

## **Den Teufel mit dem Beelzebub austreiben?**

Zum Zusammenwirken von Verlustaversion und Algorithmusaversion

**Bizer, K.; Filiz, I.; Kirchhoff, F.; Nahmer, T.;  
Spiwoks, M.**

sofia-Diskussionsbeitrag Nr. 24-5, Darmstadt 2024

# Den Teufel mit dem Beelzebub austreiben?

Zum Zusammenwirken von Verlustaversion und Algorithmusaversion

Kilian Bizer, Ibrahim Filiz, Florian Kirchhoff, Thomas Nahmer  
und Markus Spiwoks

**JEL Codes:** D81, D91, G41, O33

**Key Words:** Algorithm aversion, loss aversion, decision making under risk, behavioral economics, experiments.

**Abstract:**

Algorithmusaversion beschreibt eine Verhaltensanomalie, nach der Menschen effizienteren, algorithmusbasierten Systemen misstrauen und stattdessen menschliches Urteilsvermögen bevorzugen. Wirtschaftssubjekte laufen damit Gefahr, nicht ihren maximal erreichbaren Nutzen zu realisieren. Diese Studie soll einen Beitrag zu der Frage leisten, wie Algorithmusaversion reduziert werden kann. Im Rahmen eines Laborexperiments wird dafür überprüft, ob die bereits intensiv erforschte, wirkungsvolle Verhaltensanomalie der Verlustaversion zur Reduktion von Algorithmusaversion beitragen kann. Tatsächlich zeigt sich, dass das Gegenteil der Fall zu sein scheint: Die Bereitschaft, einen im Vergleich zu einem menschlichen Experten erkennbar leistungsfähigeren Algorithmus einzusetzen, geht sogar zurück, wenn bei der Entscheidung ein Verlust droht. Dieser Befund stützt andere Forschungsergebnisse, wonach Algorithmusaversion bei schwerwiegenden möglichen Konsequenzen verstärkt auftritt. Zur Verbreitung algorithmusbasierter Systeme scheint es daher angebracht zu sein, die mit ihrem Einsatz verbundenen Chancen auf Zugewinne zu betonen und sie nicht als Hilfsmittel zur Verlustvermeidung zu bewerben.

**Kilian Bizer**, University of Göttingen, Department of Economics, Platz der Göttinger Sieben 3, 37073 Göttingen, Germany, Tel: +49-551-39-24602, e-mail: [bizer@wiwi.uni-goettingen.de](mailto:bizer@wiwi.uni-goettingen.de), <https://orcid.org/0000-0002-2258-7725>

**Ibrahim Filiz**, Ostfalia University of Applied Sciences, Faculty of Business, Siegfried-Ehlers-Str. 1, D-38440 Wolfsburg, Germany, e-mail: [ibrahim.filiz@ostfalia.de](mailto:ibrahim.filiz@ostfalia.de)

**Florian Kirchhoff**, Ostfalia University of Applied Sciences, Faculty of Business, Siegfried-Ehlers-Str. 1, D-38440 Wolfsburg, Germany, Tel.: +49 5361 892 225 420, e-mail: [fl.kirchhoff@ostfalia.de](mailto:fl.kirchhoff@ostfalia.de), <https://orcid.org/0009-0009-2482-1560>

**Thomas Nahmer**, Ostfalia University of Applied Sciences, Faculty of Business, Siegfried-Ehlers-Str. 1, D-38440 Wolfsburg, Germany, e-mail: [th.nahmer@ostfalia.de](mailto:th.nahmer@ostfalia.de)

**Markus Spiwoks**, Ostfalia University of Applied Sciences, Faculty of Business, Siegfried-Ehlers-Str. 1, D-38440 Wolfsburg, Germany, Tel.: +49 5361 892 225 100, e-mail: [m.spiwoks@ostfalia.de](mailto:m.spiwoks@ostfalia.de)

## Inhalt

<b>1 Einführung</b> .....	<b>3</b>
<b>2 Literaturüberblick</b> .....	<b>5</b>
<b>3 Forschungsdesign und Hypothesen</b> .....	<b>9</b>
<b>4 Ergebnisse</b> .....	<b>12</b>
<b>5 Zusammenfassung</b> .....	<b>14</b>
<b>Danksagung</b> .....	<b>15</b>
<b>Literatur</b> .....	<b>16</b>
<b>Anhang</b> .....	<b>22</b>

## Abbildungen

<b>Abb. 1: Entscheidungen für den Experten oder den Algorithmus nach Treatments</b> .....	<b>12</b>
---	-----------

## Tabellen

<b>Tab. 1: Übersicht der monetären Implikationen und Erwartungswerte der Entscheidungsalternativen</b> .....	<b>10</b>
<b>Tab. 2: Entscheidungen für den Experten oder den Algorithmus nach Treatments</b> .....	<b>12</b>

# 1 Einführung

Unsere Entscheidungsfindung wird zunehmend durch algorithmusbasierte Hilfsmittel unterstützt, die oftmals effizienter große Datenmengen auswerten und resistenter gegenüber Voreingenommenheit und Verzerrungen sind als Menschen (vgl. z.B. Sunstein, 2023). Dennoch misstrauen Menschen oftmals Algorithmen und bevorzugen stattdessen menschliches Urteilsvermögen. Diese Verhaltensanomalie wurde erstmals von Dietvorst et al. (2015) als „Algorithmusaversion“ bezeichnet. Sie erschwert die Verbreitung effizienterer, algorithmusbasierter Entscheidungshilfen und Systeme in einer zunehmenden Anzahl von Anwendungsfällen. Beispiele sind autonome Fahrzeuge (vgl. z.B. Shariff et al., 2017), die Erstellung medizinischer Diagnosen (vgl. z.B. Majumdar & Ward, 2011), als Unterstützung bei Gerichtsverfahren (vgl. z.B. Simpson, 2016) oder vermögensverwaltende Robo-Advisors (vgl. z.B. Filiz et al., 2022). Der Verzicht auf derartige Entscheidungshilfen ist schädlich für Wirtschaftssubjekte im Speziellen und die Gesellschaft in Gänze, wenn diese dadurch langfristig unter ihrem maximal erreichbaren Nutzen zurückbleibt. Wenn man anerkennt, dass Algorithmusaversion schädlich ist, drängt sich die Frage auf, wie sich das Auftreten dieser Verhaltensanomalie in wichtigen Entscheidungssituationen reduzieren lässt.

Kahneman & Tversky (1979) und Tversky & Kahneman (1981) zeigen, dass sich Entscheidungssituationen unterschiedlich betrachten lassen und Verluste oftmals stärker wirken als Gewinne (Verlustaversion). So kann in konkreten Entscheidungssituationen auch der Nutzen von Algorithmen unterschiedlich dargestellt werden. Entweder wird der mögliche Nutzenzugewinn hervorgehoben, oder es wird auf die Vermeidung von Nutzeneinbußen hingewiesen. Dementsprechend können Algorithmen in autonomen Fahrzeugen beispielsweise dazu beitragen, dass im Straßenverkehr mehr Sicherheit für alle Beteiligten hinzugewonnen oder aber mehr Verkehrsunfälle und Schäden vermieden werden. Eine effizientere Auswertung von MRT-Scans durch Algorithmen kann helfen, die Gesundheit zurückzugewinnen oder aber weitere gesundheitliche Einbußen zu vermeiden. Vor Gericht können Algorithmen helfen, Prozesse zu gewinnen oder aber Freiheit nicht zu verlieren und Strafen zu vermeiden. Als Robo-Advisor können Algorithmen dabei helfen, risikoadjustierte relative Gewinne zu erwirtschaften oder aber risikoadjustierte relative Verluste zu vermeiden.

Zum einen lässt sich also festhalten, dass sich Entscheidungssituation unterschiedlich als Chancen auf Gewinn oder Vermeidung von Verlust betrachten lassen und Verluste oftmals eine stärkere Wirkung entfalten als Gewinne. Zum anderen lässt sich festhalten, dass das Zurückdrängen von Algorithmusaversion ein wichtiges Anliegen für Wirtschaftssubjekte und Gesellschaft ist. Vor diesem Hintergrund ist die Feststellung von Lin et al. (2023) bemerkenswert, dass es bis dato noch keine systematische Untersuchung der Wirkung von Gewinnen- und Verlusten auf das menschliche Verhalten im Kontext von computergestützten

Empfehlungen gab, obwohl die Gewinn-Verlust-Asymmetrie bei der menschlichen Entscheidungsfindung ansonsten eine zentrale Rolle spielt. Daher ist es von zentraler Bedeutung, näher zu untersuchen, ob das Phänomen der Verlustaversion nach Kahneman & Tversky (1979) einen Ansatzpunkt bietet, um zu einer Reduzierung der Algorithmusaversion beizutragen.

## 2 Literaturüberblick

### Algorithmusaversion

Die Entscheidungsfindung von Wirtschaftsakteuren wird in verschiedensten Bereichen zunehmend durch Algorithmen unterstützt, beispielsweise in der Vermögensverwaltung (vgl. z.B. Méndez-Suárez et al., 2019; Niszczoła & Kaszás, 2020), in der Medizin (vgl. z.B. Grove et al., 2000; Ægisdóttir et al., 2006; Beck et al., 2011), in der Polizeiarbeit (vgl. z.B. Mohler et al., 2015), in der Justiz (vgl. z.B. Simpson, 2016; Ireland, 2020) oder im Sport (vgl. z.B. Pérez-Toledano et al., 2019). Die Leistungsfähigkeit von Algorithmen ist dabei oft besser als jene von Menschen, da sie beispielsweise leichter komplexe Zusammenhänge in großen Datenmengen erkennen können, bei denen Menschen schnell an ihre kognitiven Grenzen stoßen (vgl. Meehl, 1954; Dawes et al., 1989; Youyou et al., 2015; Castelo et al., 2019).

Sunstein (2023) liefert einen Überblick über die Anwendung und die Grenzen von Algorithmen in der Gesellschaft. Er gelangt zu der Einschätzung, dass Algorithmen in vielen Bereichen (zum Beispiel in der Justiz oder Medizin) heute bereits bessere Ergebnisse liefern als Menschen, da sie resistenter gegen Voreingenommenheit und anderen Wahrnehmungsverzerrungen sind. Gleichzeitig stoßen auch Algorithmen in anderen Bereichen an ihre Grenzen, beispielsweise wo angemessene Daten nicht ausreichend zur Verfügung stehen oder Kontext, Timing, Zufall oder Stimmung unvorhersehbare Wirkungen entfalten können. In manchen davon sieht er Algorithmen in der Lage, mit der Zeit weitere Fortschritte zu erzielen, in anderen wiederum werden genaue Vorhersagen auch in Zukunft vermutlich weder von Menschen noch Algorithmen möglich sein.

Dort, wo Algorithmen heute bereits bessere Ergebnisse liefern können als Menschen, neigen Menschen dennoch oftmals dazu, Algorithmen zu misstrauen und stattdessen menschliches Urteilsvermögen vorzuziehen (vgl. Highhouse, 2008; Önköl et al., 2009; Dietvorst et al., 2015). Diese Verhaltensanomalie wurde erstmals von Dietvorst et al. (2015) konkret als Algorithmusaversion bezeichnet. In ihrer Studie beobachteten sie, dass Wirtschaftsakteure die Nutzung eines überlegenen Algorithmus reduzieren, wenn sie erkennen, dass dieser nicht stets zu fehlerfreien Ergebnissen kommt. Zudem beobachteten sie, dass Menschen weniger nachsichtig mit Fehlern von Algorithmen als jenen von Menschen sind (vgl. auch Prahl & van Swol, 2017; Bogert et al., 2021).

Dietvorst et al. (2015) erachten diese Abneigung gegenüber Algorithmen nicht nur für die Teilnehmenden ihrer Studie, die gegenüber algorithmusbasierten Entscheidungen nachweislich Geld verloren haben, als kostspielig, sondern aufgrund der vielen Anwendungsfälle von Prognosen auch für die Gesellschaft in Gänze. Die Akzeptanz und damit auch die Verbreitung von effizienteren algorithmusbasierten Systemen wird dadurch erschwert. Es besteht die Gefahr, dass

Wirtschaftsakteure im Speziellen und die Gesellschaft im Allgemeinen langfristig damit unter ihrem maximal erreichbaren Nutzen zurückbleiben. Im Rahmen eines Experiments konnten beispielsweise Filiz et al. (2023) sowie Filiz et al. (2024) zeigen, dass Algorithmusaversion umso häufiger auftritt, je schwerwiegender die möglichen Konsequenzen einer Entscheidung sind. Dies führt zu einer Reduzierung der Erfolgswahrscheinlichkeit insbesondere bei wichtigen Entscheidungen. Auch Sunstein & Gaffe (2024) erwarten wichtige Auswirkungen von Algorithmusaversion sowohl auf Politik und Recht wie auch auf öffentliche und private Einrichtungen. In der Folge widmeten sich eine Vielzahl wissenschaftlicher Studien mit der weiteren Erforschung der Ursachen und Reduktionsmöglichkeiten dieser Verhaltensanomalie. Ausführliche Literaturübersichten zur Algorithmusaversion liefern beispielsweise Alvarado-Valencia & Barrero (2014), Burton et al. (2020), Jussupow et al. (2020) sowie Mahmud et al. (2022).

Sunstein & Gaffe (2024) sehen verschiedene mögliche Ursachen für das Auftreten von Algorithmusaversion: Der Wunsch, selber handlungsfähig zu bleiben; moralische oder emotionale Bedenken; die Überzeugung, dass Menschen im Gegensatz zum Algorithmus über einzigartiges Wissen verfügen; Unwissenheit über die Quelle der Leistungsfähigkeit der Algorithmen; sowie eine stärkere negative Reaktion auf algorithmische als auf menschliche Fehler.

Dietvorst et al. (2018) konnten beispielsweise beobachten, dass sich die Probanden ihrer Studien häufiger für einen unvollkommenen, jedoch überlegenen Algorithmus zur Durchführung einer Prognoseaufgabe entschieden, wenn sie die Prognose des Algorithmus selbst geringfügig beeinflussen konnten (vgl. auch Gubaydullina et al., 2022). Ähnlich argumentieren Cheng & Chouldechova (2023), die im Rahmen einer Replikationsstudie feststellten, dass Prozesskontrolle Algorithmusaversion mindert. Watson (2024) konnte zwar nicht feststellen, dass Einblicke in den Entscheidungsprozess eines Algorithmus zur Reduzierung von Algorithmusaversion beiträgt, die Bereitstellung von Informationen über zuverlässige Leistungen eines Algorithmus in der Vergangenheit hingegen schon. Auch Judek (2024) stellt fest, dass Algorithmusaversion geringer ausfällt, wenn Entscheider über eine hohe soziale Akzeptanz des Algorithmus bei früheren Entscheidungen informiert sind.

Filiz et al. (2021) konnten mithilfe eines Experiments zur Prognose von Aktienkursbewegungen zeigen, dass Algorithmusaversion durch einen Lernprozess in Form von sich wiederholenden Aufgaben, ständigem Feedback und finanziellen Anreizen reduziert werden (vgl. auch Leffrang et al., 2023). Reich et al. (2023) zufolge neigen Verbraucher dazu, Algorithmen zu misstrauen, da sie oft fälschlicherweise davon ausgehen, dass diese anders als Menschen nicht aus Fehlern lernen können. Eine Betonung der Lernfähigkeit und eine Kenntnisnahme der Lernfortschritte von Algorithmen bieten dementsprechend Ansatzpunkte, Algorithmusaversion zu verringern (vgl. auch Berger et al., 2021). Ferner stellten Bogert et al. (2021) fest, dass sich Menschen mit zunehmender Schwierigkeit

einer Aufgabe mehr auf die Empfehlungen von Algorithmen verlassen. Jung & Seiter (2021) konnten im Rahmen einer experimentellen Studie zudem beobachten, dass Zeitdruck bei der Bearbeitung einer Aufgabe Algorithmusaversion reduziert.

Efendić et al. (2020) fanden heraus, dass sich Menschen eher auf Vorhersagen von Algorithmen verlassen und diese als genauer bewerten, wenn diese schnell generiert werden. Bei menschlichen Vorhersagen wurden hingegen langsam generierte Vorhersagen als genauer bewertet. Kim et al. (2021) beobachteten, dass algorithmusbasierte Empfehlungen umso besser bewertet werden, je genauer sie (beispielsweise mit mehr Nachkommastellen) präsentiert werden. Dieser Effekt ist zudem über verschiedene Anwendungsfälle wie zum Beispiel bei CT-Scans oder Musik- oder Buchempfehlungen hinweg konsistent. Zhao et al. (2024) zeigen, dass Menschen einem Algorithmus mit menschenähnlichen Merkmalen, wie beispielsweise einem menschenähnlichen Namen oder Kommunikationsstil, mehr Akzeptanz und Sympathie entgegenbringen als mechanisch wirkenden Algorithmen (vgl. auch Castelo et al., 2019).

Vor dem Hintergrund der bisherigen Befunde ist die Feststellung von Lin et al. (2023) bemerkenswert, dass es bis dato noch keine systematische Untersuchung der Wirkung von Gewinnen und Verlusten auf das menschliche Verhalten im Kontext von computergestützten Empfehlungen gab, obwohl die Gewinn-Verlust-Asymmetrie bei der menschlichen Entscheidungsfindung ansonsten eine zentrale Rolle spielt. Im Rahmen einer eigenen Pionierstudie beobachteten sie, dass menschliches Vertrauen in algorithmusbasierte Empfehlungen bei riskanten Entscheidungen nicht auf das Phänomen der "Gewinn-Verlust-Asymmetrie" reagiert, im Falle einer menschlichen Empfehlung hingegen schon. Die Autoren vermuten daher, dass das menschliche Vertrauen in eine computergestützte Beratung stabiler ist. Ihre Ergebnisse stützen demnach die Hypothese der Automatisierungsverzerrung (vgl. Skitka & Mosier, 1994; Skitka et al., 2000), wonach Menschen Empfehlungen von automatisierten Systemen mehr vertrauen als Individuen (vgl. Manzey et al., 2012). Das ist ein Widerspruch zum Phänomen der Algorithmusaversion. Weitere Untersuchungen sind offenbar notwendig.

## Verlustaversion

Kahneman & Tversky postulieren 1979 ihre „Neue Erwartungstheorie“ (engl. „Prospect Theory“) als eine realistischere Alternative zur bis dahin vorherrschenden Erwartungsnutzentheorie. Sie bietet einen empirisch validierten Rahmen für die Beschreibung, wie Individuen in der Realität Entscheidungen unabhängig von optimalen, normativen Überlegungen treffen. In ihrer weiteren Arbeit prägen Kahneman & Tversky (1984) dabei unter anderem den Begriff der Verlustaversion. Verlustaversion bedeutet im Wesentlichen, dass – ausgehend von einem subjektiven Referenzpunkt – der Verlust einer Geldmenge  $x$  eine stärkere

Abneigung hervorruft als ein Gewinn derselben Geldmenge  $x$  entsprechende Freude verursacht (vgl. Kahneman & Tversky, 1979; Kahneman & Tversky, 1984; Tversky & Kahneman, 1991; Tversky & Kahneman, 1992).

Dieser Referenzpunkt stellt unter dem Begriff der sogenannte Referenzabhängigkeit einen weiteren wichtigen Unterschied der Neuen Erwartungstheorie zur klassischen Erwartungsnutzentheorie dar. Während letztere annimmt, dass Menschen ihren Nutzen aus einem absoluten Niveau (beispielsweise Wohlstand) ableiten, postuliert erstere, dass sich der Nutzen aus der Veränderung im Vergleich zu einem Referenzpunkt (meistens dem Status quo) ergibt. Positive Veränderungen werden dabei als Gewinne und negative Veränderungen als Verluste begriffen (vgl. Kahneman, 2003). Damit verbunden leitet Thaler (1980) aus der Verlustaversion von Kahneman & Tversky (1979) den sogenannten "Besitztumseffekt" (engl. "Endowment Effect") ab. Demnach wird der Verlust von sich bereits im Besitz befindlichen Gütern höher bewertet als ein Zugewinn derselben Güter, wenn sie sich vorher noch nicht im Besitz befanden (vgl. Thaler, 1980).

Verlustaversion wurde bereits in vielen Kontexten nachgewiesen. Beispielsweise wirkt negative, auf Verlust fokussierte Kommunikation zur Bewerbung von brustkrebsfrüherkennender Selbstuntersuchung bei Frauen überzeugender und führt noch Monate später zu einem besseren, tatsächlichen Selbstuntersuchungsverhalten als eine positive, auf Vorteile fokussierte Kommunikation (vgl. Meyerowitz & Chaiken, 1987; Nagaya, 2023). Bei Verbraucherentscheidungen wurde Verlustaversion beispielsweise in Experimenten bereits bei der Produktauswahl von Eiern (vgl. Putler, 1992) und Immobilien (vgl. Genesove & Mayer, 2001) beobachtet und in Modellrechnungen ihr hemmender Einfluss auf die Verbreitung nachhaltigerer Heiztechnologien aufgezeigt (vgl. Knobloch et al., 2019). Neben Erwachsenen hat man sie auch schon bei Kindern (vgl. Harbaugh et al., 2001) und Kapuzineräffchen (vgl. Chen et al., 2006; Lakshminaryanan et al., 2008) beobachtet. Die betroffenen Gehirnregionen reagieren zudem empfindlicher auf Verluste als auf Gewinne, sodass vermutet wird, dass Verlustaversion eine feste, evolutionär bedingte Eigenschaft des menschlichen Verhaltens darstellt (vgl. Tom et al., 2007; Giskevicius & Kenrick, 2013; Knobloch et al., 2019).

Neumann & Böckenholt (2014) ermitteln in einer Meta-Studie eine durchschnittlich doppelt so starke Auswirkung von Verlusten gegenüber gleichgroßen Gewinnen, die in verschiedenen Forschungskontexten jedoch erhebliche Unterschiede aufweisen. Brown et al. (2021) untersuchten 607 empirische Schätzungen der Verlustaversionsstärke aus 150 Artikeln aus den Wirtschaftswissenschaften, der Psychologie, den Neurowissenschaften und verschiedenen anderen Disziplinen und identifizierten einen mittleren Verlustaversionskoeffizienten zwischen 1,8 und 2,1.

### 3 Forschungsdesign und Hypothesen

Betrachtet man die beiden Verhaltensanomalien der Verlustaversion und der Algorithmusaversion gemeinsam, drängt sich die Frage auf, inwiefern erstere dazu beitragen kann, letztere zu reduzieren. Kann die Verlustaversion genutzt werden, um die Etablierung von algorithmusbasierten Entscheidungshilfen zu unterstützen? Dies soll im Rahmen der vorliegenden Studie in einem Experiment unter kontrollierten Laborbedingungen untersucht werden.

Dafür wird eine Entscheidungssituationen kreiert, in der die Probanden die Wahl haben, ob sie eine ökonomische Entscheidung durch einen menschlichen Experten oder einen spezialisierten Algorithmus treffen lassen wollen. In Anlehnung an Kahneman & Tversky (1984) werden die Probanden dabei in zwei Treatments mit unterschiedlichen Ausgangspunkten aufgeteilt, deren Entscheidungssituation jedoch denselben Erwartungswert besitzt: In Treatment 1 droht den Probanden ein Verlust, in Treatment 2 bietet sich hingegen eine Chance auf einen Gewinn.

Beide Treatments müssen zunächst eine vorangeschaltete Real-Effort-Task nach Benndorf et al. (2014) und Filiz et al. (2020) lösen. Damit sollen zum einen insbesondere die Probanden im Treatment 1 (drohender Verlust) mit Kapital ausgestattet werden, welches sie im Rahmen des Experiments teilweise wieder verlieren könnten. Zum anderen soll durch den von den Probanden betriebenen Aufwand die Verlustaversion verstärkt und der House-Money-Effect (vgl. z.B. Thaler & Johnson, 1990; Loewenstein & Issacharoff, 1994; Weimann & Brosig-Koch, 2019) bestmöglich ausgeschlossen bzw. reduziert werden.

Hierfür müssen die Probanden im Rahmen einer Kodieraufgabe in 50 Runden jeweils unterschiedliche Buchstabenkombinationen einer richtigen Zahlenkombination zuordnen. Sowohl die Buchstaben- als auch Zahlenkombinationen werden mit jeder Runde neu generiert, zugeordnet und in der Lösungstabelle platziert (siehe Anhang). Dabei ist fehlerfreies Arbeiten erforderlich. Zusätzlich wird eine unverbindliche Zeitvorgabe von 10 Minuten gemacht. Diese Bedingungen werden absichtlich so gewählt, dass die Probandinnen und Probanden die Aufgabe als anstrengend empfinden, damit sie am Ende das so erhaltene Geld als durch ihre eigene Leistung verdient ansehen.

Die Probandinnen und Probanden aus Treatment 1 (drohender Verlust) verdienen sich damit jeweils 5,00 EUR pro Person, die ihnen nach Beendigung der Aufgabe auch zunächst physisch in Form von 5 EUR-Banknoten ausgezahlt werden. So sollen der Besitztumseffekt und die Wirkung von Verlustaversion verstärkt werden. Im daran anschließenden eigentlichen Experiment droht den Probandinnen und Probanden nun jedoch die Gefahr, dass von dem mühsam erarbeiteten Geld 3,00 EUR wieder verloren gehen können. Um dies zu verhindern, bleibt ihnen entweder die Möglichkeit, einen Algorithmus (Robo-Advisor)

mit einer verbleibenden Verlustwahrscheinlichkeit von 30% (Alternative 1.1) oder einen menschlichen Experten (Kapitalmarktexperten) mit einer verbleibenden Verlustwahrscheinlichkeit von 40 % (Alternative 1.2) zu wählen (Tabelle 1). Der Erwartungswert der Alternative 1.1 entspricht dabei 4,10 EUR ( $5,00 \text{ EUR} - 0,3 \cdot 3,00 \text{ EUR}$ ), jener der Alternative 1.2 nur 3,80 EUR ( $5,00 \text{ EUR} - 0,4 \cdot 3,00 \text{ EUR}$ ).

Die Probandinnen und Probanden aus Treatment 2 (Chance auf Zugewinn) hingegen verdienen sich durch die vorangeschaltete Kodieraufgabe zunächst jeweils nur 2,00 EUR pro Person. Im daran anschließenden eigentlichen Experiment haben sie nun jedoch die Chance, weitere 3,00 EUR hinzuzugewinnen. Auch hier bleibt ihnen entweder die Möglichkeit, einen Algorithmus (Robo-Advisor) mit einer Erfolgswahrscheinlichkeit von 70% (Alternative 2.1) oder einen menschlichen Experten (Kapitalmarktexperten) mit einer Erfolgswahrscheinlichkeit von 60% (Alternative 2.2) zu wählen (Tabelle 1). Analog zum Treatment 1 (drohender Verlust) entspricht der Erwartungswert der Alternative 2.1 dabei 4,10 EUR ( $2,00 \text{ EUR} + 0,7 \cdot 3,00 \text{ EUR}$ ), jener der Alternative 2.2 nur 3,80 EUR ( $2,00 \text{ EUR} + 0,6 \cdot 3,00 \text{ EUR}$ ).

In beiden Treatments können die Probandinnen und Probanden somit in Summe mindestens 2,00 EUR und maximal 5,00 EUR erspielen. Trotz der unterschiedlichen Referenzpunkte der Entscheidungssituationen (von 5,00 EUR etwas verlieren oder von 2,00 EUR etwas hinzugewinnen) sind die Erwartungswerte je Entscheidungsalternative (4,10 EUR beim Algorithmus und 3,80 EUR beim menschlichen Experten) in beiden Treatments identisch. Die Entscheidungsalternative pro Algorithmus ist damit jeweils jener pro menschlichen Experten überlegen ( $4,10 \text{ EUR} > 3,80 \text{ EUR}$ ). Daher wäre in beiden Treatments von einem Homo Oeconomicus zu erwarten, sich jeweils für den Algorithmus zu entscheiden. Tabelle 1 fasst die monetären Implikationen und Erwartungswerte der verschiedenen Treatments und Entscheidungsalternativen zusammen.

Tab. 1: Übersicht der monetären Implikationen und Erwartungswerte der Entscheidungsalternativen

Treatment	Szenario	Vergütung Kodieraufgabe	Entscheidungsalternative	Verlust-/Gewinnwahrscheinlichkeit	Verlust-/Gewinn-Betrag	Erwartungswert	Min. Vergütung	Max. Vergütung
1	Drohender Verlust	5,00 EUR	Algorithmus	30 %	-3,00 EUR	4,10 EUR	2,00 EUR	5,00 EUR
			Experte	40 %		3,80 EUR		
2	Chance auf Zugewinn	2,00 EUR	Algorithmus	70 %	+3,00 EUR	4,10 EUR	2,00 EUR	5,00 EUR
			Experte	60 %		3,80 EUR		

Das Auftreten von Algorithmusaversion wird aufgrund der bisherigen Erkenntnisse aus der vorhandenen Literatur jedoch in beiden Treatments erwartet. Sollte sich im verlustfokussierten Treatment 1 allerdings eine signifikant geringere Häufigkeit von Algorithmusaversion beobachten lassen als

im gewinnfokussierten Treatment 2, ließe dies vermuten, dass Verlustaversion einen dominanteren Effekt auf Wirtschaftssubjekte ausübt als die Algorithmusaversion. In der Folge könnte eine bewusste Betonung drohender Verluste in realen Anwendungsfällen dazu beitragen, Algorithmusaversion zu reduzieren und somit die Etablierung von algorithmusbasierten Entscheidungshilfen zu fördern.

Hypothese 1 lautet daher: Algorithmusaversion tritt in Treatment 2 (Chance auf Zugewinn) signifikant häufiger auf als in Treatment 1 (drohender Verlust).

Nullhypothese 1 lautet daher: Algorithmusaversion tritt in Treatment 2 (Chance auf Zugewinn) nicht signifikant häufiger auf als in Treatment 1 (drohender Verlust).

Die Programmierung und Durchführung des Experiments erfolgt mithilfe der Software „z-Tree“ nach Fischbacher (2007).

## 4 Ergebnisse

Die experimentelle Erhebung wurde im Zeitraum vom 24.04.2024 bis zum 08.05.2024 im Ostfalia Labor für experimentelle Wirtschaftsforschung (OLEW) in Wolfsburg durchgeführt. An der Erhebung haben 200 Studierende der Ostfalia Hochschule für angewandte Wissenschaften teilgenommen. 100 Probanden haben das Treatment 1 (drohender Verlust) und 100 Probanden das Treatment 2 (Chance auf Zugewinn) bearbeitet.

43,5% der Probanden sind weiblich und 56,5% der Probanden sind männlich. 67,0% der Probanden gehören der Fakultät Wirtschaft, 27,5% der Fakultät Fahrzeugtechnik und 5,5% anderen Fakultäten an. 97,0% der Probanden sind Studierende eines Bachelorstudiums und 3,0% sind Studierende eines Masterstudiums. Die Probanden im Bachelorstudium haben im Durchschnitt angegeben, bereits 4,06 Semester studiert zu haben (Masterstudium 3,40 Semester). Ihr durchschnittliches Alter beträgt 22,3 Jahre.

Es zeigt sich zunächst, dass es insgesamt nur bei 16 % der Teilnehmenden überhaupt zur Verhaltensanomalie der Algorithmusaversion kommt (siehe Tabelle 2 und Abbildung 1).

Tab. 2: Entscheidungen für den Experten oder den Algorithmus nach Treatments

	Entscheidung für		
	Experte	Algorithmus	Gesamt
Treatment 1 (drohender Verlust)	23 (23%)	77 (77%)	100 (50,0%)
Treatment 2 (Chance auf Zugewinn)	9 (9%)	91 (91%)	100 (50,0%)
Gesamt	32 (16%)	168 (84%)	200 (100,0%)




Abb. 1: Entscheidungen für den Experten oder den Algorithmus nach Treatments

Beim Vergleich der Treatments ist augenfällig, dass im Fall eines drohenden Verlusts (Treatment 1) mit 23% deutlich häufiger der Experte bevorzugt wird als im Fall der Chance auf einen Zugewinn (Treatment 2) mit nur 9%. Im Chi-Quadrat-Test nach Pearson erweist sich dieser Unterschied bei einer Irrtumswahrscheinlichkeit  $<1\%$  als statistisch signifikant ( $p$ -Wert = 0,007). Der Unterschied ist zwar signifikant, stellt sich jedoch anders herum dar als vorher vermutet. In Treatment 1 (Drohender Verlust) tritt die Algorithmusaversion nicht etwa seltener, sondern häufiger auf als in Treatment 2 (Chance auf Zugewinn). Damit kann Nullhypothese 1 nicht verworfen werden. Hypothese 1 findet somit keine Bestätigung.

Es scheint so, dass Verlustaversion nicht nur nicht geeignet ist, Algorithmusaversion zu reduzieren. Vielmehr führt Verlustaversion offenbar sogar zu einer Verschärfung der Algorithmusaversion. Die Ergebnisse von Filiz et al. (2023) und Filiz et al. (2024) bieten einen möglichen Erklärungsansatz für diesen erstaunlichen Befund. Sie zeigen im Rahmen ihrer Experimente, dass Algorithmusaversion umso häufiger auftritt, je schwerwiegender die möglichen Konsequenzen einer Entscheidung sind. Nach Kahneman & Tversky (1979) und Thaler (1980) wird der Verlust von sich bereits im Besitz befindlichen Gütern (zum Beispiel von mühsam erarbeiteten fünf Euro in Treatment 1 wieder drei Euro verlieren zu können) kritischer bewertet als ein Zugewinn derselben Güter, wenn sie sich vorher noch nicht im Besitz befanden (zum Beispiel von zwei Euro in Treatment 2 weitere drei Euro hinzugewinnen zu können). Demnach lassen sich die möglichen Konsequenzen der Entscheidung im Treatment 1 (drohender Verlust) auch als schwerwiegender klassifizieren als in Treatment 2 (Chance auf Zugewinn). Die vorliegenden Ergebnisse stützen damit ebenfalls die Beobachtungen von Filiz et al. (2023) und Filiz et al. (2024), dass Algorithmusaversion umso häufiger auftritt, je schwerwiegender die möglichen Konsequenzen einer Entscheidung sind. Auch die These der Autoren, dass dies zu einer reduzierten Erfolgswahrscheinlichkeit führt, lässt sich durch das vorliegende Experiment stützen, da mit der signifikant häufigeren Wahl des menschlichen Experten anstelle des Algorithmus auch hier eine niedrigere Erfolgswahrscheinlichkeit verbunden ist (60% anstatt 70%). Die Beobachtung von Lin et al. (2023), dass menschliches Vertrauen in algorithmusbasierte Empfehlungen bei riskanten Entscheidungen nicht auf das Phänomen der "Gewinn-Verlust-Asymmetrie" reagiert, wird durch diesen Befund hingegen nicht gestützt.

Um die Verbreitung algorithmusbasierter Systeme zu fördern, erscheint es daher angebracht, die mit ihrem Einsatz verbundenen Chancen auf Zugewinne zu betonen und sie nicht als Hilfsmittel zur Verlustvermeidung zu bewerben. Die vorliegende Studie liefert damit weitere Evidenz für ein besseres Verständnis der Verhaltensanomalie Algorithmusaversion und zu den Möglichkeiten ihrer Reduktion.

## 5 Zusammenfassung

Eine zunehmende Anzahl von Entscheidungssituationen in immer mehr Bereichen des täglichen Lebens lässt sich durch algorithmusbasierte Hilfsmittel effizienter gestalten. Dennoch lässt sich vielfach beobachten, dass Menschen diesen Algorithmen misstrauen und sich stattdessen lieber auf menschliches Urteilsvermögen verlassen. Diese Verhaltensanomalie wird „Algorithmusaversion“ genannt (vgl. Dietvorst et al., 2015). Sie erschwert die Verbreitung effizienterer algorithmusbasierter Entscheidungshilfen und -systemen. Wirtschaftssubjekte verzichten damit nachweislich auf Geld und die Gesellschaft in Gänze läuft Gefahr, nicht ihren maximal erreichbaren Nutzen zu realisieren. Algorithmusaversion stellt damit eine Verhaltensanomalie dar, bei der weiterer Forschungsbedarf besteht.

Gleichzeitig lassen sich Entscheidungssituationen, in denen Algorithmen unterstützen können, oftmals unterschiedlich betrachten. So können Algorithmen dabei helfen, einen Gewinn zu erzielen oder aber einen Verlust zu vermeiden. Mit dieser Betrachtungsweise ist durch die viel beachteten Forschungen von Kahneman & Tversky (1979) eine weitere, bereits intensiv untersuchte Verhaltensanomalie verbunden: Verlustaversion. Vor diesem Hintergrund ist die Feststellung von Lin et al. (2023) bemerkenswert, dass es bis dato noch keine systematische Untersuchung der Wirkung von Gewinnen- und Verlusten auf das menschliche Verhalten im Kontext von computergestützten Empfehlungen gab, obwohl die Gewinn-Verlust-Asymmetrie bei der menschlichen Entscheidungsfindung ansonsten eine zentrale Rolle spielt. Daher drängt sich die Frage auf, ob sich das Phänomen der Verlustaversion gezielt nutzen lässt, um Algorithmusaversion zu reduzieren.

Zur Überprüfung dieser Frage wurde ein Experiment unter kontrollierten Laborbedingungen durchgeführt. Hierfür wurde eine Entscheidungssituationen kreiert, in der die Probandinnen und Probanden für das Treffen einer ökonomischen Entscheidung in zwei Treatments unterteilt wurden. Im Treatment 1 droht den Teilnehmenden ein Verlust, im Treatment 2 haben sie die Chance auf einen Zugewinn. In beiden Treatments ist der Erwartungswert der Auszahlung identisch. Aufgrund der vielfach aufgezeigten Wirkung von Verlustaversion wird erwartet, dass Algorithmusaversion in Treatment 1 (drohender Verlust) zurückgedrängt wird und daher in Treatment 2 (Chance auf Zugewinn) signifikant häufiger auftritt (Hypothese 1).

In den Ergebnissen zeigt sich zunächst, dass Algorithmusaversion insgesamt nur bei 16 % der Probanden auftritt. Mit einer Irrtumswahrscheinlichkeit  $<1\%$  ( $p$ -Wert = 0,007) wurde zudem der menschliche Experte im Falle eines drohenden Verlusts (Treatment 1) signifikant häufiger von den Teilnehmenden gewählt als im Fall der Chance auf einen Zugewinn (Treatment 2). Hypothese 1 findet damit keine Bestätigung. Letztendlich lässt sich im Rahmen dieses Experiments die Wirkung von Verlustaversion auf Algorithmusaversion genau andersherum

beobachten, als es vorher erwartet wurde. Verlustaversion hat das Auftreten von Algorithmusaversion nicht zurückgedrängt, sondern im Gegenteil sogar noch verstärkt.

Nach Kahneman & Tversky (1979) und Thaler (1980) wird der Verlust von sich bereits im Besitz befindlichen Gütern (zum Beispiel von mühsam erarbeiteten fünf Euro in Treatment 1 wieder drei Euro verlieren zu können) kritischer bewertet als ein Zugewinn derselben Güter, wenn sie sich vorher noch nicht im Besitz befanden (zum Beispiel von zwei Euro in Treatment 2 weitere drei Euro hinzugewinnen zu können). Demnach lassen sich die möglichen Konsequenzen der Entscheidung im Treatment 1 (drohender Verlust) auch als schwerwiegender klassifizieren als in Treatment 2 (Chance auf Zugewinn). Die vorliegenden Befunde stützen damit wiederum die Ergebnisse von Filiz et al. (2023) und Filiz et al. (2024), die im Rahmen ihrer Experimente zeigen, dass Algorithmusaversion umso häufiger auftritt, je schwerwiegender die möglichen Konsequenzen einer Entscheidung sind. Auch die These der Autoren, dass dies zu einer reduzierten Erfolgswahrscheinlichkeit führt, lässt sich durch das vorliegende Experiment stützen, da mit der signifikant häufigeren Wahl des menschlichen Experten anstelle des Algorithmus auch hier eine niedrigere Erfolgswahrscheinlichkeit verbunden ist (60% anstatt 70%). Die Beobachtung von Lin et al. (2023), dass menschliches Vertrauen in algorithmusbasierte Empfehlungen bei riskanten Entscheidungen nicht auf das Phänomen der "Gewinn-Verlust-Asymmetrie" reagiert, wird durch diesen Befund hingegen nicht gestützt.

Aus den Ergebnissen dieser Studie lässt sich ableiten, dass es zur Reduktion von Algorithmusaversion und der Verbreitung effizienterer algorithmusbasierter Entscheidungshilfen und -systeme von Vorteil ist, die mit ihrem Einsatz verbundenen Chancen auf Zugewinne zu betonen und sie nicht als Hilfsmittel zur Verlustvermeidung zu bewerben. Die vorliegende Studie liefert damit weitere Evidenz für ein besseres Verständnis der Verhaltensanomalie Algorithmusaversion und zu den Möglichkeiten ihrer Reduktion.

## **Danksagung**

Wir danken Peter von Holten für seine hilfreichen Kommentare und Anregungen. Ebenfalls danken wir den Teilnehmenden des von Kilian Bizer veranstalteten Doktorandenseminars an der Universität Göttingen im Jahr 2024.

## Literatur

- Ægisdóttir, S., White, M. J., Spengler, P. M., Maugherman, A. S., Anderson, L. A., Cook, R. S., Nichols, C. N., Lampropoulos, G. K., Walker, B. S., Cohen, G. & Rush, J. D. (2006) "The Meta-Analysis of Clinical Judgment Project: Fifty-Six Years of Accumulated Research on Clinical Versus Statistical Prediction", *The Counseling Psychologist*, Vol. 34, No. 3, S. 341–382.
- Alvarado-Valencia, J. A. & Barrero, L. H. (2014) "Reliance, trust and heuristics in judgmental forecasting", *Computers in Human Behavior*, Vol. 36, S. 102–113.
- Beck, A. H., Sangoi, A. R., Leung, S., Marinelli, R. J., Nielsen, T. O., van de Vijver, M. J., West, R. B., van de Rijn, M. & Koller, D. (2011) "Systematic analysis of breast cancer morphology uncovers stromal features associated with survival", *Science Translational Medicine*, Vol. 3, No. 108, 108ra113.
- Benndorf, V., Rau, H. A. & Sölch, C. (2014) "Minimizing Learning Behavior in Experiments with Repeated Real-Effort Tasks", *SSRN Electronic Journal*.
- Berger, B., Adam, M., Rühr, A. & Benlian, A. (2021) "Watch Me Improve—Algorithm Aversion and Demonstrating the Ability to Learn", *Business & Information Systems Engineering*, Vol. 63, No. 1, S. 55–68 [Online]. DOI: 10.1007/s12599-020-00678-5.
- Bogert, E., Schechter, A. & Watson, R. T. (2021) "Humans rely more on algorithms than social influence as a task becomes more difficult", *Scientific Reports*, Vol. 11 [Online]. DOI: 10.1038/s41598-021-87480-9.
- Brown, A. L., Imai, T., Vieider, F. & Camerer, C. F. (2021) "Meta-Analysis of Empirical Estimates of Loss-Aversion", *SSRN Electronic Journal*.
- Burton, J. W., Stein, M.-K. & Jensen, T. B. (2020) "A systematic review of algorithm aversion in augmented decision making", *Journal of Behavioral Decision Making*, Vol. 33, No. 2, S. 220–239.
- Castelo, N., Bos, M. W. & Lehmann, D. R. (2019) "Task-Dependent Algorithm Aversion", *Journal of Marketing Research*, Vol. 56, No. 5, S. 809–825.
- Chen, M. K., Lakshminarayanan, V. & Santos, L. R. (2006) "How Basic Are Behavioral Biases? Evidence from Capuchin Monkey Trading Behavior", *Journal of Political Economy*, Vol. 114, No. 3, S. 517–537.
- Cheng, L. & Chouldechova, A. (2023) "Overcoming Algorithm Aversion: A Comparison between Process and Outcome Control", *Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems*. Hamburg

- Germany, 23 04 2023 28 04 2023. New York, NY, United States, Association for Computing Machinery, S. 1–27.
- Dawes, R. M., Faust, D. & Meehl, P. E. (1989) "Clinical versus actuarial judgment", *Science*, Vol. 243, No. 4899, S. 1668–1674.
- Dietvorst, B. J., Simmons, J. P. & Massey, C. (2015) "Algorithm aversion: people erroneously avoid algorithms after seeing them err", *Journal of experimental psychology. General*, Vol. 144, No. 1, S. 114–126.
- 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*, Vol. 64, No. 3, S. 1155–1170.
- 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*, Vol. 157, S. 103–114 [Online]. DOI: 10.1016/j.obhdp.2020.01.008.
- Filiz, I., Judek, J. R., Lorenz, M. & Spiwoks, M. (2021) "Reducing algorithm aversion through experience", *Journal of Behavioral and Experimental Finance*, Vol. 31.
- Filiz, I., Judek, J. R., Lorenz, M. & Spiwoks, M. (2022) "Algorithm Aversion as an Obstacle in the Establishment of Robo Advisors", *Journal of Risk and Financial Management*, Vol. 15, No. 8.
- Filiz, I., Judek, J. R., Lorenz, M. & Spiwoks, M. (2023) "The extent of algorithm aversion in decision-making situations with varying gravity", *PloS one*, Vol. 18, No. 2.
- Filiz, I., Kirchhoff, F., Nahmer, T. & Spiwoks, M. (2024) When it really matters: Algorithm aversion occurs most often when it is most harmful, *Wolfsburg Working Papers 24-02* [Online]. Verfügbar unter [https://www.ostfalia.de/cms/de/wf.galleries/forschung/WWP\\_24-02\\_when-it-really-matters\\_algorithm-aversion-occurs-most-often-when-it-is-most-harmful\\_2024-07-22.pdf](https://www.ostfalia.de/cms/de/wf.galleries/forschung/WWP_24-02_when-it-really-matters_algorithm-aversion-occurs-most-often-when-it-is-most-harmful_2024-07-22.pdf) (Abgerufen am 27 August 2024).
- Filiz, I., Nahmer, T., Spiwoks, M. & Gubaydullina, Z. (2020) "Measurement of risk preference", *Journal of Behavioral and Experimental Finance*, Vol. 27 [Online]. DOI: 10.1016/j.jbef.2020.100355.
- Fischbacher, U. (2007) *z-Tree: Zurich toolbox for ready-made economic experiments* [Online], Springer. Verfügbar unter <https://link.springer.com/article/10.1007/s10683-006-9159-4#citeas> (Abgerufen am 5 Februar 2024).
- Genesove, D. & Mayer, C. (2001) "Loss Aversion and Seller Behavior: Evidence from the Housing Market", *The Quarterly Journal of Economics*, Vol. 116, No. 4, S. 1233–1260.
- Griskevicius, V. & Kenrick, D. T. (2013) "Fundamental motives: How evolutionary needs influence consumer behavior", *Journal of Consumer Psychology*, Vol. 23, No. 3, S. 372–386.

- Grove, W. M., Zald, D. H., Lebow, B. S., Snitz, B. E. & Nelson, C. (2000) "Clinical versus mechanical prediction: A meta-analysis", *Psychological Assessment*, Vol. 12, No. 1, S. 19–30.
- Gubaydullina, Z., Judek, J. R., Lorenz, M. & Spiwoks, M. (2022) "Comparing Different Kinds of Influence on an Algorithm in Its Forecasting Process and Their Impact on Algorithm Aversion", *Businesses*, Vol. 2, No. 4, S. 448–470.
- Harbaugh, W. T., Krause, K. & Vesterlund, L. (2001) "Are adults better behaved than children? Age, experience, and the endowment effect", *Economics Letters*, Vol. 70, No. 2, S. 175–181 [Online]. DOI: 10.1016/S0165-1765(00)00359-1.
- Highhouse, S. (2008) "Stubborn Reliance on Intuition and Subjectivity in Employee Selection", *Industrial and Organizational Psychology*, Vol. 1, No. 3, S. 333–342.
- Ireland, L. (2020) "Who errs? Algorithm aversion, the source of judicial error, and public support for self-help behaviors", *Journal of Crime and Justice*, Vol. 43, No. 2, S. 174–192.
- Judek, J. R. (2024) "Willingness to Use Algorithms Varies with Social Information on Weak vs. Strong Adoption: An Experimental Study on Algorithm Aversion", *FinTech*, Vol. 3, No. 1, S. 55–65.
- Jung, M. & Seiter, M. (2021) "Towards a better understanding on mitigating algorithm aversion in forecasting: an experimental study", *Journal of Management Control*, Vol. 32, No. 4, S. 495–516.
- 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)*, S. 1–16.
- Kahneman, D. (2003) "Maps of Bounded Rationality: Psychology for Behavioral Economics", *American Economic Review*, Vol. 93, No. 5, S. 1449–1475.
- Kahneman, D. & Tversky, A. (1979) "Prospect Theory: An Analysis of Decision under Risk", *Econometrica*, Vol. 47, No. 2, S. 263–291.
- Kahneman, D. & Tversky, A. (1984) "Choices, values, and frames", *American Psychologist*, Vol. 39, No. 4, S. 341–350.
- 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*, Vol. 38, No. 7, S. 1140–1155.
- Knobloch, F., Huijbregts, M. A. & Mercure, J.-F. (2019) "Modelling the effectiveness of climate policies: How important is loss aversion by consumers?", *Renewable and Sustainable Energy Reviews*, Vol. 116.
- Lakshminaryanan, V., Chen, M. K. & Santos, L. R. (2008) "Endowment effect in capuchin monkeys", *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, Vol. 363, No. 1511, S. 3837–3844.

- Leffrang, D., Bösch, K. & Müller, O. (2023) "Do People Recover from Algorithm Aversion? An Experimental Study of Algorithm Aversion over Time", in Bui, T. X. (Hg.) Proceedings of the 56th Annual Hawaii International Conference on System Sciences: January 3-6, 2023 [Online], Honolulu, HI, Department of IT Management Shidler College of Business University of Hawaii, S. 4016–4025. Verfügbar unter <https://hdl.handle.net/10125/102456>.
- Lin, Y., Xu, P., Fan, J., Gu, R. & Luo, Y. (2023) "Gain-loss separability in human-but not computer-based changes of mind", *Computers in Human Behavior*, Vol. 143 [Online]. DOI: 10.1016/j.chb.2023.107712.
- Loewenstein, G. & Issacharoff, S. (1994) "Source dependence in the valuation of objects", *Journal of Behavioral Decision Making*, Vol. 7, No. 3, S. 157–168.
- 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*, Vol. 175.
- Majumdar, A. & Ward, R. K. (2011) "An algorithm for sparse MRI reconstruction by Schatten p-norm minimization", *Magnetic Resonance Imaging*, Vol. 29, No. 3, S. 408–417 [Online]. DOI: 10.1016/j.mri.2010.09.001.
- Manzey, D., Reichenbach, J. & Onnasch, L. (2012) "Human Performance Consequences of Automated Decision Aids", *Journal of Cognitive Engineering and Decision Making*, Vol. 6, No. 1, S. 57–87.
- Meehl, P. E. (1954) *Clinical versus statistical prediction: A theoretical analysis and a review of the evidence* [Online], Minneapolis, University of Minnesota Press.
- Méndez-Suárez, M., García-Fernández, F. & Gallardo, F. (2019) "Artificial Intelligence Modelling Framework for Financial Automated Advising in the Copper Market", *Journal of Open Innovation: Technology, Market, and Complexity*, Vol. 5, No. 4, S. 81.
- Meyerowitz, B. E. & Chaiken, S. (1987) "The effect of message framing on breast self-examination attitudes, intentions, and behavior", *Journal of personality and social psychology*, Vol. 52, No. 3, S. 500–510.
- Mohler, G. O., Short, M. B., Malinowski, S., Johnson, M., Tita, G. E., Bertozzi, A. L. & Brantingham, P. J. (2015) "Randomized Controlled Field Trials of Predictive Policing", *Journal of the American Statistical Association*, Vol. 110, No. 512, S. 1399–1411.
- Nagaya, K. (2023) "Why and Under What Conditions Does Loss Aversion Emerge? 1", *Japanese Psychological Research*, Vol. 65, No. 4, S. 379–398.
- Neumann, N. & Böckenholt, U. (2014) "A Meta-analysis of Loss Aversion in Product Choice", *Journal of Retailing*, Vol. 90, No. 2, S. 182–197 [Online]. DOI: 10.1016/j.jretai.2014.02.002.

- Niszczoła, P. & Kaszás, D. (2020) Robo-investment aversion [Online], Center for Open Science.
- Önkál, 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*, Vol. 22, No. 4, S. 390–409.
- Pérez-Toledano, M. Á., Rodríguez, F. J., García-Rubio, J. & Ibañez, S. J. (2019) "Players' selection for basketball teams, through Performance Index Rating, using multiobjective evolutionary algorithms", *PloS one*, Vol. 14, No. 9.
- Prahl, A. & van Swol, L. (2017) "Understanding algorithm aversion: When is advice from automation discounted?", *Journal of Forecasting*, Vol. 36, No. 6, S. 691–702.
- Putler, D. S. (1992) "Incorporating Reference Price Effects into a Theory of Consumer Choice", *Marketing Science*, Vol. 11, No. 3, S. 287–309.
- Reich, T., Kaju, A. & Maglio, S. J. (2023) "How to overcome algorithm aversion: Learning from mistakes", *Journal of Consumer Psychology*, Vol. 33, No. 2, S. 285–302.
- Shariff, A., Bonnefon, J.-F. & Rahwan, I. (2017) "Psychological roadblocks to the adoption of self-driving vehicles", *Nature human behaviour*, Vol. 1, No. 10, S. 694–696.
- Simpson, B. (2016) "Algorithms or advocacy: does the legal profession have a future in a digital world?", *Information & Communications Technology Law*, Vol. 25, No. 1, S. 50–61.
- Skitka, L. J. & Mosier, K. L. (1994) *Automation bias: when, where and why?*, St. Louis, MO.
- Skitka, L. J., Mosier, K. L. & Burdick, M. D. (2000) "Accountability and automation bias", *International Journal of Human-Computer Studies*, Vol. 52, No. 4, S. 701–717 [Online]. DOI: 10.1006/ijhc.1999.0349.
- Sunstein, C. R. (2023) "The use of algorithms in society", *The Review of Austrian Economics*.
- Sunstein, C. R. & Gaffe, J. (2024) *An Anatomy of Algorithm Aversion* [Online]. Verfügbar unter <https://ssrn.com/abstract=4865492> (Abgerufen am 29 August 2024).
- Thaler, R. (1980) "Toward a positive theory of consumer choice", *Journal of Economic Behavior & Organization*, Vol. 1, No. 1, S. 39–60 [Online]. DOI: 10.1016/0167-2681(80)90051-7.
- Thaler, R. H. & Johnson, E. J. (1990) "Gambling with the House Money and Trying to Break Even: The Effects of Prior Outcomes on Risky Choice", *Management Science*, Vol. 36, No. 6, S. 643–660.

- Tom, S. M., Fox, C. R., Trepel, C. & Poldrack, R. A. (2007) "The neural basis of loss aversion in decision-making under risk", *Science*, Vol. 315, No. 5811, S. 515–518.
- Tversky, A. & Kahneman, D. (1981) "The Framing of Decisions and the Psychology of Choice", *Science*, Vol. 211, No. 4481, S. 453–458.
- Tversky, A. & Kahneman, D. (1991) "Loss Aversion in Riskless Choice: A Reference-Dependent Model", *The Quarterly Journal of Economics*, Vol. 106, No. 4, S. 1039–1061.
- Tversky, A. & Kahneman, D. (1992) "Advances in prospect theory: Cumulative representation of uncertainty", *Journal of Risk and Uncertainty*, Vol. 5, No. 4, S. 297–323.
- Watson, D. E. (2024) *Through the Looking Glass: Overcoming Algorithm Aversion in Accounting* [Online]. Verfügbar unter <https://digitalcommons.usf.edu/etd/10260> (Abgerufen am 28 August 2024).
- Weimann, J. & Brosig-Koch, J. (2019) *Einführung in die experimentelle Wirtschaftsforschung* [Online], Berlin, Heidelberg, Springer Berlin Heidelberg. Verfügbar unter <http://nbn-resolving.org/urn:nbn:de:bsz:31-epflicht-1568131>.
- Youyou, W., Kosinski, M. & Stillwell, D. (2015) "Computer-based personality judgments are more accurate than those made by humans", *Proceedings of the National Academy of Sciences*, Vol. 112, No. 4, S. 1036–1040.
- Zhao, Y., Xu, L., Yu, F. & Jin, W. (2024) "Perceived opacity leads to algorithm aversion in the workplace", *Acta Psychologica Sinica*, Vol. 56, No. 4, S. 497 [Online]. DOI: 10.3724/SP.J.1041.2024.00497.



Für die Kodierung aller 50 Buchstaben-Kombinationen (Wörter) sollten möglichst nicht mehr als 10 Minuten verwendet werden. Nach Beginn der Aufgabe können Sie die Ihnen noch verbleibende Zeit in der oberen rechten Ecke des Bildschirms einsehen.

### Auszahlung

Für jede richtig kodierte Buchstaben-Kombination (Wort) erhalten Sie eine Gutschrift von 10 Cent. Insgesamt können Sie bei dieser Aufgabe 5.00 EUR verdienen (50 Kombinationen à 10 Cent).

### Exemplarische Eingabemaske der vorangestellten Kodieraufgabe (Real-Effort-Task)

Verbleibende Zeit [in Sekunden]: 600

Kodierung

Von 50 zu kodierenden Wörtern verschlüsseln Sie gerade Wort Nummer 1

WORT: F K W

CODE: [ ] [ ] [ ]

A	O	K	W	G	D	C	E	R	N	X	T	I	Q	U	L	M	B	H	V	S	Y	Z	P	J	F
792	685	328	552	307	483	715	937	768	146	528	463	413	489	671	757	661	899	191	589	952	486	657	448	830	633

OK

### Zwischenauszahlungsbildschirm nach Abschluss der vorangestellten Kodieraufgabe (Real-Effort-Task)

#### Herzlichen Glückwunsch!

In der soeben absolvierten Kodieraufgabe haben Sie 5.00 EUR erwirtschaftet.

Die Laboraufsicht wird nun nach und nach herumkommen und hierfür eine Zwischenauszahlung vornehmen.

Bitte warten Sie diese Zwischenauszahlung ab. Verhalten Sie sich weiterhin ruhig, sprechen Sie nicht mit Ihren Nachbarn und schauen Sie ihnen nicht auf den Bildschirm.

Die nächste Aufgabe wird automatisch starten, sobald alle Teilnehmenden ihre Zwischenauszahlung erhalten haben.

## **Spielanleitung zum eigentlichen Experiment**

### **Situation**

In der Aufgabe zuvor haben Sie 5.00 EUR erwirtschaftet und ausgezahlt bekommen. Davon sind Ihnen bereits 2.00 EUR sicher. Die übrigen 3.00 EUR stellen Ihren Einsatz für die nun folgende, neue Entscheidungssituation dar. In dieser müssen Sie eine Auswahl treffen, ob Sie eine Investition von einem Kapitalmarktexperten oder von einem Robo-Advisor tätigen lassen wollen. Ein Robo-Advisor ist ein spezialisiertes Computerprogramm, das fortlaufend die Kapitalmärkte analysiert und selbstständig auf den jeweiligen Kunden zugeschnittene Investitionsentscheidungen umsetzt. Es ist bekannt, dass der Kapitalmarktexperte bei dieser Aufgabe mit einer Wahrscheinlichkeit von 40% eine erfolglose Investition vornimmt. Weiterhin ist bekannt, dass der Robo-Advisor bei dieser Aufgabe mit einer Wahrscheinlichkeit von 30% eine erfolglose Investition tätigt. Sollte sich die Investition als erfolglos erweisen, verlieren Sie Ihren Einsatz von 3.00 EUR.

### **Ablauf**

Nach dem Lesen dieser Instruktionen und der Beantwortung von Kontrollfragen wird Ihnen die Entscheidungssituation präsentiert. In dieser müssen Sie eine der beiden möglichen Entscheidungsoptionen auswählen.

### **Auszahlung**

Für die Teilnahme an dieser Aufgabe erhalten Sie eine Auszahlung in Abhängigkeit der von Ihnen getroffenen Entscheidung und eines Zufallsprinzips, welches sich nach den oben genannten Eintrittswahrscheinlichkeiten bemisst. Sollte eine erfolglose Investition getätigt werden, verlieren Sie Ihren Einsatz von 3.00 EUR. Andernfalls verlieren Sie nichts.

### Kontrollfragen zum eigentlichen Experiment

#### Kontrollfrage 1: Welche Entscheidungsoptionen stehen Ihnen für das Tätigen der Investition zur Verfügung?

- Ich kann die Investition von einem Robo-Advisor vornehmen lassen oder sie selbst tätigen.
- Ich kann die Investition selbst tätigen oder von einem Kapitalmarktexperten vornehmen lassen.
- Ich kann die Investition von einem Kapitalmarktexperten oder von einem Robo-Advisor vornehmen lassen. (Zutreffend!)

#### Kontrollfrage 2: Was ist ein Robo-Advisor?

- Ein spezialisiertes Computerprogramm, das fortlaufend die Kapitalmärkte analysiert und selbstständig auf den jeweiligen Kunden zugeschnittene Investitionsentscheidungen umsetzt. (Zutreffend!)
- Ein spezialisierter Fachmann, der selbstständig Unternehmen zum Einsatz von Robotertechnologie in Produktionsanlagen berät und diese auf Wunsch auch aufbaut.
- Ein auf jedem handelsüblichen PC verfügbares Computerprogramm, das auf Knopfdruck die aktuellen Aktienkurse im Deutschen Aktienindex (DAX) anzeigt.

#### Kontrollfrage 3: Wie hoch ist die Wahrscheinlichkeit für eine erfolglose Investition durch den Robo-Advisor?

- 20%
- 30% (Zutreffend!)
- 40%

**Kontrollfrage 4:** Wie viel Geld verlieren Sie, wenn eine erfolglose Investition getätigt wird?

- 2.00 EUR
- 3.00 EUR (Zutreffend!)
- 5.00 EUR

**Entscheidungssituation zum eigentlichen Experiment**

Treffen Sie nun Ihre Auswahl, wer die Investition vornehmen soll!

- Ich lasse die Investition von einem Kapitalmarktexperten vornehmen.
- Ich lasse die Investition von einem Robo-Advisor vornehmen.

## Treatment 2 (Chance auf Zugewinn)

### Spielanleitung zur vorangestellten Kodieraufgabe (Real-Effort-Task)

**Kodierung**

Von 50 zu kodierenden Wörtern verschlüsseln Sie gerade Wort Nummer 3

WORT:                    S                    V                    P

CODE:                                                           

V	A	Y	W	Q	E	D	G	X	Z	K	P	F	B	O	L	I	M	T	J	S	C	U	H	R	N
115	558	607	423	329	401	421	833	808	855	317	588	251	446	747	708	986	210	214	962	239	875	903	998	523	563

### Ablauf

Bei dieser Aufgabe können Sie Geld verdienen, indem Sie 50 Buchstaben-Kombinationen (Wörter) korrekt in Zahlen kodieren.

Der Bildausschnitt oben stellt exemplarisch die Ihnen dafür gleich zur Verfügung stehende Eingabemaske dar.

Zur Erfüllung der Aufgabe müssen Sie die zufällig generierten Zahlen aus der unteren Tabelle den über den blauen Feldern angezeigten Buchstaben zuordnen, indem Sie mit der Maus in das jeweilige blaue Feld unter einem Buchstaben klicken und die korrekte Zahl aus der Tabelle mithilfe der Tastatur eingeben.

Im obigen Beispiel wurden die Buchstaben S und V bereits korrekt mit den Zahlen 239 und 115 kodiert. Für eine vollständige und korrekte Kodierung wären für den Buchstaben P noch die Zahlen 588 in das rechte blaue Feld einzutragen.

Wenn Sie in allen drei blauen Feldern jeweils die richtigen Zahlen eingegeben haben, bestätigen Sie Ihre Eingabe mit einem Klick auf OK in der unteren rechten Ecke des Bildschirms (im obigen Bildausschnitt nicht dargestellt).

Sofern alle Eingaben korrekt waren, gelangen Sie zur nächsten, zufällig generierten Buchstaben-Kombination (Wort). Dabei wird auch die Tabelle komplett neu durchmischt und jedem Buchstaben werden neue Zahlen zugeordnet.

Sollten Ihre Eingaben falsch gewesen sein, erhalten Sie einen entsprechenden Hinweis in roter Schrift und müssen die Eingabe wiederholen. Die Tabelle verändert sich in diesem Falle nicht.

Für die Kodierung aller 50 Buchstaben-Kombinationen (Wörter) sollten möglichst nicht mehr als 10 Minuten verwendet werden. Nach Beginn der Aufgabe können Sie die Ihnen noch verbleibende Zeit in der oberen rechten Ecke des Bildschirms einsehen.

### Auszahlung

Für jede richtig kodierte Buchstaben-Kombination (Wort) erhalten Sie eine Gutschrift von 4 Cent. Insgesamt können Sie bei dieser Aufgabe 2.00 EUR verdienen (50 Kombinationen à 4 Cent).

### Exemplarische Eingabemaske der vorangestellten Kodieraufgabe (Real-Effort-Task)

Verbleibende Zeit [in Sekunden] 600

Kodierung

Von 50 zu kodierenden Wörtern verschlüsselte Sie gerade Wort Nummer 1

WORT: F K W

CODE:

A	O	K	W	G	D	C	E	R	N	X	T	I	Q	U	L	M	B	H	V	S	Y	Z	P	J	F
792	685	328	552	307	483	715	937	768	146	528	463	413	489	671	757	661	899	191	589	952	486	657	448	830	633

OK

**Zwischenauszahlungsbildschirm nach Abschluss der vorangestellten  
Kodieraufgabe (Real-Effort-Task)**

**Herzlichen Glückwunsch!**

In der soeben absolvierten Kodieraufgabe haben Sie 2.00 EUR erwirtschaftet.

Bitte klicken Sie auf OK, um mit der nächsten Aufgabe fortzufahren.

## **Spielanleitung zum eigentlichen Experiment**

### **Situation**

In der Aufgabe zuvor haben Sie 2.00 EUR erwirtschaftet. Diese sind Ihnen bereits sicher. In der nun folgenden Entscheidungssituation haben Sie die Chance, zusätzliche 3.00 EUR zu gewinnen. Dafür müssen Sie eine Auswahl treffen, ob Sie eine Investition von einem Kapitalmarktexperten oder von einem Robo-Advisor tätigen lassen wollen. Ein Robo-Advisor ist ein spezialisiertes Computerprogramm, das fortlaufend die Kapitalmärkte analysiert und selbstständig auf den jeweiligen Kunden zugeschnittene Investitionsentscheidungen umsetzt. Es ist bekannt, dass der Kapitalmarktexperte bei dieser Aufgabe mit einer Wahrscheinlichkeit von 60% eine erfolgreiche Investition vornimmt. Weiterhin ist bekannt, dass der Robo-Advisor bei dieser Aufgabe mit einer Wahrscheinlichkeit von 70% eine erfolgreiche Investition tätigt. Sollte sich die Investition als erfolgreich erweisen, gewinnen Sie die zusätzlichen 3.00 EUR.

### **Ablauf**

Nach dem Lesen dieser Instruktionen und der Beantwortung von Kontrollfragen wird Ihnen die Entscheidungssituation präsentiert. In dieser müssen Sie eine der beiden möglichen Entscheidungsoptionen auswählen.

### **Auszahlung**

Für die Teilnahme an dieser Aufgabe erhalten Sie eine Auszahlung in Abhängigkeit der von Ihnen getroffenen Entscheidung und eines Zufallsprinzips, welches sich nach den oben genannten Eintrittswahrscheinlichkeiten bemisst. Sollte eine erfolgreiche Investition getätigt werden, gewinnen Sie die zusätzlichen 3.00 EUR. Andernfalls gewinnen Sie nichts.

### Kontrollfragen zum eigentlichen Experiment

#### Kontrollfrage 1: Welche Entscheidungsoptionen stehen Ihnen für das Tätigen der Investition zur Verfügung?

- Ich kann die Investition von einem Robo-Advisor vornehmen lassen oder sie selbst tätigen.
- Ich kann die Investition selbst tätigen oder von einem Kapitalmarktexperten vornehmen lassen.
- Ich kann die Investition von einem Kapitalmarktexperten oder von einem Robo-Advisor vornehmen lassen. (Zutreffend!)

#### Kontrollfrage 2: Was ist ein Robo-Advisor?

- Ein spezialisiertes Computerprogramm, das fortlaufend die Kapitalmärkte analysiert und selbstständig auf den jeweiligen Kunden zugeschnittene Investitionsentscheidungen umsetzt. (Zutreffend!)
- Ein spezialisierter Fachmann, der selbstständig Unternehmen zum Einsatz von Robotertechnologie in Produktionsanlagen berät und diese auf Wunsch auch aufbaut.
- Ein auf jedem handelsüblichen PC verfügbares Computerprogramm, das auf Knopfdruck die aktuellen Aktienkurse im Deutschen Aktienindex (DAX) anzeigt.

#### Kontrollfrage 3: Wie hoch ist die Wahrscheinlichkeit für eine erfolgreiche Investition durch den Robo-Advisor?

- 60%
- 70% (Zutreffend!)
- 80%

**Kontrollfrage 4:** Wie viel Geld gewinnen Sie, wenn eine erfolgreiche Investition getätigt wird?

- 2.00 EUR
- 3.00 EUR (Zutreffend!)
- 5.00 EUR

**Entscheidungssituation zum eigentlichen Experiment**

Treffen Sie nun Ihre Auswahl, wer die Investition vornehmen soll!

- Ich lasse die Investition von einem Kapitalmarktexperten vornehmen.
- Ich lasse die Investition von einem Robo-Advisor vornehmen.