

sofia

Sonderforschungsgruppe
Institutionenanalyse

**Die Bereitschaft zur Nutzung von Algorithmen
variiert mit der sozialen Information über die
schwache vs. starke Akzeptanz:
Eine experimentelle Studie zur Algorithm
Aversion**

Judek, Jan René

sofia-Diskussionsbeiträge 22-5, Darmstadt 2022

ISBN: 978-3-947850-03-7

sofia-Diskussionsbeiträge
zur Institutionenanalyse
Nr. 22-5

ISSN 1437-126X

ISBN 978-3-947850-03-7

Keywords

Algorithm aversion, algorithmic decision-making, herding behavior, decision aids, forecasting, behavioral finance, experiments

JEL classification

D81, D91, G17, G41, O33.

Jan René Judek, Ostfalia University of Applied Sciences, Faculty of Business,
Siegfried-Ehlers-Str. 1, D-38440 Wolfsburg, Germany, Tel.: +49 5361 892 225
420, E-Mail: ja.judek@ostfalia.de

Abstract

Der Prozess der Entscheidungsfindung wird in verschiedensten Kontexten immer häufiger von Algorithmen unterstützt. Das Phänomen der Algorithm Aversion steht der Entfaltung des technologischen Potenzials, das Algorithmen mit sich bringen, jedoch entgegen. Wirtschaftsakteure neigen dazu, ihre Entscheidungen an den Entscheidungen anderer Wirtschaftsakteure auszurichten. Daher wird in einem experimentellen Ansatz die Bereitschaft zur Nutzung eines Algorithmus bei der Abgabe von Aktienkursprognosen untersucht, wenn Informationen über die vorherige Nutzungsrate eines Algorithmus bereitgestellt werden. Es zeigt sich, dass Entscheidungsträger häufiger einen Algorithmus verwenden, wenn die Mehrheit der zuvor entscheidenden Wirtschaftsakteure diesen ebenfalls verwendet hat. Die Bereitschaft, einen Algorithmus zu verwenden, variiert mit der sozialen Information über die vorherige schwache beziehungsweise starke Akzeptanz. Zudem zeigt die Affinität zur Technikinteraktion der Wirtschaftsakteure einen Einfluss auf das Entscheidungsverhalten.

Danksagung

Mein ausdrücklicher Dank gilt Markus Spiwoks, Ibrahim Filiz und Marco Lorenz für konstruktive Kommentare und hilfreiche Diskussionen während der Anfertigung der Studie sowie Albert Heinecke für die Unterstützung während des gesamten Projektes.

Inhalt

1 Literaturüberblick und Hypothesenentwicklung	4
2 Forschungsmethodik	8
2.1 Teilnehmende.....	8
2.2 Design	8
2.3 Vorgehensweise	11
3 Ergebnisse	12
3.1 Genauigkeit der Prognosen	12
3.2 Bereitschaft zur Nutzung des Algorithmus	13
4 Diskussion	16
5 Zusammenfassung.....	19
6 Literatur	20

Abbildungen

Abbildung 1 Aktienkursentwicklung der A-Aktie und B-Aktie	8
Abbildung 2 Entscheidungsverhalten bei sozialer Information über niedrige vs. hohe Akzeptanz	14

Tabellen

Tabelle 1 Staffelung des erfolgsabhängigen Bonus nach Genauigkeit je abgegebener Prognose.....	9
Tabelle 2 Genauigkeit der Prognosen: Eigene Prognosen vs. Prognoserechner	12
Tabelle 3 Entscheidungsverhalten bei sozialer Information über niedrige vs. hohe Akzeptanz	13
Tabelle 4 Entscheidungsverhalten nach Geschlechtern.....	14
Tabelle 5 Entscheidungsverhalten unter Berücksichtigung des ATI-Scores	15

1

Literaturüberblick und Hypothesenentwicklung

In unterschiedlichsten Bereichen, wie beispielsweise der Vermögensverwaltung (Niszczoła & Kaszás, 2020; Méndez-Suárez, García-Fernández & Gallardo, 2019), der Justiz (Ireland, 2020; Simpson, 2016), der Medizin (Beck et al., 2011; Ægisdóttir et al., 2006; Grove et al., 2000), im Sport (Pérez-Toledano et al., 2019) oder der vorausschauenden Polizeiarbeit (Mohler et al., 2015) werden immer häufiger stochastische Modelle bzw. Algorithmen zur Erstellung von Vorhersagen eingesetzt. Die Prognoseleistung dieser Modelle ist der Prognoseleistung von Menschen dabei häufig überlegen (Castelo, Bos & Lehmann, 2019; Youyou, Kosinski & Stillwell, 2015; Dawes, Faust & Meehl, 1989; Meehl, 1954). Algorithmen sind in der Lage, auch da komplexe Zusammenhänge in großen Datenmengen zu identifizieren, wo Menschen an ihre kognitiven Grenzen stoßen. Nichtsdestotrotz zeigt sich, dass die Ablehnung von Prognosen automatisierter Verfahren weit verbreitet ist (für einen Literaturüberblick siehe Alvarado-Valencia & Barrero, 2014) und Menschen sich häufig gegen die Nutzung überlegener Algorithmen und für weniger genauere Prognosen von Menschen entscheiden (Dietvorst, Simmons & Massey, 2015; Önkál et al., 2009; Highhouse, 2008).

Die ablehnende Haltung gegenüber Algorithmen wird als Algorithm Aversion bezeichnet. Diese beschreibt den Umstand, dass Wirtschaftsakteure auf den Einsatz eines Algorithmus verzichten, sobald sie erkennen, dass dieser zwar überlegen, aber dennoch nicht fehlerfrei ist (Prahł & Van Swol, 2017; Dietvorst, Simmons & Massey, 2015). Während Menschen auf Prognosefehler eines Algorithmus häufig eine starke Ablehnungshaltung gegenüber der Nutzung des Algorithmus entwickeln, ist die Ablehnungshaltung bei Prognosefehlern, die von Menschen begangen werden, weniger stark ausgeprägt (Dietvorst, Simmons & Massey, 2015). Wirtschaftsakteure unterschätzen die Genauigkeit stochastischer Modelle und bevorzugen Vorhersagen von Menschen (Önkál et al., 2009). In Anbetracht der Leistungsfähigkeit von Algorithmen bei der Erstellung von Prognosen, ist die Algorithm Aversion besonders nachteilig, da Wirtschaftsakteure durch den Verzicht auf den Einsatz eines Algorithmus schlechtere Prognosen verwenden. Gleichzeitig werden durch die Nutzung menschlicher Prognosen und den Verzicht auf algorithmische Prognosen die Erfolgchancen reduziert. Wenn Algorithmen die Qualität menschlicher Prognosen übertreffen, kann das Nutzenmaximum auf Dauer nur erreicht werden, wenn Wirtschaftsakteure algorithmischen Prognosen den Vorzug vor menschlichen Prognosen geben (ausführliche Literaturübersichten zur Algorithm Aversion finden sich in Mahmud et al., 2022; Burton, Stein & Jensen, 2020; Jussupow, Benbasat & Heinzl, 2020).

Die Algorithm Aversion tritt vor allem dann auf, wenn Wirtschaftsakteure mit Algorithmen interagieren, die keine fehlerfreien Prognosen abgeben und sie daher gelegentlich mit schlechten Ratschlägen konfrontiert werden (Prahł &

Van Swol, 2017; Dietvorst, Simmons & Massey, 2015). Im Rahmen der Forschungsarbeit zur Algorithm Aversion wird das Entscheidungsverhalten von Wirtschaftsakteuren in verschiedenen Zusammenhängen betrachtet. Beispielsweise wirkt sich die wahrgenommene Objektivität einer Aufgabe auf die Bereitschaft zur Nutzung eines Algorithmus aus. Wirtschaftsakteure sind eher bereit, einen Algorithmus einzusetzen, wenn dieser eine scheinbar objektive statt einer scheinbar subjektiven Aufgabe ausführt. Die wahrgenommene Objektivität ist jedoch mittels Beschreibung formbar und mit zunehmender Objektivität einer Aufgabe, steigt auch die Bereitschaft zur Verwendung eines Algorithmus an (Castelo, Bos & Lehman, 2019). Auch die Reaktionszeit eines Algorithmus hat einen Einfluss auf die Nutzungsbereitschaft der Wirtschaftsakteure. Von Algorithmen langsam generierte Prognosen werden als weniger zuverlässig empfunden und daher seltener genutzt als schnell generierte Prognosen (Efendić, van de Calseyde & Evans, 2020).

Wirtschaftsakteure, die Erfahrung mit einem Algorithmus sammeln, indem incentivierte, gleichartige Aufgaben unter regelmäßigem Feedback bearbeitet werden, lernen die Grenzen ihrer eigenen Fähigkeiten besser einzuschätzen und nutzen einen Algorithmus häufiger (Filiz et al., 2021). Ein weiterer Ansatz zeigt, dass das wahrgenommene Lernen aus Fehlern von Algorithmen und Menschen einen Einfluss auf die Algorithm Aversion hat. Nach dem Begehen von Fehlern werden Algorithmen im Vergleich zum Menschen als weniger lernfähig angesehen. Werden jedoch Beweise erbracht, dass ein Algorithmus aus Fehlern lernen kann, führt dies zu einem höheren Vertrauen und einer häufigeren Verwendung des Algorithmus (Reich, Kaju & Maglio, 2022).

Es gibt noch weitere Möglichkeiten zur Reduzierung der Algorithm Aversion wie beispielsweise die Vermenschlichung von Algorithmen (Hodge, Mendoza & Sinha, 2021; Castelo, Bos & Lehmann, 2019), die Bereitstellung unterschiedlicher Erklärungsansätze des automatisiert erstellten Prognoseergebnisses (Ben David, Resheff & Tron, 2021) oder eine geeignete Darstellung des automatisiert erstellten Prognoseergebnisses (Kim, Giroux & Lee, 2021). Wird Wirtschaftsakteuren im Prozess der Prognoseerstellung unter Zuhilfenahme eines Algorithmus eine Möglichkeit zur Einflussnahme auf das Prognoseergebnis in Form einer nachträglichen Anpassung gewährt, so erhöht sich die Nutzungsbereitschaft signifikant. Dies gilt sogar dann, wenn die Möglichkeiten zur Anpassung des Prognoseergebnisses stark limitiert sind (Dietvorst, Simmons & Massey, 2018).

Wirtschaftsakteure neigen dazu, ihr Verhalten am Verhalten anderer Wirtschaftsakteure auszurichten (Spyrou, 2013; Raafat, Chater & Frith, 2009). Die soziale Orientierung an dem Verhalten anderer wird als Herdenverhalten (engl. „Herding“) bezeichnet. Dies beschreibt das Phänomen, dass Wirtschaftsakteure den Handlungen anderer Wirtschaftsakteure (einer Herde) folgen, unabhängig davon, ob die Handlungen rational oder irrational sind (Baddeley et al., 2012).

Nicht-rationales Herdenverhalten entsteht, wenn Wirtschaftsakteure die Handlungen anderer Wirtschaftsakteure blind nachahmen und auf die Einbeziehung rationaler Gesichtspunkte in die Entscheidungsfindung weitgehend verzichten (Baddeley et al., 2012; Devenow & Welch, 1996). Auch die Möglichkeit, die Entscheidungen anderer Wirtschaftsakteure zu beobachten (zum Beispiel die Investitionsentscheidung eines Kollegen), kann zu Herdenverhalten führen (Devenow & Welch, 1996). Durch die Nachahmung der Handlungen anderer kann es somit zu einer Angleichung des Verhaltens einer Vielzahl von einzelnen Wirtschaftsakteuren kommen (Spyrou, 2013; Raafat, Chater & Frith, 2009; Hirshleifer & Teoh, 2003).

Herdenverhalten ist unter anderem an den Aktienmärkten, beispielsweise bei Börsencrashes, beobachtbar und wird im Zusammenhang mit Investment- und Finanzentscheidungen untersucht (Mavruk, 2022; Deng, 2013; Baddeley, et al., 2012; Bikhchandani & Sharma, 2000). Das Geschehen rund um die GameStop-Aktie vom Winter 2020 bis ins Frühjahr 2021 hat eindrücklich gezeigt, welche Auswirkungen Herdenverhalten haben kann. Kleinanleger initiierten einen Short Squeeze institutioneller Anleger, die auf einen Kursrückgang der Aktie gesetzt hatten. In der Folge stieg der Kurs der GameStop-Aktie von ca. 10 USD im Oktober 2020 auf bis zu 480 USD im Januar 2021, was zu erheblichen Verlusten auf Seiten der institutionellen Anleger führte, die auf einen Kursrückgang gesetzt hatten (Lyócsa, Baumöhl & Vÿrost, 2021; Vasileiou, Bartzou & Tzanakis, 2021; Chohan, 2021). In diesem Zusammenhang zeigen Betzer und Harries (2022) eine positive Beziehung zwischen koordinierten Aktivitäten auf Social Media und verschiedenen Handelskennzahlen.

Die vorliegende Studie befasst sich mit dem Entscheidungsverhalten von Wirtschaftsakteuren, denen im Entscheidungsprozess ein Algorithmus zur Verfügung steht. Es ist denkbar, dass der Einfluss der Entscheidungen anderer Wirtschaftsakteure einen Effekt auf das Ausmaß der Algorithm Aversion haben kann. In diesem Beitrag soll daher untersucht werden, ob Wirtschaftsakteure, die mit Algorithmen interagieren, durch die Entscheidungen anderer beeinflusst werden und ihre eigenen Entscheidungen an das Verhalten anderer anpassen. Zu diesem Zweck wird ein incentiviertes, ökonomisches Experiment durchgeführt, in welchem Wirtschaftsakteure Informationen über die (niedrige bzw. hohe) Bereitschaft zur Nutzung eines Algorithmus von früher entscheidenden Wirtschaftsakteuren erhalten, bevor sie selbst über die Nutzung eines Algorithmus entscheiden. Es ist von Interesse, ob die Wirtschaftsakteure das Verhalten der anderen nachahmen und stärker oder weniger stark geneigt sind, einen Algorithmus zu nutzen. Ein konvergentes soziales Verhalten (Raafat, Chater & Frith, 2009) könnte dazu führen, dass Wirtschaftsakteure eher bereit sind, einen Algorithmus zu nutzen, wenn vorherige Entscheidungsträger sich mehrheitlich für die Verwendung eines Algorithmus entschieden haben (hohe Nutzungsrate) und vice versa. Auch in Bereichen, wie zum Beispiel dem Social Commerce, hat sich gezeigt, dass Informationen darüber, was andere tun, das Vertrauen in

neue Technologien erhöhen und den Absatz fördern können (Hajli et al., 2014; Amblee & Bui, 2011). Alexander, Blinder & Zak (2018) zeigen, dass die Bereitstellung der sozialen Information über die Nutzung eines Algorithmus einen Einfluss auf die Bereitschaft zur Nutzung haben kann. Daher wird vermutet:

H₁: Wirtschaftsakteure, die über eine vorherige hohe Akzeptanz eines Algorithmus informiert werden, nutzen häufiger einen Algorithmus als Wirtschaftsakteure, die Informationen über eine vorherige niedrige Akzeptanz erhalten.

Dies hätte unter Umständen interessante Implikationen für die Praxis zur Folge: Die Algorithm Aversion ließe sich dadurch reduzieren, dass Wirtschaftsakteuren Informationen über die hohe Bereitschaft zur Nutzung des Algorithmus zur Verfügung gestellt werden. Wenn dies dazu beiträgt, dass ein leistungsfähiger Algorithmus häufiger genutzt wird, kann zugleich eine Steigerung der volkswirtschaftlichen Effizienz ermöglicht werden. In Anbetracht des Prognoseerfolges von Algorithmen, ist es in den meisten Fällen ratsam, dessen Prognosen heranzuziehen, da diese den Vorhersagen von Menschen in den meisten Fällen überlegen sind (Dietvorst, Simmons & Massey, 2015; Önkal et al., 2009). Dennoch zögern viele Wirtschaftsakteure, einen Algorithmus zu verwenden und verringern damit die Qualität ihrer Prognosen. Sie verzichten zu Lasten ihres Prognoseerfolges bewusst auf den Einsatz eines überlegenen Algorithmus und ziehen ihre eigenen Prognosen vor (Burton, Stein & Jensen, 2019).

2 Forschungsmethodik

2.1 Teilnehmende

Zur Teilnahme an dem ökonomischen Experiment wurden 285 Probanden online über Amazon Mechanical Turk (MTurk) und Cloud Research rekrutiert. Aus der Auswertung wurden 31 Probanden aufgrund der inkorrekten Beantwortung mindestens einer Verständnisfrage (bei maximal zwei Versuchen) oder des Nichtbestehens einer Aufmerksamkeitskontrolle ausgeschlossen. Damit verbleiben 254 Probanden als Stichprobe, von denen 50,4% dem weiblichen und 49,6% dem männlichen Geschlecht zugehörig sind. Das Durchschnittsalter liegt bei 40,6 Jahren ($\sigma_{\text{Alter}} = 10,97$). Das Experiment wurde als Survey in Qualtrics programmiert. Die Erhebung wurde am 28. November 2022 durchgeführt. Die durchschnittliche Bearbeitungszeit lag bei 7,02 Minuten. Die Probanden erhielten eine fixe Antrittsprämie in Höhe von 0,30 USD und eine erfolgsabhängige Vergütung, die bis zu 1,67 USD betragen konnte.

2.2 Design

Zur Durchführung des ökonomischen Experimentes wurde eine Aufgabe zur Aktienkursprognose konzipiert. Prognoseaufgaben in diesem Bereich wurden auch bereits in anderen Studien zur Erforschung des Entscheidungsverhaltens in Zusammenarbeit mit Algorithmen bzw. stochastischen Modellen verwendet (Gubaydullina et al., 2022; Castelo, Bos & Lehman, 2019; Önkal et al., 2009). Den Probanden wird mitgeteilt, dass die Aufgabe darin besteht, zehn Aktienkursprognosen abzugeben. Den Probanden steht zum einen der Aktienkurs der A-Aktie für die Perioden 1 bis 30 und zum anderen der Aktienkurs der B-Aktie




Abbildung 1 Aktienkursentwicklung der A-Aktie und B-Aktie

für die Perioden 1 bis 20 als Graph zur Verfügung (Abbildung 1). Der Prognosegegenstand ist der Aktienkurs der B-Aktie in den Perioden 21 bis 30.

Den Probanden wird weiterhin mitgeteilt, dass die Unternehmen der A-Aktie und der B-Aktie in derselben Branche tätig und daher eng miteinander verbunden sind. Das heißt, der Erfolg des Unternehmens der A-Aktie geht eng mit dem Erfolg des Unternehmens der B-Aktie einher. Dies hat zur Folge, dass ein steigender Kurs der A-Aktie wahrscheinlich auch mit einem steigenden Kurs der B-Aktie einhergeht und vice versa. Die Probanden können also aus der Entwicklung des Kurses der A-Aktie Rückschlüsse auf die Entwicklung des Kurses der B-Aktie ziehen. Tatsächlich weisen die Kurse der A-Aktie und der B-Aktie in den Perioden 1 bis 20 einen Korrelationskoeffizienten von 0,94 auf.

Im nächsten Schritt lernen die Probanden das aus zwei Komponenten bestehende Vergütungsmodell kennen. Zum einen wird eine fixe Antrittsprämie in Höhe von 0,30 USD und zum anderen eine erfolgsabhängige Vergütung gezahlt, die sich an der Genauigkeit der abgegebenen Prognosen orientiert und umso höher ausfällt, je exakter die Prognosen sind. Zur Bestimmung der Höhe der erfolgsabhängigen Vergütung wird für jede einzelne Prognose die prozentuale Abweichung zum tatsächlich eingetretenen Aktienkurs errechnet und entsprechend einer Staffelung vergütet (Tabelle 1). Dabei wird eine Prognose nur vergütet, wenn sie maximal 15 Prozent vom tatsächlich eingetretenen Aktienkurs abweicht. So kann insgesamt eine maximale Vergütung in Höhe von 1,97 USD erzielt werden. Die Vergütung wird während des Experimentes in Coins erzielt und nach Beendigung des Experimentes zu einem Umrechnungskurs von 300 Coins = 1 USD umgetauscht.

Tabelle 1 Staffelung des erfolgsabhängigen Bonus nach Genauigkeit je abgegebener Prognose

Max. Abweichung in %	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	>15
Vergütung in Coins	50	47	43	40	37	33	30	27	23	20	17	13	10	7	3	0

Anschließend werden die Probanden darüber informiert, dass neben der Möglichkeit, eigene Aktienkursprognosen abzugeben, auch ein Prognosecomputer (Algorithmus) zur Verfügung steht. Die Probanden erhalten die Information, dass die Aktienkursprognosen des Algorithmus in der Vergangenheit in 6 von 10 Fällen maximal 10 Prozent vom tatsächlich eingetretenen Aktienkurs abweichen. Zusätzlich erhalten die Probanden je nach Treatment die Information über die niedrige versus hohe Akzeptanz des Algorithmus aus der Vorerhebung. Sie werden darüber informiert, dass dem Algorithmus dieselben Informationen

über die Aktienkursverläufe der A-Aktie und der B-Aktie wie den Probanden zur Verfügung stehen. Die Probanden haben vor der Abgabe ihrer Prognosen einmalig die Wahl, ob ihre eigenen Aktienkursprognosen oder die Aktienkursprognosen des Algorithmus zur Bestimmung der erfolgsabhängigen Vergütung herangezogen werden sollen. Diese Vorgehensweise orientiert sich an anderen Studien zur Algorithm Aversion (Dietvorst, Simmons & Massey, 2018; Dietvorst, Simmons & Massey, 2015). Die Anzeigereihenfolge der beiden Optionen ist randomisiert. Unabhängig von der Auswahl müssen die Probanden jedoch eigene Aktienkursprognosen abgeben.

Die Untersuchung ist als Between-Subjects-Design konzipiert. Die Probanden werden zufällig einem von zwei Treatments zugeordnet. In Treatment 1 (soziale Information über geringe Akzeptanz) werden die Probanden neben der Genauigkeit des Algorithmus auch über die geringe Akzeptanz zur Nutzung des Algorithmus von anderen Wirtschaftsakteuren in der Vorerhebung informiert. In Treatment 2 (soziale Information über hohe Akzeptanz) werden die Probanden neben der Genauigkeit des Algorithmus entsprechend über die hohe Akzeptanz zur Nutzung des Algorithmus von anderen Wirtschaftsakteuren in der Vorerhebung informiert.

Die Funktionsweise des Prognoserechners (Algorithmus) basiert auf einer linearen OLS-Regression mit den Aktienkursen der A-Aktie und der B-Aktie in den Perioden 1 bis 20 (in-sample Bereich). Die sich daraus ergebende Regressionsgleichung ($K_{B_t} = 1,43K_{A_t} + 10,47$) wird verwendet, um die Kurse der B-Aktie im out-of-sample Bereich der Perioden 21 bis 30 unter Berücksichtigung des Kurses der A-Aktie als unabhängige Variable zu prognostizieren. So wird beispielsweise zur Vorhersage des Aktienkurses der B-Aktie in der ersten zu prognostizierenden Periode 21 der Kurs der A-Aktie von 65 USD (Abbildung 1) in die Regressionsgleichung eingesetzt ($K_{B_{21}} = 1,43 \times 65 + 10,47$). Daraus ergibt sich eine Prognose des Prognoserechners von 103,4 USD für den Kurs der B-Aktie in Periode 21.

Zur Feststellung der vorherigen niedrigen beziehungsweise hohen Akzeptanz des Algorithmus, über die in der Hauptuntersuchung informiert wird, wurde eine Vorerhebung im gleichen Setting durchgeführt. Die Probanden der Vorerhebung ($n = 29$; $\bar{x}_{\text{Alter}} = 35,48$; $\sigma_{\text{Alter}} = 10,47$; 41,4% weiblich) wurden nach Beantwortung eines Fragebogens zur Erfassung der Affinität zur Technikinteraktion (Franke, Attig & Wessel, 2018) in zwei Hälften je nach erzieltm Score aufgeteilt. In der oberen Hälfte verwenden 35,71% der Probanden und in der unteren Hälfte 71,43% der Probanden einen zur Verfügung stehenden Algorithmus.

2.3

Vorgehensweise

Die Probanden lernen zunächst die Prognoseaufgabe und den Prognosegegenstand kennen, indem die Instruktionen gelesen werden. Der grafische Verlauf der verfügbaren Aktienkurse der A-Aktie und der B-Aktie wird dargestellt (Abbildung 1). Die Probanden erhalten Informationen über das Vergütungsmodell. Die Probanden werden darüber informiert, dass ein Prognoserechner verwendet werden kann. Sie erhalten Informationen über die Genauigkeit der Prognosen des Prognoserechners und je nach Treatment über die vorherige niedrige beziehungsweise hohe Nutzungsrate. Anschließend beantworten die Probanden einige Verständnisfragen, um sicherzustellen, dass die Aufgabe verstanden wurde. Zur Beantwortung stehen maximal zwei Versuche zur Verfügung. Im nächsten Schritt entscheiden die Probanden, ob ihre eigenen Prognosen oder die Prognosen des Prognoserechners zur Bestimmung der erfolgsabhängigen Vergütung herangezogen werden sollen. Unabhängig von der Entscheidung bearbeiten die Probanden im Anschluss die Prognoseaufgabe und geben zehn eigene Aktienkursprognosen ab. Anschließend beantworten die Probanden einen aus 9 Items bestehenden Fragebogen zur Erfassung der Affinität zur Technikinteraktion (Franke, Attig & Wessel, 2018) und einen kurzen demografischen Fragebogen. Zur Aufmerksamkeitskontrolle wird in einer zusätzlichen Fragestellung die Auswahl einer Option vorgegeben. Wird diese nicht gewählt, gilt die Kontrolle als nicht bestanden. Zuletzt werden die Probanden über den Erfolg der verwendeten Prognosen und die erzielte Vergütung informiert.

3 Ergebnisse

3.1 Genauigkeit der Prognosen

Die Analyse der Genauigkeit der abgegebenen Prognosen, die zur Grundlage der Vergütung gewählt wurden, zeigt, dass die Aktienkursprognosen des Prognoserechners exakter als die Aktienkursprognosen der Probanden sind (Tabelle 2). Während die durchschnittliche Abweichung zwischen dem prognostizierten und dem tatsächlichen Aktienkurs der Prognosen der Probanden, die ihre eigenen Prognosen zur Grundlage der Vergütung gewählt haben, bei 20,51 USD (bzw. 18,51%) liegt, weisen die Prognosen des Prognoserechners lediglich einen Prognosefehler von 10,90 USD (bzw. 8,56%) auf (absoluter Prognosefehler: $t(252) = 16,21$; $p < 0,001$; relativer Prognosefehler: $t(252) = 14,19$; $p < 0,001$). Die Vorhersagen der Probanden zeigen einen um bis zu 88% höheren Prognosefehler als die Vorhersagen des Prognoserechners. Auch bei Betrachtung des für die Vorhersagegenauigkeit gezahlten Bonus zeigt sich, dass durch die Verwendung des Prognoserechners ein um ca. 63% höherer Bonus erreicht wird ($t(252) = 17,47$; $p < 0,001$). Hinsichtlich des Prognoseerfolges und des daraus resultierenden Bonus ist es also ratsam, den Prognoserechner zu verwenden. Die von den Probanden abgegeben Prognosen führen im Durchschnitt zu einem geringeren Prognoseerfolg und somit auch zu einem geringeren erfolgsabhängigen Bonus.

Tabelle 2 Genauigkeit der Prognosen: Eigene Prognosen vs. Prognoserechner

	Grundlage der Vergütung		
	Eigene Prognosen	Prognoserechner (Algorithmus)	t-Test
Ø absoluter Prognosefehler [in USD]	20,51	10,90	$t(252) = 16,21$; $p < 0,001$; $d = 2,06$
Ø relativer Prognosefehler [in %]	18,51	8,56	$t(252) = 14,19$; $p < 0,001$; $d = 1,80$
Ø erfolgsabhängiger Bonus [in USD]	0,51	0,83	$t(252) = 17,47$; $p < 0,001$; $d = 2,22$

3.2

Bereitschaft zur Nutzung des Algorithmus

Trotz der höheren Genauigkeit der Aktienkursprognosen des Prognoserechners verzichtet ein großer Teil der Probanden darauf, den Algorithmus als Grundlage zur Bestimmung des erfolgsabhängigen Bonus zu verwenden. Insgesamt ziehen 41,34% der Probanden ihre eigenen Aktienkursprognosen den Prognosen des Prognoserechners vor und verringern dadurch ihren Prognoseerfolg.

Tabelle 3 Entscheidungsverhalten bei sozialer Information über niedrige vs. hohe Akzeptanz

	Ge- samt n	Prognoserechner (Algorithmus)		Eigene Prognosen	
		n	%	n	%
Soziale niedrige Akzeptanz (T1)	127	66	51,97%	61	48,03%
Soziale hohe Akzeptanz (T2)	127	83	65,35%	44	34,65%

Die Hypothese H_1 besagt, dass Probanden, die über eine vorherige hohe Akzeptanz eines Algorithmus informiert werden, diesen signifikant häufiger verwenden als Probanden, die Informationen über eine vorherige niedrige Akzeptanz erhalten. Der einzige Unterschied zwischen den beiden Treatments besteht in der Information zur niedrigen beziehungsweise hohen Nutzungsrate des Prognoserechners, welche sich aus der Vorerhebung ergibt. Tatsächlich unterscheidet sich das Entscheidungsverhalten der Probanden zur Verwendung des Prognoserechners zwischen den Treatments. Bei Information über die geringe Akzeptanz eines Algorithmus (T1) setzen 51,97% der Probanden den Prognoserechner zur Bestimmung des erfolgsabhängigen Bonus ein (Tabelle 3; Abbildung 2). Bei Information über die hohe Akzeptanz eines Algorithmus (T2) nutzen hingegen bereits 65,35% der Probanden den Prognoserechner (χ^2 ($n = 254$) = 4,69; $p = 0.030$). Somit kann H_1 nicht verworfen werden. Die soziale Information über die häufige Verwendung des Algorithmus führt dazu, dass die Probanden signifikant häufiger den Algorithmus einsetzen. Die Information über die vorherige Bereitschaft zur Verwendung eines Algorithmus von anderen Wirtschaftsakteuren hat einen Einfluss auf die Entscheidung zur Verwendung eines Algorithmus.

Weitere Analysen zeigen, dass die Wahl zur Nutzung des Algorithmus vom Geschlecht beeinflusst wird. Sowohl in Treatment 1 (χ^2 ($n = 127$) = 3,69; $p = 0.055$) als auch in Treatment 2 (χ^2 ($n = 127$) = 8,14; $p = 0.004$) nutzen Frauen häufiger den Algorithmus als Männer. Der Vergleich der Treatments unter Berücksichtigung des Geschlechts zeigt, dass der Effekt vor allem von Frauen (χ^2

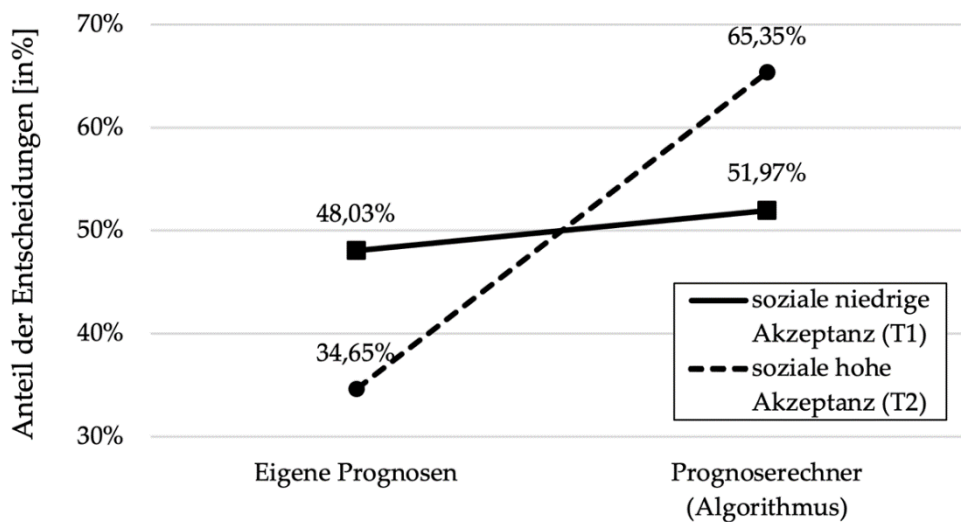


Abbildung 2 Entscheidungsverhalten bei sozialer Information über niedrige vs. hohe Akzeptanz

($n = 128$) = 3,20; $p = 0.073$) und weniger von Männern (χ^2 ($n = 126$) = 0,70; $p = 0.402$) getrieben wird. Während bei niedriger Akzeptanz (T1) 61,40% der Frauen den Algorithmus einsetzen, nutzen bei hoher Akzeptanz (T2) bereits 76,06% der Frauen den Algorithmus. Bei den Männern hingegen nutzen in T1 (respektive T2) 44,29% (51,79%) den Algorithmus (Tabelle 4). Das Alter der Probanden zeigt hingegen keinen statistisch signifikanten Einfluss auf die Entscheidungen ($t(252) = 1,97$; $p = 0,278$).

Tabelle 4 Entscheidungsverhalten nach Geschlechtern

	Geschlecht	Algorithmus		Eigene Prognosen	
		n	%	n	%
Soziale niedrige Akzeptanz (T1)	männlich	31	44,29%	39	55,71%
	weiblich	35	61,40%	22	38,60%
Soziale hohe Akzeptanz (T2)	männlich	29	51,79%	27	48,21%
	weiblich	54	76,06%	17	23,94%

Hinsichtlich der Affinität zur Technikinteraktion (ATI) weisen die Probanden insgesamt einen durchschnittlichen ATI-Score von 3,84 auf. Ein ATI-Score von 1,00 korrespondiert dabei mit einer geringen und ein ATI-Score von 6,00 mit einer starken Affinität zur Technikinteraktion. Bei Betrachtung des ATI-Scores ergeben sich zwischen den Treatments kaum Unterschiede: In beiden Treatments liegt der Anteil der Probanden, die einen geringen ATI-Score aufweisen bei ca.

30% und der Anteil der Probanden, die einen hohen ATI-Score aufweisen bei ca. 70% (Tabelle 5). Damit weist die Mehrheit der Probanden eine hohe Affinität zur Technikinteraktion auf. Auffällig sind hingegen die Unterschiede im Entscheidungsverhalten zur Nutzung des Algorithmus unter Berücksichtigung des ATI-Scores. Vor allem Probanden, die einen geringen ATI-Score aufweisen, verwenden häufiger den Prognoserechner. Während bei Informationen über die niedrige Akzeptanz 64,86% der Probanden, die einen niedrigen ATI-Score aufweisen, den Algorithmus nutzen, wählen bei Informationen über die hohe Akzeptanz sogar 84,21% der Probanden den Algorithmus (χ^2 (n = 75) = 3,71; p = 0.054). Bei Informationen über eine niedrige Akzeptanz nutzen 46,67% der Probanden, die einen hohen ATI-Score aufweisen und bei hoher Akzeptanz 57,30% der Probanden den Algorithmus (χ^2 (n = 179) = 2,03; p = 0.154). Vor allem Probanden (84,21%), die eine geringe ATI aufweisen, lassen sich also eher von der sozialen Information über die starke Akzeptanz beeinflussen und zur Nutzung des Algorithmus bewegen als Probanden (57,30%), die eine hohe ATI aufweisen (χ^2 (n = 127) = 8,52; p = 0.004).

Tabelle 5 Entscheidungsverhalten unter Berücksichtigung des ATI-Scores

	ATI-Score*	Gesamt		davon Algorithmus	davon eigene Prognosen
		n	%	%	%
Soziale niedrige Akzeptanz (T1)	≤ 3,5	37	29,13%	64,86%	35,14%
	> 3,5	90	70,87%	46,67%	53,33%
Soziale hohe Akzeptanz (T2)	≤ 3,5	38	29,92%	84,21%	15,79%
	> 3,5	89	70,08%	57,30%	42,70%

*Der ATI-Score kann Werte von 1,00 (geringe ATI) bis 6,00 (starke ATI) annehmen.

4 Diskussion

Die Aversion vor der Verwendung von Algorithmen, die in einem Prognoseprozess durchschnittlich erfolgreicher sein können, ist kostspielig. Dadurch bleiben algorithmische Angebote ungenutzt und Entscheidungsträger profitieren nicht von einer höheren Genauigkeit, die Vorhersagen von Algorithmen oft bieten (Reich, Kaju & Maglio, 2022). Es zeigt sich, dass die Algorithm Aversion durch die Möglichkeit zur Anpassung der algorithmischen Vorhersage zurückgeht (Dietvorst, Simmons & Massey, 2018). Dennoch entsteht hier ein Zielkonflikt: Insgesamt erhöht die Möglichkeit der Anpassung zwar die Akzeptanz zur Nutzung von Algorithmen, die vorgenommenen Anpassungen verringern jedoch gleichzeitig die Qualität der endgültigen Entscheidungen (Sele & Chugunova, 2022).

Die Ergebnisse der vorliegenden Studie zeigen, dass eine Reduzierung der Algorithm Aversion auch ohne Anpassung der algorithmischen Prognose erreicht werden kann. Dadurch bleibt eine etwaige Verschlechterung der endgültigen Entscheidungen durch Anpassungen ausgeschlossen. Wirtschaftsakteure neigen auch im Prozess der algorithmischen Entscheidungsfindung dazu, sich an den Entscheidungen anderer Wirtschaftsakteure zu orientieren, was im Einklang zu den Befunden zum Herdenverhalten steht (Spyrou, 2013). Wirtschaftsakteure, die neben der Genauigkeit eines Algorithmus auch über dessen vorherige starke Akzeptanz von anderen Wirtschaftsakteuren informiert werden, sind signifikant häufiger bereit, einen Algorithmus einzusetzen als Wirtschaftsakteure, die neben der Genauigkeit auch über dessen vorherige schwache Akzeptanz informiert werden. Die Ergebnisse zeigen jedoch auch, dass dieser Effekt vor allem bei Frauen und weniger bei Männern auftritt. Es liegen Hinweise darauf vor, dass Overconfidence einen Einfluss auf die Algorithm Aversion ausüben kann (Filiz et al., 2021). Spiwoks und Bizer (2018) zeigen, dass die Einschätzungen von Männern und Frauen bei der Abgabe von Aktienkursprognosen stark auseinanderfallen und Frauen eher zu einer Underconfidence neigen. Dies könnte sich auch auf die Entscheidungen zur Nutzung eines Algorithmus in der vorliegenden Studie auswirken.

Alexander, Blinder und Zak (2018) untersuchen in vier Treatments (keine Information, Information über die Genauigkeit und Information über die niedrige beziehungsweise hohe soziale Akzeptanz) die Bereitschaft, ein automatisiertes Hilfsmittel bei der Lösung eines Labyrinths zu verwenden. In den beiden Treatments, die über die soziale Akzeptanz des automatisierten Hilfsmittels informieren, wird den Probanden eine soziale Akzeptanz von 54% bzw. 70% präsentiert. Im Ergebnis zeigt sich, dass soziale Informationen über die Akzeptanz (unabhängig vom Ausmaß der Akzeptanz), das heißt das Wissen darüber, dass andere Personen das Hilfsmittel verwendet haben, die Wirtschaftsakteure am ehesten dazu bewegt, das Hilfsmittel selbst einzusetzen (Alexander, Blinder &

Zak, 2018). Einschränkend muss allerdings erwähnt werden, dass die Studie mit einer geringen Anzahl von Probanden durchgeführt wurde, die zwei von vier Treatments zugeordnet waren. Zudem ist das technische Hilfsmittel nicht die erkennbar beste Option und für die Nutzung des Hilfsmittels muss gezahlt werden. Zuletzt handelt es sich nicht um eine klassische Prognoseaufgabe, die entweder automatisiert oder von einem Menschen ausgeführt werden kann, sondern um ein Hilfsmittel, das eine eigene Lösung des Labyrinths erleichtern kann. Die vorliegenden Ergebnisse zeigen, anders als die Ergebnisse von Alexander, Blinder und Zak (2018), dass besonders die soziale Information über eine hohe Akzeptanz dazu geeignet ist, Wirtschaftsakteure zur Nutzung eines Algorithmus zu bewegen. Bei sozialer Information über eine niedrige Akzeptanz sind hingegen signifikant weniger Wirtschaftsakteure bereit, einen Algorithmus zu nutzen. Die Bereitschaft zur Verwendung eines Algorithmus variiert also mit der Information über die schwache beziehungsweise starke Akzeptanz.

Die vorliegenden Ergebnisse deuten auch darauf hin, dass sich vor allem Wirtschaftsakteure, die eine geringe Affinität zur Technikinteraktion aufweisen, von den Entscheidungen anderer Wirtschaftsakteure beeinflussen lassen. Während sich technikaffine Wirtschaftsakteure nur geringfügig von der Information zur vorherigen Akzeptanz beeinflussen lassen, sind nicht- bzw. wenig-technikaffine Wirtschaftsakteure bei Informationen über eine starke Akzeptanz deutlich häufiger bereit einen Algorithmus einzusetzen als bei Informationen über eine schwache Akzeptanz. Dies könnte darauf hindeuten, dass je unwissender Wirtschaftsakteure hinsichtlich der Fähigkeiten eines Algorithmus sind, desto eher auf die vermutete „Schwarmintelligenz“ der Gesellschaft beziehungsweise den Entscheidungen der vorherigen Entscheidungsträger vertrauen.

Auch technikaffine Wirtschaftsakteure befürworten keineswegs den Einsatz von Technik jeglicher Art. Technikaffine Wirtschaftsakteure könnten allerdings über ein höheres Bewusstsein darüber verfügen, wann es sinnvoll ist, Technik einzusetzen und wann auf den Einsatz verzichtet werden sollte. Eine Verbindung zwischen den tatsächlichen Beweggründen zur Nutzung eines Algorithmus (z.B. Genauigkeit, Zeitdruck, Gewohnheit, etc.) und der Algorithm Aversion herzustellen, sowie die Identifizierung weiterer Möglichkeiten zur Reduzierung der Algorithm Aversion bleibt der nachfolgenden Forschung vorbehalten. In der vorliegenden Studie wird eine Aufgabe zur Vorhersage von Aktienkursen verwendet. Obwohl die Vorhersage von Aktienkursen im Allgemeinen als eine schwierige Aufgabe angesehen werden kann, erlaubt das Design dieser Studie auch Laien eine Vorhersage abzugeben. Dennoch ist es möglich, dass es Bereiche gibt, in denen Entscheidungsträger eher dazu geneigt sind, Algorithmen einzusetzen als in anderen Bereichen und dieser Umstand sich auf die Ergebnisse auswirken kann. Außerdem können andere Faktoren als die Affinität zur Technikinteraktion oder das Geschlecht einen Einfluss auf die Entscheidungen

von Wirtschaftsakteuren zur Verwendung eines Algorithmus ausüben. Die vorliegende Studie liefert jedoch erste Erkenntnisse über die ATI, die einen Einfluss auf die Algorithm Aversion haben kann.

5 Zusammenfassung

Die Algorithm Aversion führt dazu, dass Wirtschaftsakteure auf den Einsatz überlegener Algorithmen verzichten, sobald sie erkennen, dass diese fehleranfällig sein können. Eigene Prognosen werden den Prognosen von Algorithmen vorgezogen, was insgesamt zu einem geringeren Prognoseerfolg führen kann. Auch in der vorliegenden Studie zeigt sich im Bereich der Aktienkursprognosen, dass ein Prognoserechner, der eine einfache lineare Regression zur Erstellung seiner Prognose anwendet, den eigenen Prognosen der Probanden deutlich überlegen ist. Dennoch verzichtet ein großer Teil der Probanden auf die Nutzung des Prognoserechners und verwendet schlechtere eigene Aktienkursprognosen.

Die vorliegende Studie zeigt, dass bei der Entscheidung zur Nutzung eines Algorithmus das vorherige Verhalten von anderen Wirtschaftsakteuren im Entscheidungsprozess berücksichtigt wird. Werden Wirtschaftsakteure nicht nur über die Genauigkeit eines Algorithmus, sondern zusätzlich auch über eine hohe Nutzungsrate bei anderen Wirtschaftsakteuren informiert, verwenden sie signifikant häufiger einen Algorithmus, als wenn über eine vorherige niedrige Nutzungsrate informiert werden. Die Information über die schwache beziehungsweise starke Akzeptanz eines Algorithmus, also darüber wie andere Wirtschaftsakteure entschieden haben, hat einen Einfluss auf die Algorithm Aversion. Die Bereitstellung von Informationen über eine starke Akzeptanz führt zu einer Reduzierung der Algorithm Aversion. Wirtschaftsakteure entscheiden sich mehrheitlich für die Nutzung eines Algorithmus, wenn sich früher entscheidende Wirtschaftsakteure mehrheitlich für die Nutzung eines Algorithmus entschieden haben. Wirtschaftsakteure, die eine niedrige Affinität zur Technikinteraktion (ATI) aufweisen, sind durch die soziale Information der starken Akzeptanz eher zur Nutzung des Algorithmus geneigt als Wirtschaftsakteure, die einen hohen ATI-Score aufweisen.

Zusammenfassend ist festzustellen, dass die Bereitschaft zur Nutzung eines Algorithmus mit der sozialen Information über die schwache beziehungsweise starke Akzeptanz variiert. Somit kann die Bereitstellung von Informationen über die hohe Bereitschaft von anderen Wirtschaftsakteuren, einen Algorithmus zu verwenden, in der wirtschaftlichen Praxis dazu beitragen, dass die Bereitschaft zur Nutzung eines Algorithmus erhöht wird. Dies kann zu einer Verbesserung der Prognosequalität insgesamt und einer Steigerung der volkswirtschaftlichen Effizienz beitragen. Dennoch ist weitere Forschung notwendig, um Ursachen und weitere Möglichkeiten zur Reduzierung der Algorithm Aversion zu identifizieren.

6 Literatur

- Ægisdóttir, S., White, M.J., Spengler, P.M., Maugherman, A.S., Anderson, L.A., Cook, R.S., Nichols, C.N., Lampropoulos, G., Walker, B.S., Cohen, G.R., & 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*, 34(3), 341-382.
- Alexander, V., Blinder, C., & Zak, P.J. (2018). Why trust an algorithm? Performance, cognition, and neurophysiology. *Computers in Human Behavior*, 89, 279-288.
- Alvarado-Valencia, J.A., & Barrero, L.H. (2014). Reliance, trust and heuristics in judgmental forecasting. *Computers in Human Behavior*, 36, 102-113.
- Ambler, N., & Bui, T.X. (2011). Harnessing the Influence of Social Proof in Online Shopping: The Effect of Electronic Word of Mouth on Sales of Digital Microproducts. *International Journal of Electronic Commerce*, 16(2), 91-114.
- Baddeley, M., Burke, C.J., Schultz, W., & Tobler, P.N. (2012). Herding in Financial Behaviour: A Behavioural and Neuroeconomic Analysis of Individual Differences. <https://doi.org/10.17863/CAM.1041>.
- Beck, A., Sangoi, A., Leung, S., Marinelli, R. J., Nielsen, T., Vijver, M. J., West, R., Rijn, M.V., & Koller, D. (2011). Systematic Analysis of Breast Cancer Morphology Uncovers Stromal Features Associated with Survival. *Science Translational Medicine*, 3(108), 108-113.
- Ben David, D., Resheff, Y.S., & Tron, T. (2021). Explainable AI and Adoption of Algorithmic Advisors: an Experimental Study. *ArXiv, abs/2101.02555*.
- Betzer, A., & Harries, J.P. (2022). How online discussion board activity affects stock trading: the case of GameStop. *Financial Markets and Portfolio Management*, 36(4), 443-472.
- Bikhchandani, S., & Sharma, S.K. (2000). Herd Behavior in Financial Markets. *IMF Staff Papers*, 47(3), 279-310.
- Burton, J., Stein, M., & Jensen, T.B. (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.
- Chohan, U.W., YOLO Capitalism (2022). Available at SSRN 3775127.
- Dawes, R.M., Faust, D., & Meehl, P.E. (1989). Clinical versus actuarial judgment. *Science*, 243(4899), 1668-1674.
- Deng, G. (2013). The Herd Behavior of Risk-Averse Investor Based on Information Cost. *Journal of Financial Risk Management*, 2(4), 87-91.
- Devenow, A., & Welch, I. (1996). Rational herding in financial economics. *European Economic Review*, 40(3-5), 603-615.

- 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: General*, 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, 103-114.
- Filiz, I., Judek, J.R., Lorenz, M., & Spiwoks, M. (2021). Reducing algorithm aversion through experience. *Journal of Behavioral and Experimental Finance*, 31, 100524.
- Franke, T., Attig, C., & Wessel, D. (2019). A Personal Resource for Technology Interaction: Development and Validation of the Affinity for Technology Interaction (ATI) Scale. *International Journal of Human-Computer Interaction*, 35(6), 456-467.
- Grove, W.M., Zald, D.H., Lebow, B.S., Snitz, B.E., & Nelson, C. (2000). Clinical versus mechanical prediction: a meta-analysis. *Psychological Assessment*, 12(1), 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*, 2(4), 448-470.
- Hajli, N., Lin, X., Featherman, M., & Wang, Y. (2014). Social Word of Mouth: How Trust Develops in the Market. *International Journal of Market Research*, 56(5), 673-689.
- Highhouse, S. (2008). Stubborn Reliance on Intuition and Subjectivity in Employee Selection. *Industrial and Organizational Psychology*, 1(3), 333-342.
- Hirshleifer, D., & Hong Teoh, S. (2003). Herd behaviour and cascading in capital markets: A review and synthesis. *European Financial Management*, 9(1), 25-66.
- Hodge, F.D., Mendoza, K.I., & Sinha, R.K. (2021). The effect of humanizing robo-advisors on investor judgments. *Contemporary Accounting Research*, 38(1), 770-792.
- Ireland, L. (2019). 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. *ECIS*.
- 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(7), 1140-1155.

- Lyócsa, Š., Baumöhl, E., & Výrost, T. (2021). YOLO trading: Riding with the herd during the GameStop episode. *Finance Research Letters*, 46(A), 102359.
- 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.
- Mavruk, T. (2022). Analysis of herding behavior in individual investor portfolios using machine learning algorithms. *Research in International Business and Finance*, 62, 101740.
- Meehl, P.E. (1954). Clinical versus statistical prediction: A theoretical analysis and a review of the evidence.
- 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*, 5(4), 81.
- Mohler, G.O., Short, M.B., Malinowski, S., Johnson, M.E., Tita, G.E., Bertozzi, A., & Brantingham, P.J. (2015). Randomized Controlled Field Trials of Predictive Policing. *Journal of the American Statistical Association*, 110, 139-1411.
- Niszczoła, P., & Kaszás, D. (2020). Robo-investment aversion. *PLoS ONE*, 15(9), 0239277, 1-19.
- Önkál, D., Goodwin, P., Thomson, M.E., Gönül, S., & Pollock, A.C. (2009). The relative influence of advice from human experts and statistical methods on forecast adjustments. *Journal of Behavioral Decision Making*, 22(4), 390-409.
- Pérez-Toledano, M., Rodríguez, F.J., García-Rubio, J., & Ibáñez, S.J. (2019). Players' selection for basketball teams, through Performance Index Rating, using multiobjective evolutionary algorithms. *PLoS ONE*, 14(9), 0221258, 1-20.
- Prahl, A., & Van Swol, L. (2017). Understanding algorithm aversion: When is advice from automation discounted? *Journal of Forecasting*, 36(6), 691-702.
- Raafat, R.M., Chater, N., & Frith, C. (2009). Herding in humans. *Trends in Cognitive Sciences*, 13(10), 420-428.
- Reich, T., Kaju, A., & Maglio, S.J. (2022). How to overcome algorithm aversion: Learning from mistakes. *Journal of Consumer Psychology*, ahead-of-print, 1-18.
- Sele, D., & Chugunova, M. (2022). Putting a Human in the Loop: Increasing Uptake, but Decreasing Accuracy of Automated Decision-Making. *Max Planck Institute for Innovation & Competition Research Paper No. 22-20*. Available at SSRN 4285645.

- Simpson, B. (2016). Algorithms or advocacy: does the legal profession have a future in a digital world? *Information & Communications Technology Law*, 25(1), 50-61.
- Spiwoks, M., & Bizer, K. (2018). On the Measurement of Overconfidence: An Experimental Study. *International Journal of Economics and Financial Research*, 4(1), 30-37.
- Spyrou, S.I. (2013). Herding in financial markets: a review of the literature. *Review of Behavioral Finance*, 5, 175-194.
- Vasileiou, E., Bartzou, E., & Tzanakis, P. (2021). Explaining Gamestop Short Squeeze using Intraday Data and Google Searches. Available at SSRN 3805630.
- 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*, 112(4), 1036-1040.