartigen Robo-Advisor anvertrauen, der Ihnen einen Vermögenszuwachs verspricht. Wie leicht fällt es Ihnen, Vertrauen in die neue Technologie zu entwickeln, wenn so viel auf dem Spiel steht? Der Robo-Advisor ist explizit dafür konzipiert worden, Informationen aus dem Markt zielgerichtet zur Maximierung Ihres Vermögens heranzuziehen, und scheint gegenüber allen Alternativen überlegen zu sein. Aber wird dies dem Robo-Advisor auch in Ihrem Fall gelingen, oder sind Sie vielleicht nicht doch besser dran, wenn Sie die Verwaltung Ihres Vermögens selbst in die Hand nehmen?

Stellen Sie sich nun vor, Sie könnten zwei am Markt verfügbare Robo-Advisors miteinander vergleichen und sich zwischen diesen frei entscheiden. Schnell wird ersichtlich, dass einer der beiden Robo-Advisors im Vergleich zum anderen besonders leistungsstark zu sein scheint. Wie treffen Sie Ihre ursprüngliche Entscheidung nun? Wird es Ihnen gelingen, den zweiten Robo-Advisor in Ihrer Entscheidungsfindung komplett auszublenden, oder führt die Vergleichsmöglichkeit dazu, dass der überlegene erste Robo-Advisor zusätzlich an Attraktivität gewinnt?

Die Ergebnisse dieser Studie liefern erste Anhaltspunkte, dass die Präsenz des zweiten Robo-Advisors kaum etwas verändert. Der Einfluss des Decoy-Effekts auf unser Entscheidungsverhalten wurde bei zahlreichen Produkten und Dienstleistungen aus der analogen Welt nachgewiesen. Die bisherigen Befunde legen eigentlich nahe, dass das Hinzufügen eines weiteren Algorithmus als Decoy dazu führen müsste, dass der Target-Algorithmus größeren Anklang findet. Für Entscheidungen im Kontext neuartiger, komplexer, digitaler Technologien, die vom Phänomen der Algorithm Aversion betroffen sind, scheint dies überraschenderweise nicht zu gelten. Es wurde bereits gezeigt, dass ein Betonen der statistischen Überlegenheit von Algorithmen allein nicht ausreicht, um die Algorithm Aversion zu beheben (z. B. Filiz et al., 2021a). Die Ergebnisse dieser Studie untermauern die Hartnäckigkeit der Algorithm Aversion. Sie ist anscheinend so robust, dass selbst der sonst äußerst zuverlässige Decoy-Effekt nicht gegen sie ankommt (Abbildung 6).

Abbildung 6: Vergleich der Entscheidungen zugunsten des Target-Produkts vor und nach Hinzufügen eines Decoys in verschiedenen Studien



*Sofern in den Studien mehrere Experimente mit unterschiedlichem Design durchgeführt wurden, werden hier stets die Ergebnisse aus dem Forschungsdesign dargestellt, das dem originalen Aufbau von Huber, Payne & Puto (1982) und der vorliegenden Studie am nächsten kommt.*

In dieser Studie wurde der Decoy-Effekt äußerst salient gestaltet. In den Instruktionen wurde den Probanden ein Vergleich des Targets mit dem Decoy in Tabellenform mit leicht vergleichbaren Zahlen an die Hand gegeben (Anhang A). Vor Beginn des Experiments mussten alle Probanden des entsprechenden Treatments in den Kontrollfragen zeigen, dass sie verstanden haben, dass ihnen zwei unterschiedliche Algorithmen zur Verfügung stehen (Anhang B). Zu guter Letzt wurden die Erfolgswahrscheinlichkeiten des Targets und des Decoys in jeder einzelnen Spielrunde unmittelbar im Auswahlbereich des Bildschirms erneut angezeigt (Anhang C). Dass der Decoy in 2,75% der Entscheidungen auch tatsächlich ausgewählt wurde, passt ebenfalls zu den Ergebnissen der Vorgängerstudien (bspw. Yang & Lynn, 2014; Huber, Payne & Puto, 1982) und spricht dafür, dass der Decoy als Entscheidungsmöglichkeit zur Kenntnis genommen wurde.

Der Decoy-Effekt führt aber anders als gewohnt zu keiner Erhöhung der Anteile des Targets. Darüber hinaus ist er auch nicht zum Abbau der Algorithm

Aversion geeignet. Selbst wenn man die Entscheidungen für beide Algorithmen addiert, ergibt sich kaum ein Unterschied zur Kontrollgruppe. Das ist äußerst überraschend. Einerseits scheinen die Probanden so rational zu agieren, dass sie sich vom unterlegenen Decoy in ihrer Entscheidung zwischen Target und Competitor kaum beeinflussen lassen. Andererseits werden mehr als die Hälfte der Entscheidungen für die eigenständige Durchführung der Prognoseaufgabe getroffen, obwohl dabei die Leistung deutlich hinter der eines Algorithmus zurückbleibt.

Das Hauptergebnis dieser Studie ist, dass die Algorithm Aversion sich gegen den Decoy-Effekt durchsetzt, sobald beide einen Einfluss auf eine Entscheidungssituation nehmen. Dies gilt sowohl im gesamten Verlauf des Spiels als auch explizit nach dem Beobachten von Fehlern durch den Algorithmus. Dietvorst, Simmons & Massey (2015) hatten aufgedeckt, dass das Vertrauen in einen Algorithmus nach fehlerhaften Prognosen rapide zurückgeht, was zur ursprünglichen Begriffsprägung der „Algorithm Aversion“ geführt hatte. Die Ergebnisse der vorliegenden Studie legen nahe, dass dieser Befund nicht nur im Kontext „1 Mensch vs. 1 Algorithmus“ gültig zu sein scheint. Wenn ein zusätzlicher Decoy-Algorithmus zur Verfügung steht, geht die Bereitschaft zur Nutzung von Algorithmen nach Fehlern immer noch im gleichen Ausmaß zurück.

In vielen Einsatzgebieten für Algorithmen und KI befinden wir uns aktuell an dem Punkt, an dem erste Angebote als Vorreiter in den Markt eindringen. So sollen zum Beispiel im Jahr 2022 erstmalig autonome Robo-Taxis in Deutschland für die Öffentlichkeit angeboten werden. Für die Anbieter stellt sich dadurch die Frage, wie der Markteinstieg am besten gelingt. Die bisherige Theorie zum Decoy-Effekt hatte impliziert, dass Anbieter zusätzlich zu ihrem Target-Produkt, dass sie am Markt langfristig etablieren wollen, einen Decoy anbieten sollten, um potenzielle Kunden in ihrem Entscheidungsverhalten zugunsten des Targets zu beeinflussen.

Die Ergebnisse dieser Studie zeigen jedoch, dass sich der Marktanteil der neuen Technologien nicht so einfach vergrößern lässt. Vielmehr hegen die potenziellen Nutzer eine große Skepsis gegenüber innovativen, automatisierten Verfahren, die sich nicht durch eine Erweiterung des Angebots um einen Decoy beheben lässt. Den Pionieren digitalisierter und automatisierter Geschäftsideen sollte deshalb empfohlen werden, den Decoy-Effekt nicht als Verkaufsstrategie zu verfolgen. Sie sollten sich eher auf bereits identifizierte Maßnahmen zum Abbau der Algorithm Aversion berufen, wie beispielsweise Einflussmöglichkeiten auf den algorithmischen Output (Dietvorst, Simmons & Massey, 2018) oder Lerneffekte (Filiz et al., 2021b).

Abschließend seien noch einige Aspekte erwähnt, die die Aussagekraft dieser Studie für reale Entscheidungen in der Praxis einschränken können. Um sich an der etablierten Forschung zum Decoy-Effekt zu orientieren, wurden den Teilnehmenden im ökonomischen Experiment lediglich zwei Algorithmen (Target und Decoy) zur Verfügung gestellt. Tatsächlich können wir in der Praxis häufig

zwischen mehr als zwei Angeboten auswählen, die sich auf unterschiedlichste Art und Weise hinsichtlich verschiedener Dimensionen gegenseitig dominieren. Insbesondere die schnelle Skalierbarkeit von digitalen Technologien führt dazu, dass die Auswahl in der Regel schnell zwei Angebote übersteigt. Zweitens sei erwähnt, dass die Ergebnisse im Kontext von Robo-Advisors erzielt wurden. Die Vermögensverwaltung ist jedoch nur ein kleiner Bereich, der von der Algorithm Aversion betroffen ist. Eventuell würden sich beim Einsatz anderer Algorithmen aus Bereichen wie Medizin, Verkehr oder Unterhaltung andere Ergebnisse einstellen. Zu guter Letzt stand in dieser Studie auch keine Untersuchung sozialer Einflüsse im Fokus. Der Mensch ist jedoch ein soziales Wesen. In unserem Alltag findet im Gegensatz zu einem Laborexperiment viel Austausch mit den Mitmenschen statt, der unser Entscheidungsverhalten ebenfalls beeinflusst. Es muss der nachfolgenden Forschung vorbehalten bleiben, diese Aspekte genauer zu analysieren.

## 6 Zusammenfassung

In dieser Studie wird anhand eines ökonomischen Laborexperiments der Einfluss des Decoy-Effekts auf die Algorithm Aversion untersucht. Probanden werden für ein Investmentspiel in zwei Gruppen aufgeteilt und versuchen, ihre Vergütung zu maximieren. In der Kontrollgruppe haben sie in zehn Spielrunden die Wahl, ob sie eine Prognoseaufgabe an einen spezialisierten Algorithmus mit einer Erfolgsquote von 70% delegieren (Target) oder eigenständig bewältigen (Competitor). In der Treatment-Gruppe steht ihnen neben dem ersten Algorithmus und der eigenen Prognoseabgabe auch noch ein zweiter Algorithmus (Decoy) zur Verfügung. Der zweite Algorithmus ist mit dem ersten bis auf eine Ausnahme identisch: Er hat eine deutlich geringere Erfolgsquote von gerade einmal 60%. Wir sprechen vom Decoy-Effekt, wenn eine Option (Decoy) einer anderen Option (Target) in mindestens einer Dimension unterlegen und in keiner übrigen Dimension überlegen ist.

Die Theorie zum Decoy-Effekt legt nahe, dass der erste Algorithmus (Target) in der Treatment-Gruppe deutlich häufiger ausgewählt werden sollte als in der Kontrollgruppe. Sobald der Decoy ins Spiel kommt, wenden Entscheidungsträger regelmäßig eine Heuristik an. Sie vergleichen Target und Decoy und entscheiden sich für das Target, da dieses zumindest dem Decoy eindeutig überlegen ist. Der Competitor büßt in diesem Fall stets Anteile zugunsten des Targets ein. Das Hinzufügen des Decoys liefert schließlich keine zusätzlichen Informationen über den Competitor, sondern nur über das Target.

Im Kontrast zu diesen Überlegungen steht die Algorithm Aversion. Sie beschreibt Vorbehalte der Nutzer gegenüber automatisierten Verfahren (Algorithmen), die sich nicht ohne Weiteres beheben lassen. Wenn ein Nutzer der Algorithm Aversion unterliegt, sollte er sich von der Präsenz eines Decoys nicht beeinflussen lassen, da Algorithmen für ihn generell keine attraktive Option darstellen.

Als erstes zeigt sich, dass die Probanden auch in dieser Studie von der Algorithm Aversion betroffen sind. Obwohl jede Entscheidung zugunsten eines der beiden Algorithmen ihre Vergütung um durchschnittlich 19,793 Cent erhöht, wird in gerade einmal 43,813% der Entscheidungen ein Algorithmus ausgewählt.

Weiterhin zeigt sich, dass die Präsenz eines Decoys keinen Einfluss auf das Ausmaß der Algorithm Aversion hat. Der Anteil der Entscheidungen zugunsten des leistungsstärkeren Target-Algorithmus steigt nach Hinzufügen des Decoys um lediglich 0,375 Prozentpunkte von 42,250% auf 42,625%. Weitere 2,750% der Entscheidungen werden nun zugunsten des leistungsschwächeren Algorithmus (Decoy) getroffen. Der Anteil der eigenen Prognosen durch die Probanden selbst geht leicht von 57,750% auf 54,625% zurück. Der Unterschied erweist sich als nicht signifikant.

Abschließend wird auch die Reaktion auf fehlerhafte Prognosen untersucht. Auf Prognosefehler des Algorithmus wird in etwas über 30% der Fälle in der darauffolgenden Spielrunde mit einem Wechsel zur eigenständigen Prognoseabgabe reagiert. Dieser Anteil unterscheidet sich allerdings nur minimal zwischen den Treatments. Das Verhalten nach Fehlern des Algorithmus wird durch den Decoy-Effekt nicht beeinflusst. Dasselbe gilt auch für das Verhalten nach eigenen fehlerhaften Prognosen. Der Anteil der Wechsel zum Algorithmus ist in beiden Treatments annähernd gleich stark ausgeprägt.

Durch Hinzufügen eines zusätzlichen Algorithmus (Decoy) ändert sich in allen untersuchten Fällen nichts an der Bereitschaft, auf einen spezialisierten Algorithmus zurückzugreifen. Die Algorithm Aversion lässt sich durch den Decoy-Effekt nicht effektiv reduzieren.

## 7

### Literatur

- Alemanni, B., Angelovski, A., di Cagno, D. T., Galliera, A., Linciano, N., Marazzi, F., & Soccorso, P. (2020). Do Investors Rely on Robots? Evidence from an Experimental Study, *CONSOB Fintech Series*, 7.
- Allen, R., & Choudhury, P. (2022). Algorithm-augmented work and domain experience: The countervailing forces of ability and aversion, *Organization Science*, 33(1), 149-169.
- Ariely, D., (2009). Predictably Irrational: The Hidden Forces that Shape Our Decisions, New York.
- Ariely, D., & Wallsten, T. S. (1995). Seeking subjective dominance in multidimensional space: An explanation of the asymmetric dominance effect, *Organizational Behavior and Human Decision Processes*, 63(3), 223-232.
- Back, C., Morana, S., & Spann, M. (2021). Do Robo-Advisors Make Us Better Investors?. Discussion Paper No. 276, Ludwig-Maximilians-Universität München und Humboldt-Universität zu Berlin, Collaborative Research Center Transregio 190 – Rationality and Competition, München und Berlin. URL: <http://hdl.handle.net/10419/233499>
- Ben David, D., Resheff, Y. S., & Tron, T. (2021). Explainable AI and Adoption of Financial Algorithmic Advisors: An Experimental Study, *Proceedings of the 2021 AAAI/ACM Conference on AI, Ethics, and Society*, 390-400.
- Berger, B., Adam, M., Rühr, A., & Benlian, A. (2020). Watch Me Improve—Algorithm Aversion and Demonstrating the Ability to Learn, *Business & Information Systems Engineering*, 1-14.
- Bogert, E., Schechter, A., & Watson, R. T. (2021). Humans rely more on algorithms than social influence as a task becomes more difficult, *Scientific reports*, 11(1), 1-9.
- Burton, J., Stein, M. & Jensen, T. (2020). A systematic review of algorithm aversion in augmented decision making, *Journal of Behavioral Decision Making*, 33(2), 220-239.
- Castelo, N., Bos, M. W., & Lehmann, D. R. (2019). Task-dependent algorithm aversion, *Journal of Marketing Research*, 56(5), 809-825.
- Crosetto, P., & Gaudeul, A. (2016). A monetary measure of the strength and robustness of the attraction effect, *Economics Letters*, 149, 38-43.
- Dietvorst, B. J., Simmons, J. P. & Massey, C. (2018). Overcoming algorithm aversion: People will use imperfect algorithms if they can (even slightly) modify them, *Management Science*, 64(3), 1155-1170.



- Dietvorst, B. J., Simmons, J. P. & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err, *Journal of Experimental Psychology*, 144(1), 114-126.
- Efendić, E., Van de Calseyde, P. P. & Evans, A. M. (2020). Slow response times undermine trust in algorithmic (but not human) predictions, *Organizational Behavior and Human Decision Processes*, 157(C), 103-114.
- Filiz, I., Judek, J. R., Lorenz, M., & Spiwoks, M. (2021a). The Tragedy of Algorithm Aversion, *Wolfsburg Working Papers 21-02*, Wolfsburg.
- Filiz, I., Judek, J. R., Lorenz, M., & Spiwoks, M. (2021b). Reducing algorithm aversion through experience, *Journal of Behavioral and Experimental Finance*, 31, 100524.
- Fischbacher, U. (2007). z-Tree: Zurich Toolbox for Ready-made Economic Experiments, *Experimental Economics*, 10(2), 171-178.
- Frederick, S., Lee, L., & Baskin, E. (2014). The limits of attraction, *Journal of Marketing Research*, 51(4), 487-507.
- Gaube, S., Suresh, H., Raue, M., Merritt, A., Berkowitz, S. J., Lerner, E. & Ghassemi, M. (2021). Do as AI say: susceptibility in deployment of clinical decision-aids, *NPJ digital medicine*, 4(1), 1-8.
- Germann, M., & Merkle, C. (2020). Algorithm Aversion in Financial Investing, Working Paper. URL: <http://dx.doi.org/10.2139/ssrn.3364850>
- Herne, K. (1999). The effects of decoy gambles on individual choice, *Experimental Economics*, 2(1), 31-40.
- Huber, J., Payne, J. W., & Puto, C. (1982). Adding asymmetrically dominated alternatives: Violations of regularity and the similarity hypothesis, *Journal of consumer research*, 9(1), 90-98.
- Ireland, L. (2020). Who errs? Algorithm aversion, the source of judicial error, and public support for self-help behaviors, *Journal of Crime and Justice*, 43(2), 174-192.
- Jussupow, E., Benbasat, I., & Heinzl, A. (2020). Why are we averse towards Algorithms? A comprehensive literature Review on Algorithm aversion, Proceedings of the 28th European Conference on Information Systems (ECIS). URL: [https://aisel.aisnet.org/ecis2020\\_rp/168](https://aisel.aisnet.org/ecis2020_rp/168)
- Kawaguchi, K. (2021). When will workers follow an algorithm? A field experiment with a retail business, *Management Science*, 67(3), 1670-1695.
- Kim, J., Giroux, M., & Lee, J. C. (2021). When do you trust AI? The effect of number presentation detail on consumer trust and acceptance of AI recommendations, *Psychology & Marketing*, 38, 1140-1155.

- Köbis, N. & Mossink, L. D. (2021). Artificial intelligence versus Maya Angelou: Experimental evidence that people cannot differentiate AI-generated from human-written poetry, *Computers in Human Behavior*, 114(2021), 1-13.
- Kroll, E. B., & Vogt, B. (2012). The relevance of irrelevant alternatives, *Economics Letters*, 115(3), 435-437.
- Lennartz, S., Dratsch, T., Zopfs, D., Persigehl, T., Maintz, D., Hokamp, N. G., & Dos Santos, D. P. (2021). Use and Control of Artificial Intelligence in Patients Across the Medical Workflow: Single-Center Questionnaire Study of Patient Perspectives, *Journal of Medical Internet Research*, 23(2), e24221, 1-10.
- Leyer, M., & Schneider, S. (2019). Me, you or AI? How do we feel about delegation, *Twenty-Seventh European Conference on Information Systems (ECIS2019)*, Stockholm-Uppsala, Sweden. URL: [https://aisel.aisnet.org/ecis2019\\_rp/36/](https://aisel.aisnet.org/ecis2019_rp/36/)
- Longoni, C., Bonezzi, A., & Morewedge, C. K. (2019). Resistance to medical artificial intelligence, *Journal of Consumer Research*, 46(4), 629-650.
- Mahmud, H., Islam, A. N., Ahmed, S. I., & Smolander, K. (2022). What influences algorithmic decision-making? A systematic literature review on algorithm aversion, *Technological Forecasting and Social Change*, 175, 121390, 1-26.
- Malkoc, S. A., Hedgcock, W., & Hoeffler, S. (2013). Between a rock and a hard place: The failure of the attraction effect among unattractive alternatives, *Journal of Consumer Psychology*, 23(3), 317-329.
- Meehl, P. (1955). *Clinical Versus Statistical Prediction: A Theoretical Analysis and a Review of the Evidence*, University of Minnesota Press, Minneapolis.
- Niszczoła, P. & Kaszás, D. (2020). Robo-investment aversion, *PLoS ONE*, 15(9), 1-19.
- Önkal, D., Goodwin, P., Thomson, M., Gönül, S. & Pollock, A. (2009). The Relative Influence of Advice from Human Experts and Statistical Methods on Forecast Adjustments, *Journal of Behavioral Decision Making*, 22(4), 390-409.
- Park, J., & Kim, J. (2005). The effects of decoys on preference shifts: The role of attractiveness and providing justification, *Journal of Consumer Psychology*, 15(2), 94-107.
- Pezzo, M. V., & Beckstead, J. W. (2020). Algorithm aversion is too often presented as though it were non-compensatory: A reply to Longoni et al. (2020), *Judgment and Decision Making*, 15(3), 449.

- Promberger, M., & Baron, J. (2006). Do patients trust computers?, *Journal of Behavioral Decision Making*, 19(5), 455-468.
- Rebitschek, F. G., Gigerenzer, G., & Wagner, G. G. (2021). People underestimate the errors by algorithms for credit scoring and recidivism but tolerate even fewer errors, Preprint. URL: [http://pure.mpg.de/rest/items/item\\_3307252/component/file\\_3307253/content](http://pure.mpg.de/rest/items/item_3307252/component/file_3307253/content)
- Rencher, A. C., & Schaalje, G. B. (2008). Linear models in statistics (Second Edition), John Wiley & Sons, Hoboken, New Jersey.
- Simonson, I. (1989). Choice based on reasons: The case of attraction and compromise effects. *Journal of consumer research*, 16(2), 158-174.
- Wang, R., Harper, F. M., & Zhu, H. (2020). Factors Influencing Perceived Fairness in Algorithmic Decision-Making: Algorithm Outcomes, Development Procedures, and Individual Differences, *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, Paper 684, 1-14.
- Wang, Z., Jusup, M., Shi, L., Lee, J. H., Iwasa, Y., & Boccaletti, S. (2018). Exploiting a cognitive bias promotes cooperation in social dilemma experiments, *Nature communications*, 9(1), 1-7.
- Yang, S., & Lynn, M. (2014). More evidence challenging the robustness and usefulness of the attraction effect, *Journal of Marketing Research*, 51(4), 508-513.
- Yeomans, M., Shah, A., Mullainathan, S., & Kleinberg, J. (2019). Making sense of recommendations, *Journal of Behavioral Decision Making*, 32(4), 403-414.

## 8 Anhang

### 8.1 Anhang A: Instruktionen

#### Instruktionen Treatment 1 (Kontrollgruppe)

##### Das Spiel

In diesem Spiel werden Sie gebeten, im Verlauf von zehn Spielrunden jeweils eine Investmententscheidung zu treffen. Sie erhalten dafür ein Budget an Experimentalwährung (ECU) in Höhe von je 10 ECU pro Runde. In jeder einzelnen der zehn Spielrunden können Sie jeweils 10 ECU entweder in die Z-Aktie investieren oder sparen. Sie investieren oder sparen immer den vollen Betrag, eine Aufteilung des Budgets innerhalb einer Spielrunde ist nicht möglich.

Wenn Sie die 10 ECU in Z-Aktien investieren, so kaufen Sie die Aktien zu Beginn der Periode und verkaufen die Aktien am Ende der Periode wieder. Der Verkaufspreis wird Ihrem Guthaben gutgeschrieben. Er kann über oder unter dem anfänglich von Ihnen investierten Betrag von 10 ECU liegen, je nachdem, ob der Kurs der Z-Aktie in der Runde gestiegen oder gefallen ist.

Wenn der Kurs der Z-Aktie innerhalb einer Runde beispielsweise um 10% steigt, und Sie 10 ECU in die Z-Aktie investiert haben, so werden Ihrem Guthaben 11 ECU gutgeschrieben. Wenn der Kurs der Z-Aktie innerhalb einer Runde beispielsweise um 10% fällt, und Sie 10 ECU in die Z-Aktie investiert haben, so werden Ihrem Guthaben 9 ECU gutgeschrieben. Sie können also gezielt in den Runden in die Z-Aktie investieren, in denen Sie einen Kursanstieg erwarten.

Der Aktienkurs der Z-Aktie ergibt sich stets aus vier Einflussfaktoren (siehe Tabelle 8) sowie einem Zufallseinfluss. Die Werte der Einflussfaktoren werden Ihnen vor jeder Spielrunde bekanntgegeben.

Tabelle 8: Einflussfaktoren auf die Aktienkursbildung der Z-Aktie

Einflussfaktor	Spannweite	Einfluss	Stärke des Einflusses
A	5 bis 15	Positiv	Stark
B	5 bis 25	Positiv	Mittel
C	0 bis 10	Negativ	Mittel
D	15 bis 35	Positiv	Gering
Zufallseinfluss	-2 bis +2	Positiv	Mittel

Die Einflussfaktoren A, B, D und der Zufallseinfluss wirken sich positiv auf den Aktienkurs aus. Das heißt, wenn diese Einflussfaktoren im oberen Bereich ihrer Spannweite liegen (also über dem Durchschnitt der Vorperioden), steigt tendenziell der Aktienkurs während der kommenden Spielrunde.

Der Einflussfaktor C wirkt sich negativ auf den Aktienkurs aus. Das heißt, wenn dieser Einflussfaktor im oberen Bereich seiner Spannweite liegt (also über dem Durchschnitt der Vorperioden), fällt tendenziell der Aktienkurs während der kommenden Runde. Die Einflussfaktoren haben einen unterschiedlich starken Einfluss auf den Aktienkurs (Tabelle 8).

Alternativ können Sie das Rundenbudget in Höhe von 10 ECU sparen. Für die jeweilige Runde werden Ihrem Guthaben dann 10 ECU gutgeschrieben.

Ihr Guthaben wird über die 10 Spielrunden aufgebaut und am Ende des Spiels zur Berechnung Ihrer Vergütung verwendet. Unabhängig von Ihren Entscheidungen in den vorherigen Runden können Sie in jeder neuen Runde immer exakt 10 ECU investieren oder sparen.

### **Auswahl zwischen eigener Durchführung und Algorithmus**

Sie können außerdem in jeder Spielrunde auswählen, ob Sie Ihr Rundenbudget eigenständig verwalten oder einem Robo-Advisor (Algorithmus) anvertrauen möchten.

Sofern Sie sich für den Algorithmus entscheiden, wird dieser an Ihrer Stelle Ihr Rundenbudget von 10 ECU in der jeweiligen Spielrunde entweder in Z-Aktien investieren oder sparen. Der Algorithmus entscheidet sich immer dann für ein Investieren Ihrer ECU, wenn sein Modell einen steigenden Aktienkurs vorhersagt. Wenn sein Modell einen sinkenden Aktienkurs vorhersagt, so wird er Ihr Guthaben in der jeweiligen Runde sparen.

In der Vergangenheit hat sich gezeigt, dass der Algorithmus in 7 von 10 Fällen (70%) diejenige Entscheidung (investieren oder sparen) trifft, die zu einem höheren Ertrag führt.

### **Vergütung**

Die Vergütungsstruktur gestaltet sich unabhängig davon, ob Sie Ihr Budget eigenständig verwalten oder dem Algorithmus anvertrauen. Am Ende des Spiels wird Ihr in den zehn Spielrunden insgesamt erspieltes, kumuliertes Guthaben betrachtet. Es werden 95 der ursprünglich zugewiesenen 100 ECU (je 10 ECU in 10 Spielrunden) von Ihrem Guthaben abgezogen. Der übrige Betrag wird im Verhältnis 1 ECU = 1 EUR gegen echtes Geld eingetauscht und Ihnen als Ihre Vergütung ausgezahlt.

## Ablauf

Nach dem Lesen der Instruktionen und der Beantwortung der Kontrollfragen startet die erste vergütete Spielrunde (Periode 11 von 20) an Ihrem Bildschirm.

Zu Beginn jeder Spielrunde sehen Sie den Kursverlauf der Z-Aktie, den Verlauf der Einflussfaktoren und den Verlauf der Zufallseinflüsse für die letzten zehn Spielrunden (Periode 1 bis 10), um sich ein Bild von der Entwicklung machen zu können. Außerdem werden Ihnen stets die aktuellen Werte der vier Einflussfaktoren für die jeweilige Spielrunde bekanntgegeben. Der Wert des Zufallseinflusses ist hingegen vorab unbekannt. Anschließend treffen Sie für die jeweilige Spielrunde Ihre Entscheidung, ob Sie Ihr Rundenbudget eigenständig verwalten oder dem Robo-Advisor (Algorithmus) anvertrauen möchten.

Wenn Sie sich für die eigenständige Durchführung entscheiden, so können Sie weiterhin auswählen, ob Sie in der jeweiligen Runde 10 ECU in Z-Aktien investieren oder sparen möchten.

Wenn Sie sich für den Algorithmus entscheiden, so trifft dieser die Entscheidung zwischen Investieren und Sparen an Ihrer Stelle.

Nach Abgabe der Entscheidung werden Sie in jedem Fall über die Entwicklung des Aktienkurses der Z-Aktie informiert, unabhängig davon, ob Sie investiert oder gespart haben. Sie erhalten also in jedem Fall die vollständigen Informationen. Der erzielte Ertrag aus der Investition in Z-Aktien bzw. der gesparte Betrag wird Ihrem Guthaben gutgeschrieben.

Insgesamt werden zehn Runden gespielt. Nach Abschluss des Experiments erhalten Sie Ihre Vergütung, die sich nach dem unter „Vergütung“ beschriebenen Schema errechnet.

## Hinweise

- Bitte verhalten Sie sich während des Experiments ruhig!
- Bitte schauen Sie Ihren Nachbarn nicht auf den Bildschirm!
- Bis auf einen Stift und einen Taschenrechner sind **keine** weiteren Hilfsmittel (Smartphones, Smartwatches, etc.) zugelassen.
- Verwenden Sie für Ihre Notizen ausschließlich das zur Verfügung gestellte weiße Blatt Papier.

## Instruktionen Treatment 2 (Decoy-Effekt)

### Das Spiel

In diesem Spiel werden Sie gebeten, im Verlauf von zehn Spielrunden jeweils eine Investmententscheidung zu treffen. Sie erhalten dafür ein Budget an Experimentalwahrung (ECU) in Hohle von je 10 ECU pro Runde. In jeder einzelnen der zehn Spielrunden konnen Sie jeweils 10 ECU entweder in die Z-Aktie investieren oder sparen. Sie investieren oder sparen immer den vollen Betrag, eine Aufteilung des Budgets innerhalb einer Spielrunde ist nicht moglich.

Wenn Sie die 10 ECU in Z-Aktien investieren, so kaufen Sie die Aktien zu Beginn der Periode und verkaufen die Aktien am Ende der Periode wieder. Der Verkaufspreis wird Ihrem Guthaben gutgeschrieben. Er kann uber oder unter dem anfanglich von Ihnen investierten Betrag von 10 ECU liegen, je nachdem, ob der Kurs der Z-Aktie in der Runde gestiegen oder gefallen ist.

Wenn der Kurs der Z-Aktie innerhalb einer Runde beispielsweise um 10% steigt, und Sie 10 ECU in die Z-Aktie investiert haben, so werden Ihrem Guthaben 11 ECU gutgeschrieben. Wenn der Kurs der Z-Aktie innerhalb einer Runde beispielsweise um 10% fallt, und Sie 10 ECU in die Z-Aktie investiert haben, so werden Ihrem Guthaben 9 ECU gutgeschrieben. Sie konnen also gezielt in den Runden in die Z-Aktie investieren, in denen Sie einen Kursanstieg erwarten.

Der Aktienkurs der Z-Aktie ergibt sich stets aus vier Einflussfaktoren (siehe Tabelle 9) sowie einem Zufallseinfluss. Die Werte der Einflussfaktoren werden Ihnen vor jeder Spielrunde bekanntgegeben.

Tabelle 9: Einflussfaktoren auf die Aktienkursbildung der Z-Aktie

Einflussfaktor	Spannweite	Einfluss	Starke des Einflusses
A	5 bis 15	Positiv	Stark
B	5 bis 25	Positiv	Mittel
C	0 bis 10	Negativ	Mittel
D	15 bis 35	Positiv	Gering
Zufallseinfluss	-2 bis +2	Positiv	Mittel

Die Einflussfaktoren **A**, **B**, **D** und der Zufallseinfluss wirken sich positiv auf den Aktienkurs aus. Das heit, wenn diese Einflussfaktoren im oberen Bereich ihrer Spannweite liegen (also uber dem Durchschnitt der Vorperioden), steigt tendenziell der Aktienkurs wahrend der kommenden Spielrunde.

Der Einflussfaktor **C** wirkt sich negativ auf den Aktienkurs aus. Das heit, wenn dieser Einflussfaktor im oberen Bereich seiner Spannweite liegt (also uber dem Durchschnitt der Vorperioden), fallt tendenziell der Aktienkurs wahrend der

kommenden Runde. Die Einflussfaktoren haben einen unterschiedlich starken Einfluss auf den Aktienkurs (Tabelle 9). Alternativ können Sie das Rundenbudget in Höhe von 10 ECU sparen. Für die jeweilige Runde werden Ihrem Guthaben dann 10 ECU gutgeschrieben.

Ihr Guthaben wird über die 10 Spielrunden aufgebaut und am Ende des Spiels zur Berechnung Ihrer Vergütung verwendet. Unabhängig von Ihren Entscheidungen in den vorherigen Runden können Sie in jeder neuen Runde immer exakt 10 ECU investieren oder sparen.

### Auswahl zwischen eigener Durchführung und Algorithmen

Sie können außerdem in jeder Spielrunde auswählen, ob Sie Ihr Rundenbudget eigenständig verwalten oder einem von zwei Robo-Advisors (Algorithmen) anvertrauen möchten.

Sofern Sie sich für einen der Algorithmen entscheiden, wird dieser an Ihrer Stelle Ihr Rundenbudget von 10 ECU in der jeweiligen Spielrunde entweder in Z-Aktien investieren oder sparen. Der Algorithmus entscheidet sich immer dann für ein Investieren Ihrer ECU, wenn sein Modell einen steigenden Aktienkurs vorhersagt. Wenn sein Modell einen sinkenden Aktienkurs vorhersagt, so wird er Ihr Guthaben in der jeweiligen Runde sparen.

Für die Aufgabe stehen Ihnen die Algorithmen A und B zur Verfügung (siehe Tabelle 10). In der Vergangenheit hat sich gezeigt, dass Algorithmus A in 7 von 10 Fällen (70%) diejenige Entscheidung (investieren oder sparen) trifft, die zu einem höheren Ertrag führt. Weiterhin hat sich gezeigt, dass Algorithmus B in 6 von 10 Fällen (60%) die vorteilhafte Entscheidung trifft.

Tabelle 10: Eigenschaften der Algorithmen

Eigenschaft	Algorithmus A	Algorithmus B
Jahr der Fertigstellung	2022	2022
Hersteller	Ostfalia Analytics	Ostfalia Analytics
Erfolgsquote	70%	60%

### Vergütung

Die Vergütungsstruktur gestaltet sich unabhängig davon, ob Sie Ihr Budget eigenständig verwalten oder einem Algorithmus anvertrauen. Am Ende des Spiels wird Ihr in den zehn Spielrunden insgesamt erspieltes, kumuliertes Guthaben betrachtet. Es werden 95 der ursprünglich zugewiesenen 100 ECU (je 10 ECU in 10 Spielrunden) von Ihrem Guthaben abgezogen. Der übrige Betrag wird im Verhältnis 1 ECU = 1 EUR gegen echtes Geld eingetauscht und Ihnen als Ihre Vergütung ausgezahlt.



### Ablauf

Nach dem Lesen der Instruktionen und der Beantwortung der Kontrollfragen startet die erste vergütete Spielrunde (Periode 11 von 20) an Ihrem Bildschirm.

Zu Beginn jeder Spielrunde sehen Sie den Kursverlauf der Z-Aktie, den Verlauf der Einflussfaktoren und den Verlauf der Zufallseinflüsse für die letzten zehn Spielrunden (Periode 1 bis 10), um sich ein Bild von der Entwicklung machen zu können. Außerdem werden Ihnen stets die aktuellen Werte der vier Einflussfaktoren für die jeweilige Spielrunde bekanntgegeben. Der Wert des Zufallseinflusses ist hingegen vorab unbekannt. Anschließend treffen Sie für die jeweilige Spielrunde Ihre Entscheidung, ob Sie Ihr Rundenbudget eigenständig verwalten, dem Robo-Advisor A (Algorithmus) anvertrauen möchten oder dem Robo-Advisor B (Algorithmus) anvertrauen möchten.

Wenn Sie sich für die eigenständige Durchführung entscheiden, so können Sie weiterhin auswählen, ob Sie in der jeweiligen Runde 10 ECU in Z-Aktien investieren oder sparen möchten.

Wenn Sie sich für einen Algorithmus entscheiden, so trifft dieser die Entscheidung zwischen Investieren und Sparen an Ihrer Stelle.

Nach Abgabe der Entscheidung werden Sie in jedem Fall über die Entwicklung des Aktienkurses der Z-Aktie informiert, unabhängig davon, ob Sie investiert oder gespart haben. Sie erhalten also in jedem Fall die vollständigen Informationen. Der erzielte Ertrag aus der Investition in Z-Aktien bzw. der gesparte Betrag wird Ihrem Guthaben gutgeschrieben.

Insgesamt werden zehn Runden gespielt. Nach Abschluss des Experiments erhalten Sie Ihre Vergütung, die sich nach dem unter „Vergütung“ beschriebenen Schema errechnet.

### Hinweise

- Bitte verhalten Sie sich während des Experiments ruhig!
- Bitte schauen Sie Ihren Nachbarn nicht auf den Bildschirm!
- Bis auf einen Stift und einen Taschenrechner sind **keine** weiteren Hilfsmittel (Smartphones, Smartwatches, etc.) zugelassen.
- Verwenden Sie für Ihre Notizen ausschließlich das zur Verfügung gestellte weiße Blatt Papier.

## 8.2

### Anhang B: Kontrollfragen

**Kontrollfrage 1:** Wie viele Spielrunden umfasst dieses ökonomische Experiment?

- a) 5.
- b) 10. *(Zutreffend!)*
- c) 15.

**Kontrollfrage 2 (Treatment 1):** Welche Alternativen haben Sie in jeder Runde?

- a) Ich muss die Investmentaufgabe eigenständig durchführen.
- b) Ich kann die Investmentaufgabe eigenständig durchführen oder an einen Finanzexperten delegieren.
- c) Ich kann die Investmentaufgabe eigenständig durchführen oder an einen Robo-Advisor (Algorithmus) delegieren. *(Zutreffend!)*

**Kontrollfrage 2 (Treatment 2):** Welche Alternativen haben Sie in jeder Runde?

- a) Ich muss die Investmentaufgabe eigenständig durchführen.
- b) Ich kann die Investmentaufgabe eigenständig durchführen oder an einen Finanzexperten delegieren.
- c) Ich kann die Investmentaufgabe eigenständig durchführen oder an einen von zwei Robo-Advisors (Algorithmen) delegieren. *(Zutreffend!)*

**Kontrollfrage 3:** Welche Einflussfaktoren wirken sich positiv auf den Kurs der Z-Aktie aus?

- a) Die Einflussfaktoren A, B und C.
- b) Die Einflussfaktoren A, B und D. *(Zutreffend!)*
- c) Die Einflussfaktoren A, C und D.

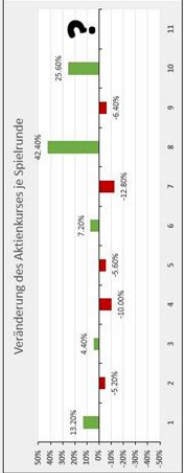
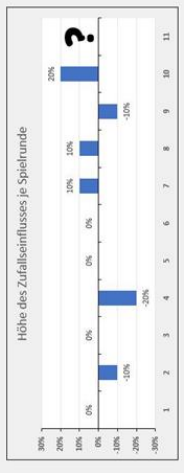
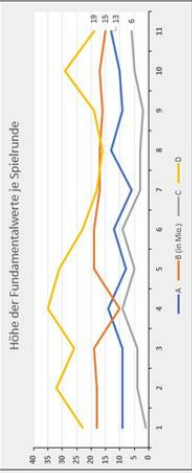
**Kontrollfrage 4:** Wie berechnet sich Ihre Vergütung?

- a) Vom insgesamt erspielten Guthaben werden 100 ECU abgezogen. Der verbleibende Betrag wird im Verhältnis 1 ECU = 0,10 EUR umgetauscht.
- b) Vom insgesamt erspielten Guthaben werden 100 ECU abgezogen. Der verbleibende Betrag wird im Verhältnis 1 ECU = 1 EUR umgetauscht.
- c) Vom insgesamt erspielten Guthaben werden 95 ECU abgezogen. Der verbleibende Betrag wird im Verhältnis 1 ECU = 1 EUR umgetauscht. *(Zutreffend!)*

### 8.3 Anhang C: Bildschirmgestaltung

Abbildung 7: Bildschirmgestaltung in Treatment 1 (Kontrollgruppe)

**Spielrunde 11 von 20**  
Ihr Guthaben beträgt: 0.00 ECU

<p><b>Historie der Kursentwicklungen:</b></p>  <p style="font-size: small;">Veränderung des Aktienkurses je Spielrunde</p>	<p><b>Historie der Zufallseinflüsse:</b></p>  <p style="font-size: small;">Höhe des Zufallseinflusses je Spielrunde</p>
<p><b>Historie und aktuelle Fundamentalwerte:</b></p>  <p style="font-size: small;">Höhe der Fundamentalwerte je Spielrunde</p>	<p><b>Bitte entscheiden Sie sich nun, wie Sie Ihr Rundenbudget in Höhe von 10 ECU einsetzen wollen.</b></p> <p>Ihre Entscheidung für diese Spielrunde:</p> <p><input type="radio"/> Ich vertraue mein Rundenbudget selbst. Ich möchte mein Rundenbudget in die 2. Aktie investieren.</p> <p><input type="radio"/> Ich vertraue mein Rundenbudget selbst. Ich möchte mein Rundenbudget sparen.</p> <p><input type="radio"/> Ich vertraue mein Rundenbudget dem Robo-Aktilist an.</p>

OK

Abbildung 8: Bildschirmgestaltung in Treatment 2 (Decoy-Effekt)

**Spielrunde 11 von 20**  
Ihr Guthaben beträgt: 0.00 ECU

**Höhe des Zufallseinflusses je Spielrunde**

Runde	Einfluss
1	-30%
2	-10%
3	0%
4	0%
5	0%
6	0%
7	10%
8	10%
9	10%
10	20%
11	?

---

**Historie der Kursentwicklungen:**

Runde	Veränderung
1	13.20%
2	-5.20%
3	-4.60%
4	-10.00%
5	-18.80%
6	-4.40%
7	7.20%
8	42.40%
9	25.60%
10	-4.40%
11	?

**Bitte entscheiden Sie sich nun, wie Sie Ihr Rundenbudget in Höhe von 10 ECU einsetzen wollen.**

**Ihre Entscheidung für diese Spielrunde:**

- Ich verhalte mein Rundenbudget selbst. Ich möchte mein Rundenbudget in die 2 Aktien investieren.
- Ich verhalte mein Rundenbudget selbst. Ich möchte mein Rundenbudget sichern.
- Ich verlaue mein Rundenbudget dem Robo-Akteur A mit einer Erfolgsquote von 70% an.
- Ich verlaue mein Rundenbudget dem Robo-Akteur B mit einer Erfolgsquote von 60% an.

---

**Historie und aktuelle Fundamentaltwerte:**

**Höhe der Fundamentaltwerte je Spielrunde**

51

