

Reduzierung der Algorithm Aversion durch Erfahrung

Filiz, I.; Judek, J.R.; Lorenz, M.; Spiwoks, M.

sofia-Diskussionsbeiträge 21-1, Darmstadt 2021

ISBN: 978-3-941627-86-4

Reduzierung der Algorithm Aversion durch Erfahrung

Ibrahim Filiz,
Jan René Judek,
Marco Lorenz und
Markus Spiwoks

Wolfsburg, Göttingen Januar 2021

Keywords

Algorithm aversion, overconfidence, operating experience, stock market forecasting, behavioral finance, experiments.

JEL classification

D83, D84, D91, G17, G41.

Abstract

Wir untersuchen experimentell die Persistenz der Algorithm Aversion im Hinblick auf Lernprozesse. Probanden sind aufgefordert in 40 Runden je eine Aktienkursprognose (steigend oder fallend) abzugeben. Es steht ein Prognosecomputer (Algorithmus) zur Verfügung, der eine Erfolgsquote von 70% aufweist. Intuitive Prognosen der Probanden führen in aller Regel zu einer deutlich schlechteren Erfolgsquote. Feedbacks nach jeder Prognoserunde und ein klarer ökonomischer Anreiz führen dazu, dass die Probanden ihre eigenen Prognosefähigkeiten besser einzuschätzen lernen. Dabei geht auch die Algorithm Aversion signifikant zurück.

Ibrahim Filiz

Ostfalia University of Applied Sciences, Faculty of Business, Siegfried-Ehlers-Str. 1, D-38440 Wolfsburg, Germany, Tel.: +49 160 3344 078
E-Mail: ibrahim.filiz@ostfalia.de

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

Marco Lorenz

Georg August University Göttingen, Faculty of Economic Sciences, Platz der Göttinger Sieben 3, D-37073 Göttingen, Germany, Tel.: +49 1522 6672 503
E-Mail: marco.lorenz@stud.uni-goettingen.de

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

Inhalt

1 Einführung	5
2 Experimentelles Design und Hypothesen.....	7
3 Ergebnisse	11
4 Zusammenfassung.....	19
5 Literatur	21
6 Anhänge.....	24
6.1 Anhang 1: Spielanleitung.....	24
<i>6.1.1</i> Das Spiel	24
<i>6.1.2</i> Ablauf	25
<i>6.1.3</i> Auszahlung	25
<i>6.1.4</i> Hinweise	25
6.2 Anhang 2: Kontrollfragen.....	26
6.3 Anhang 3: Bildschirm	27
6.4 Anhang 4: Kursverlaufsvarianten	28

Tabellen

Tabelle 1: Entscheidungen für und gegen den Algorithmus..... 12
Tabelle 2: Entscheidungen für und gegen den Algorithmus nach Prognoserunden ... 14
Tabelle 3: Entscheidungsverhalten in den ersten und in den letzten
Prognoserunden 17
Tabelle 4: Effektstärken der Lernprozesse nach Pearsons r und Cohens d 18

Abbildungen

Abbildung 1: Wahrscheinlichkeitsverteilung des Zufallseinflusses ϵ_t 7
Abbildung 2: Anteile der Entscheidungen zugunsten des Algorithmus in % nach
Prognoserunden 13
Abbildung 3: Prozentualer Anteil der Entscheidungen für den Algorithmus in den
ersten 5, 10, 15 beziehungsweise 20 Prognoserunden..... 16
Abbildung 4: Prozentualer Anteil der Entscheidungen für den Algorithmus in den
letzten 20, 15, 10 beziehungsweise 5 Prognoserunden..... 16
Abbildung 5: Wahrscheinlichkeitsverteilung des Zufallseinflusses ϵ_t 25

1

Einführung

Bankkunden zeigen sich zunehmend preissensibel, was Banken unter erheblichen Kostendruck setzt. Insbesondere im kostenträchtigen Vermögensmanagement bemühen sich Banken, kleine und mittlere Vermögen mit geringerem Personalaufwand als bisher zu betreuen. Die erheblichen Fortschritte im Bereich der künstlichen Intelligenz führen dazu, dass immer mehr Banken Robo Advisor anbieten, die den Kunden ein weitgehend automatisiertes Vermögensmanagement ermöglichen (vgl. bspw. Rühr et al., 2019; Jung et al., 2018; Singh & Kaur, 2017). Es gibt einige typische Fehler, die sowohl von Anlageprofis als auch von Laien oft begangen werden. So werden Wertpapierportfolios oft unterdiversifiziert (vgl. bspw. Dimmock et al., 2016; Anderson, 2013; Hibbert, Lawrence & Prakash, 2012; Goetzmann & Kumar, 2008) oder es werden zu häufig Portfolioumschichtungen vorgenommen (vgl. bspw. Barber & Odean, 2001; Barber & Odean, 2000). Viele Börsenakteure neigen dazu, bei der Beobachtung von Kursentwicklungen an den Kapitalmärkten Muster zu erkennen, wo in Wirklichkeit keine Muster vorhanden sind (vgl. bspw. Zielonka, 2004; Wärneryd, 2001; Gilovich, Vallone & Tversky, 1985; Roberts, 1959). So werden sie von ihrer Intuition oft in suboptimale Investitionsentscheidungen gelockt (vgl. bspw. Frydman & Camerer, 2016; Kudryavtsev, Cohen & Hon-Snir, 2013). Diese problematischen Verhaltensweisen lassen sich mit einem entsprechend ausgerichteten Robo Advisor mühelos vermeiden. Den Kunden kann somit ein durchaus zuverlässiges und preisgünstiges Vermögensmanagement-Angebot gemacht werden, das darüber hinaus Risiko und Rendite in ein günstiges Verhältnis bringt (vgl. bspw. Rossi & Utkus, 2020; Bhatia, Chandani & Chhateja, 2020; D'Acunto, Prabhala & Rossi, 2019; Beketov, Lehmann und Wittke, 2018; Uhl & Rohner, 2018).

Allerdings zeigen viele Menschen Vorbehalte gegenüber automatisierten Verfahren. Das gilt häufig sogar dann, wenn klar erkennbar wird, dass ein Algorithmus (wie beispielsweise ein Robo Advisor) bessere Ergebnisse erzielt, als wenn Experten sich der Aufgabe annehmen. Dieses Phänomen wird als Algorithm Aversion bezeichnet (vgl. bspw. Erlei et al., 2020; Ku, 2020; Köbis & Mosink, 2020; Castelo, Bos & Lehmann, 2019; Dietvorst, Simmons & Massey, 2018; Prahl & Van Swol, 2017; Dietvorst, Simmons & Massey, 2015). Diese Problemlage tritt auch dann auf, wenn Wirtschaftssubjekte sich entscheiden müssen, ob sie auf sich selbst oder auf einen Algorithmus vertrauen (vgl. E-fendić, Van de Calseyde & Evans, 2020; Rühr et al., 2019; Dietvorst, Simmons & Massey, 2018; Dietvorst, Simmons & Massey, 2015). Selbst wenn deutliche Hinweise darauf vorliegen, dass es ihnen kaum möglich sein wird, auf Dauer bessere Entscheidungen zu treffen als der Algorithmus, vertrauen viele Wirtschaftssubjekte eher auf sich selbst.

Es liegt nahe anzunehmen, dass dabei Selbstüberschätzung eine bedeutende Rolle spielt. Algorithm Aversion und Overconfidence sind also vermutlich nahe

beieinander liegende, artverwandte Phänomene. Darin liegt eine Chance. Proeger & Meub (2014) zeigen, dass ökonomische Anreize, wiederholtes Feedback und allmählich wachsende Erfahrung der Probanden dazu führen können, dass sie ihre Fähigkeiten besser einzuschätzen lernen. Ein Lernprozess kann also zu einem Rückgang der Overconfidence führen.

Insofern erscheint es denkbar, dass auch die Algorithm Aversion spürbar reduziert werden kann, sofern sich Entscheidungssituationen wiederholen, klare Feedbacks erfolgen und ökonomische Anreize bestehen. In der vorliegenden Studie wird genau dies anhand wiederholter Aktienkursprognosen experimentell überprüft.

2 Experimentelles Design und Hypothesen

Die Probanden haben die Aufgabe, in 40 Perioden den Kursverlauf einer Aktie zu prognostizieren. Allerdings müssen sie nicht den exakten Kurs voraussagen, sondern nur, ob der Kurs der Aktie steigen wird oder ob er fallen wird. Der Kurs der Aktie bleibt immer in Bewegung. Es kommt also nie zu einem unveränderten Kurs. Der Kurs steigt oder er fällt. Der Kurs der Aktie wird im Wesentlichen durch vier fundamentale Einflussfaktoren (A, B, C und D) bestimmt. Allerdings werden diese fundamentalen Einflussfaktoren durch einen Zufallseinfluss ε ergänzt (vgl. dazu Filiz, Nahmer & Spiwoks, 2019; Meub et al., 2015; Becker, Leitner & Leopold-Wildburger, 2009).

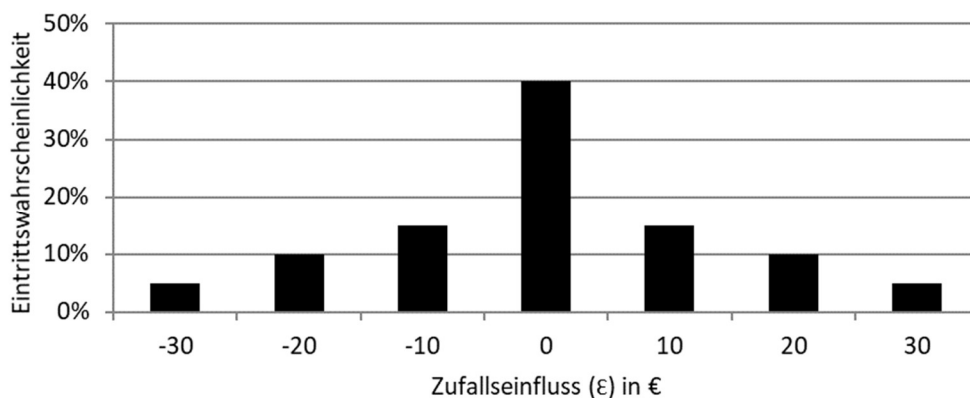
Der Kurs (K) der Aktie kommt wie folgt zustande:

$$K_t = 32 A_t + 1 B_t - 18 C_t + 44 D_t + \varepsilon_t$$

Die fundamentalen Einflussfaktoren (A, B, C und D) würden ohne den Zufallseinfluss ε_t in jeder Periode zu einer Kursveränderung zwischen 0 € und 10 € führen. Entwickeln sich die fundamentalen Einflussfaktoren alles in allem günstig, käme es ohne den Zufallseinfluss ε_t stets zu einer Kurssteigerung zwischen 0 € und 10 €. Das heißt: $0 \text{ €} < (K_t - \varepsilon_t) < +10 \text{ €}$. Entwickeln sich die fundamentalen Einflussfaktoren hingegen alles in allem ungünstig, käme es ohne den Zufallseinfluss ε_t stets zu einem Kursrückgang zwischen 0 € und 10 €. Das heißt: $0 \text{ €} > (K_t - \varepsilon_t) > -10 \text{ €}$.

Der Zufallseinfluss ε_t hat einen Erwartungswert von 0 und weist folgende Verteilung auf: Mit 40%iger Wahrscheinlichkeit verändert der Zufallseinfluss ε_t den Kurs nicht. Mit jeweils 15%iger Wahrscheinlichkeit verändert der Zufallseinfluss ε_t den Kurs um +10 € oder um -10 €. Mit jeweils 10%iger Wahrscheinlichkeit verändert der Zufallseinfluss ε_t den Kurs um +20 € oder um -20 €. Und mit jeweils 5%iger Wahrscheinlichkeit verändert der Zufallseinfluss ε_t den Kurs um +30 € oder um -30 € (Abb. 1).

Abbildung 1: Wahrscheinlichkeitsverteilung des Zufallseinflusses ε_t



Die fundamentalen Einflussfaktoren werden den Probanden vor jeder Prognoserunde bekannt gegeben. Sie haben in jeder Prognoserunde die Möglichkeit, entweder ihre eigene Einschätzung (Kurs steigt oder Kurs fällt) abzugeben oder die Entscheidung an einen Prognosecomputer (Algorithmus) zu delegieren. Der Prognosecomputer schätzt die Entwicklungsrichtung des künftigen Kurses der Aktie in 70% der Fälle zutreffend ein. Der Algorithmus nutzt also lediglich die zur Verfügung stehenden Informationen über die fundamentalen Einflussfaktoren und den Zufallseinfluss ε_t optimal aus.

Da der Erwartungswert des Zufallseinflusses ε_t null beträgt, rechnet der Algorithmus: $K_t = 32 A_t + 1 B_t - 18 C_t + 44 D_t + 0$. Dann vergleicht er K_t mit K_{t-1} . Bei $K_t > K_{t-1}$ prognostiziert der Algorithmus einen steigenden Kursverlauf. Bei $K_t < K_{t-1}$ prognostiziert der Algorithmus einen fallenden Kursverlauf.

Wenn die Fundamentaldaten einen steigenden Kursverlauf ($+10 \text{ €} > K_t > 0 \text{ €}$) nahelegen, bleibt es in 70% der Fälle auch nach Berücksichtigung des Zufallseinflusses ε_t dabei. Nur falls die Zufallsereignisse $\varepsilon_t = -10 \text{ €}$ (15% Wahrscheinlichkeit) oder $\varepsilon_t = -20 \text{ €}$ (10% Wahrscheinlichkeit) oder $\varepsilon_t = -30 \text{ €}$ (5% Wahrscheinlichkeit) eintreten, kommt es nicht zu einem steigenden sondern zu einem fallenden Kursverlauf. Wenn die Fundamentaldaten einen fallenden Kursverlauf ($-10 \text{ €} < K_t < 0 \text{ €}$) nahelegen, bleibt es in 70% der Fälle auch nach Berücksichtigung des Zufallseinflusses ε_t dabei. Nur falls die Zufallsereignisse $\varepsilon_t = +10 \text{ €}$ (15% Wahrscheinlichkeit) oder $\varepsilon_t = +20 \text{ €}$ (10% Wahrscheinlichkeit) oder $\varepsilon_t = +30 \text{ €}$ (5% Wahrscheinlichkeit) eintreten, kommt es nicht zu einem fallenden sondern zu einem steigenden Kursverlauf.

Der Algorithmus nutzt also die vorhandenen Informationen optimal, kommt aber keineswegs zu perfekten Prognosen. Er liegt nur in 70% aller Fälle richtig. Gerade bei Algorithmen, die erkennbar nicht perfekt funktionieren, tritt das Phänomen der Algorithm Aversion auf (vgl. bspw. Dietvorst, Simmons & Massey, 2015).

Die Probanden erhalten Einblick in 40 Perioden Kurshistorie, bevor sie ihre erste Entscheidung treffen müssen (siehe Anhang 3). In diesen 40 Perioden Kurshistorie ist der Kurs exakt 20 Mal gestiegen und 20 Mal gefallen. Bei diesem Verhältnis bleibt es auch in den folgenden 40 Perioden: 20 Mal steigt der Kurs und 20 Mal fällt der Kurs. Darüber werden die Probanden nicht ausdrücklich informiert. Aber sie können sich durch Betrachtung der Kurshistorie einen Eindruck davon verschaffen, dass es bisher ebenso oft zu einem steigenden wie zu einem fallenden Aktienkurs gekommen ist.

Die Probanden sind über den Kursbildungsmechanismus ($K_t = 32 A_t + 1 B_t - 18 C_t + 44 D_t + \varepsilon_t$) sowie über die Wahrscheinlichkeitsverteilung von ε_t informiert. Außerdem werden die Probanden ausdrücklich darauf hingewiesen, dass der Prognosecomputer (Algorithmus) in 70% aller Fälle eine zutreffende Einschätzung vornimmt. Durch Kontrollfragen wird sichergestellt, dass die Probanden diese Ausgangslage auch verstanden haben (siehe Anhang 2).

Die Probanden haben nun 40 Mal die Alternative, eine eigene Prognose abzugeben oder dem Algorithmus zu vertrauen. Für jede zutreffende Prognose (Kurs steigt oder Kurs fällt), die sie abgeben oder durch den Algorithmus abgeben lassen, erhalten die Probanden eine Vergütung in Höhe von 50 Cent. Sie erhalten keine Vergütung, wenn sie eine unzutreffende Prognose abgeben oder durch den Algorithmus abgeben lassen.

Da die Abfolge von steigenden und fallenden Kursverläufen keine Muster aufweist, die die Prognose ermöglichen würden (siehe Anhang 4), haben die Probanden die Wahl zwischen drei Strategien. Die Probanden müssen sich jedoch keineswegs auf eine dieser drei Strategien festlegen. Sie haben von Prognoserunde zu Prognoserunde die freie Auswahl, wie sie sich verhalten wollen. Nur so lassen sich mögliche Lernprozesse beobachten. Im Kern stellen sich diese drei Strategien wie folgt dar:

1. Die Probanden versuchen, den Kursverlauf intuitiv zu erraten. In diesem Fall werden sie etwa in 50% der Fälle richtig raten. Der Erwartungswert ihrer Vergütung liegt bei 10 €.
2. Die Probanden nutzen alle Informationen, die zur Verfügung stehen, und geben Prognosen ab, wie es auch der Algorithmus tun würde. Zur Unterstützung dieser Strategie stehen ihnen Taschenrechner, Stifte und Papier zur Verfügung. In diesem Fall werden sie in etwa 70% der Fälle eine zutreffende Prognose abgeben. Der Erwartungswert der Vergütung liegt bei 14 €.
3. Sie delegieren die Prognose an den Algorithmus. In diesem Fall werden sie in etwa 70% der Fälle eine zutreffende Prognose abgeben. Der Erwartungswert der Vergütung liegt dann bei 14 €.

Rational agierende, nutzenmaximierende Wirtschaftssubjekte (homo oeconomicus) müssen die dritte Strategie verfolgen. Die erste Strategie führt zu einer spürbaren Reduzierung des Erwartungswertes der Auszahlung. Die zweite Strategie führt zu keinem höheren Erwartungswert der Auszahlung als die dritte Strategie, ist aber wegen des erheblichen Rechenaufwandes (in 40 Spielrunden insgesamt 160 Multiplikationen mit 320 Faktoren und zusätzlich 40 Additionen von 160 Summanden) fehleranfällig und mühevoll. Ein homo oeconomicus wird daher zweifelsfrei die dritte Strategie wählen.

Aus früheren Untersuchungen ist allerdings bekannt, dass die Betrachtung einer Kurshistorie bei vielen Wirtschaftssubjekten eine starke Intuition auslöst, wie es mit dem Kursverlauf weitergehen könnte (vgl. bspw. Zielonka, 2004; Wärneryd, 2001; Roberts, 1959). Wir vermuten daher, dass keineswegs alle Wirtschaftssubjekte von der ersten bis zur letzten Spielrunde die dritte Strategie auswählen werden.

Hypothese 1 lautet daher: Einige Probanden werden zumindest zeitweise nicht die dritte Strategie (Delegation der Prognose an den Algorithmus) wählen.

Nullhypothese 1 lautet daher: Alle Probanden werden in allen vierzig Spielrunden die dritte Strategie (Delegation der Prognose an den Algorithmus) wählen. Wir gehen davon aus, dass Algorithm Aversion und Overconfidence artverwandte Verhaltensanomalien sind. Die Probanden werden also häufig der eigenen Intuition statt dem Algorithmus folgen (1. Strategie), weil sie ihre Prognosefähigkeiten überschätzen. Bezieht man die Forschungsergebnisse von Proeger und Meub (2014) ein, ist anzunehmen, dass die Probanden allmählich lernen werden, ihre Prognosefähigkeiten realistischer einzuschätzen. Denn nach jeder Prognoserunde werden die Probanden darüber informiert, wie sich der Kurs entwickelt hat (steigend oder fallend), wie erfolgreich sie bisher mit ihren Entscheidungen waren (aktueller Stand der Vergütung) und wie erfolgreich sie bisher gewesen wären, wenn sie die Prognoseaufgabe stets an den Algorithmus delegiert hätten (siehe Anhang 3).

Hypothese 2 lautet daher: In den letzten 5 (10/15/20) Prognoserunden werden die Probanden signifikant häufiger dem Algorithmus vertrauen als in den ersten 5 (10/15/20) Prognoserunden.

Nullhypothese 2 lautet daher: Der Algorithmus wird in den letzten 5 (10/15/20) Prognoserunden nicht signifikant häufiger gewählt als in den ersten 5 (10/15/20) Prognoserunden.

3 Ergebnisse

Das Experiment wird im Zeitraum vom 2. bis zum 14. November 2020 im Ostfalia Labor für experimentelle Wirtschaftsforschung (OLEW) der Ostfalia Hochschule für angewandte Wissenschaften in Wolfsburg durchgeführt. Insgesamt nehmen 143 Probanden an dem Experiment teil. Die Probanden sind Studierende der Ostfalia Hochschule für angewandte Wissenschaften in Wolfsburg. 65 Probanden (45,5%) studieren an der Fakultät Wirtschaft, 60 Probanden (42,0%) an der Fakultät Fahrzeugtechnik und 18 Probanden (12,6%) an der Fakultät Gesundheitswesen. 91 Probanden (63,6%) sind männlich, 50 Probanden (35,0%) sind weiblich und 2 Probanden (1,4%) ordnen sich selbst in die Geschlechtskategorie „divers“ ein. Der jüngste Proband ist 18 Jahre alt. Der älteste Proband ist 35 Jahre alt. Das durchschnittliche Alter der Probanden beträgt 23,5 Jahre.

Das Experiment ist in z-Tree implementiert (vgl. Fischbacher, 2007). Im Ostfalia Labor für experimentelle Wirtschaftsforschung (OLEW) stehen zwölf Bildschirmarbeitsplätze zur Verfügung, von denen allerdings nicht mehr als vier Plätze pro Session belegt werden. Damit wird gewährleistet, dass ein großer räumlicher Abstand zwischen den Probanden aufrechterhalten werden kann. Das ist angesichts der Covid-19-Pandemie erforderlich, um die Probanden keiner Gesundheitsgefahr auszusetzen. Die Bildschirmarbeitsplätze im Labor sind darüber hinaus mit Platzbegrenzungen ausgestattet, die eine vollkommene Separierung der Probanden erlauben. Die Experimente werden durchgängig von einem Spielleiter begleitet, so dass Kommunikation zwischen den Probanden sowie der Einsatz unerlaubter Hilfsmittel (bspw. Smartphones) ausgeschlossen werden kann. Insgesamt werden 42 Sessions durchgeführt. Eine Session dauert im Durchschnitt etwa 45 Minuten.

Kommt es in diesem Experiment zur Algorithm Aversion oder wählen alle Probanden unentwegt den Algorithmus? Ein Wirtschaftssubjekt, das vollständig informiert ist und stets rational sein Nutzenmaximum sucht (homo oeconomicus), müsste in allen 40 Prognoserunden stets dem Algorithmus vertrauen. Diese Strategie führt zum höchstmöglichen Erwartungswert der Auszahlung.

Insgesamt treffen 143 Probanden je 40 Entscheidungen. Das sind insgesamt 5.720 Entscheidungen. Davon fallen lediglich 2.624 Entscheidungen (45,9%) zugunsten des Algorithmus aus. Bei 3.096 Entscheidungen (54,1%) wird nicht dem Algorithmus vertraut. Die deutliche Mehrzahl der Entscheidungen ist also durch Vorbehalte gegenüber dem Algorithmus geprägt (Tabelle 1).

Tabelle 1: Entscheidungen für und gegen den Algorithmus


Entscheidungen			
für den Algorithmus		gegen den Algorithmus	
Anzahl	Prozent	Anzahl	Prozent
2.624	45,90	3.096	54,10

Der t-Test offenbart, dass die Nullhypothese 1 klar verworfen werden muss. Der p-Wert in Höhe von 0,000 unterstreicht die Deutlichkeit des Ergebnisses. Es bestätigt sich also die Vermutung, dass Algorithm Aversion in erheblichem Umfang zum Tragen kommt und dass die Probanden keineswegs immer rational-nutzenmaximierende Entscheidungen treffen.

Nur sehr wenige Probanden verfolgen nachhaltig die Strategie, bei der die Fundamentaldaten genutzt werden, um den Erwartungswert des nächsten Aktienkurses zu ermitteln und einen Vergleich zum letzten tatsächlichen Aktienkurs vorzunehmen. Wir können dieses Verhalten nur bei fünf Probanden (3,5%) beobachten. Ihre Entscheidungen gegen den Algorithmus müssen dennoch uneingeschränkt dem Phänomen der Algorithm Aversion zugerechnet werden. Denn für ein vollständig informiertes, rational-nutzenmaximierendes Wirtschaftssubjekt ist klar erkennbar, dass diese Strategie zu keinem höheren Erwartungswert der Auszahlung führt. Gleichzeitig muss man befürchten, dass sich angesichts der Vielzahl der erforderlichen Rechenoperationen (in 40 Spielrunden insgesamt 160 Multiplikationen mit 320 Faktoren und zusätzlich 40 Additionen von 160 Summanden) Fehler einschleichen können. Deshalb offenbart auch diese mühevollen mathematische Rekapitulation des Algorithmus einen objektiv ungerechtfertigten Vorbehalt gegenüber der Zuverlässigkeit des Algorithmus.

Von besonderem Interesse ist nun, ob es im Zeitverlauf zu einem Rückgang der Algorithm Aversion kommt. Viele Probanden beginnen das Experiment mit dem ungerechtfertigten Selbstvertrauen, die künftige Entwicklung des Aktienkurses (steigend oder fallend) besser vorhersagen zu können als der Algorithmus. Die Abfolge von steigenden und fallenden Aktienkursen entspricht jedoch einem Zufallsprozess mit einer Eintrittswahrscheinlichkeit von je 50% für einen Anstieg beziehungsweise für einen Rückgang des Aktienkurses (siehe Anhang 4). Aus dem historischen Kursverlauf lassen sich keine Informationen über die nächste Kursbewegung ableiten. Insofern führen intuitive Entscheidungen auf mittlere bis lange Sicht zu einer deutlichen Reduzierung der erwarteten Auszahlung.

Abbildung 2: Anteile der Entscheidungen zugunsten des Algorithmus in % nach Prognoserunden



Die Probanden werden nach jeder Prognoserunde über den Erfolg des Algorithmus und gegebenenfalls über den Erfolg ihrer davon abweichenden Prognose informiert. Deshalb wird für die Probanden im Laufe der Zeit immer deutlicher erkennbar, dass es eine suboptimale Strategie ist, auf die eigene Intuition und nicht auf den Algorithmus zu vertrauen. Ein Teil der Probanden gibt im Laufe der Zeit seine Vorbehalte gegenüber dem Algorithmus auf (Abbildung 2 und Tabelle 2). Fügt man eine logarithmische Regressionslinie ein (Abbildung 2), dann wird die Charakteristik einer typischen Lernkurve mit degressiven Lernfortschritten erkennbar (vgl. bspw. Anzanello & Fogliatto, 2011; Wright, 1936).

Tabelle 2: Entscheidungen für und gegen den Algorithmus nach Prognoserunden

Prognoserunde	Entscheidungen			
	für den Algorithmus		gegen den Algorithmus	
	Anzahl	Prozent	Anzahl	Prozent
1	40	27,97	103	72,03
2	41	28,67	102	71,33
3	27	18,88	116	81,12
4	34	23,78	109	76,22
5	38	26,57	105	73,43
6	51	35,66	92	64,34
7	54	37,76	89	62,24
8	57	39,86	86	60,14
9	74	51,75	69	48,25
10	64	44,76	79	55,24
11	79	55,24	64	44,76
12	70	48,95	73	51,05
13	54	37,76	89	62,24
14	69	48,25	74	51,75
15	57	39,86	86	60,14
16	72	50,35	71	49,65
17	63	44,06	80	55,94
18	69	48,25	74	51,75
19	77	53,85	66	46,15
20	72	50,35	71	49,65
21	79	55,24	64	44,76
22	78	54,55	65	45,45
23	73	51,05	70	48,95
24	66	46,15	77	53,85
25	71	49,65	72	50,35
26	67	46,85	76	53,15
27	73	51,05	70	48,95
28	75	52,45	68	47,55
29	79	55,24	64	44,76
30	76	53,15	67	46,85
31	68	47,55	75	52,45
32	68	47,55	75	52,45
33	85	59,44	58	40,56
34	67	46,85	76	53,15
35	72	50,35	71	49,65
36	63	44,06	80	55,94
37	81	56,64	62	43,36
38	76	53,15	67	46,85
39	70	48,95	73	51,05
40	75	52,45	68	47,55

Es zeigt sich, dass der prozentuale Anteil der Entscheidungen für den Algorithmus zunächst recht niedrig ist. Im Durchschnitt der ersten fünf Prognoserunden ist nur etwa ein Viertel der Entscheidungen der Probanden (25,2%) für den Algorithmus ausgefallen. Dann setzt aber ein rascher Lernprozess ein. Viele Probanden erkennen, dass ihre Intuition wenig zuverlässig ist. Im Durchschnitt der Prognoserunden 6-10 steigt der prozentuale Anteil der Entscheidungen zugunsten des Algorithmus bereits auf 42,0%. Im Durchschnitt der Prognoserunden 11-15 steigt der prozentuale Anteil der Entscheidungen zugunsten des Algorithmus weiter auf 46,0%.

Der Lernprozess und das allmähliche Abebben der Algorithm Aversion vollziehen sich vor allem in den ersten 20 Prognoserunden (Abbildung 3). In den letzten 20 Prognoserunden kommt es hingegen nicht mehr zu einem nennenswerten Rückgang der Algorithm Aversion (Abbildung 4). In den ersten 5 Prognoserunden wurde 180 Mal (25,2%) der Algorithmus gewählt, in den letzten 5 Prognoserunden 365 Mal (51,1%). In den ersten 10 Prognoserunden wurde 480 Mal (33,6%) der Algorithmus gewählt, in den letzten 10 Prognoserunden 725 Mal (50,7%). In den ersten 15 Prognoserunden wurde 809 Mal (37,7%) der Algorithmus gewählt, in den letzten 15 Prognoserunden 1.095 Mal (51,1%). In den ersten 20 Prognoserunden wurde 1.162 Mal (40,6%) der Algorithmus gewählt, in den letzten 20 Prognoserunden 1.462 Mal (51,1%).

Abbildung 3: Prozentualer Anteil der Entscheidungen für den Algorithmus in den ersten 5, 10, 15 beziehungsweise 20 Prognoserunden


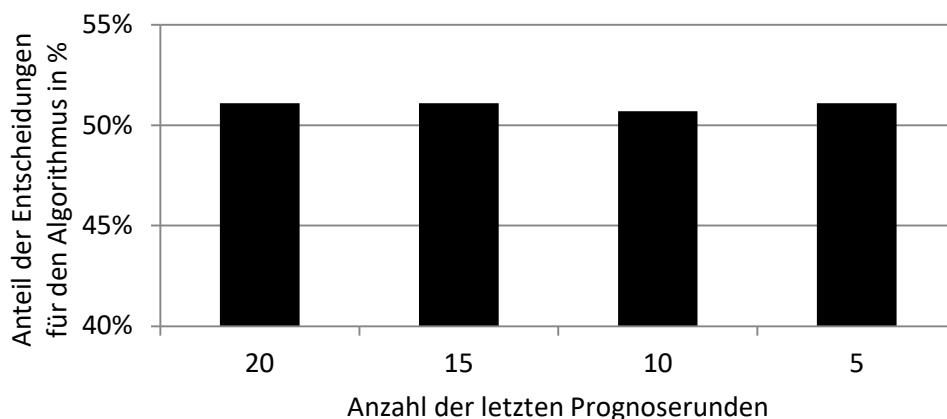


Abbildung 4: Prozentualer Anteil der Entscheidungen für den Algorithmus in den letzten 20, 15, 10 beziehungsweise 5 Prognoserunden



Die Hypothese 2 lässt sich mit Hilfe einer Regressionsanalyse überprüfen. Bei Durchführung einer linearen Regression ($y_t = \beta_1 + \beta_2 \cdot x_t + u_t$) zeigt sich sehr deutlich, dass die Algorithm Aversion im Verlauf der 40 Prognoserunden zurückgeht. Der Anteil der Entscheidungen, die zugunsten des Algorithmus ausfallen, steigt signifikant an ($t = 5,902$; $p < 0,001$). Die Nullhypothese 2 muss somit eindeutig verworfen werden. Die Algorithm Aversion wird im Zuge eines kontinuierlichen Lernprozesses deutlich abgemildert.

Ein weiteres Verfahren, die statistische Signifikanz des Lernprozesses zu überprüfen, ist der Wilcoxon-Signed-Rank-Test. Auch mit Hilfe dieses Tests lässt sich feststellen, ob die allmähliche Zunahme der Entscheidungen zugunsten des Algorithmus statistisch signifikant ist (Tabelle 4). Dabei wird betrachtet, wie viele Probanden in den letzten 5 (10/15/20) Prognoserunden häufiger (weniger häufig/unverändert häufig) dem Algorithmus folgen als in den ersten 5 (10/15/20) Prognoserunden.

Ob man die ersten 5 Prognoserunden mit den letzten 5 Prognoserunden vergleicht oder ob man die ersten 10 Prognoserunden mit den letzten 10 Prognoserunden vergleicht oder ob man die ersten 15 Prognoserunden mit den letzten 15 Prognoserunden vergleicht oder ob man die ersten 20 Prognoserunden mit den letzten 20 Prognoserunden vergleicht, hat kaum einen Einfluss auf das Ergebnis. In allen vier Fällen zeigt sich, dass im Laufe der 40 Prognoserunden ein Lernprozess einsetzt. Die Probanden lernen ihre Prognosefähigkeiten realistischer einzuschätzen. Die Algorithm Aversion geht deutlich zurück. Die Ergebnisse erweisen sich im Wilcoxon-Signed-Rank-Test als hochsignifikant (Tabelle 3). Die Nullhypothese 2 muss somit klar verworfen werden. Erfahrungen mit den Vorteilen des Algorithmus können also durchaus zu einer Reduzierung der Algorithm Aversion beitragen.

Tabelle 3: Entscheidungsverhalten in den ersten und in den letzten Prognoserunden

Anzahl (x) der betrachteten Prognoserunden (erste und letzte)	5	10	15	20
Probanden mit weniger Entscheidungen für den Algorithmus in den ersten x Prognoserunden als in den letzten x Prognoserunden	79	80	80	81
Probanden mit mehr Entscheidungen für den Algorithmus in den ersten x Prognoserunden als in den letzten x Prognoserunden	17	21	28	30
Probanden mit gleich viel Entscheidungen für den Algorithmus in den ersten x Prognoserunden wie in den letzten x Prognoserunden	47	42	35	32
Summe	143	143	143	143
p-Wert Wilcoxon-Signed-Rank-Test	0,000***	0,000***	0,000***	0,000***

*** = signifikant mit einer Irrtumswahrscheinlichkeit von 1%
 ** = signifikant mit einer Irrtumswahrscheinlichkeit von 5%
 * = signifikant mit einer Irrtumswahrscheinlichkeit von 10%.

Die Effektstärke des Lernprozesses lässt sich sowohl mit dem Korrelationskoeffizienten r nach Pearson (vgl. Fritz, Morris & Richler, 2012) als auch unter Verwendung von Cohens d beschreiben (vgl. Cohen, 1992; Cohen, 1988). Der Korrelationskoeffizient r nach Pearson betrachtet die Stärke des Zusammenhangs zweier Stichproben. Cohens d betrachtet die Erwartungswerte von zwei Verteilungen und fällt umso größer aus, je weiter diese auseinanderliegen. So lassen sich die ersten 5 (10/15/20) Prognoserunden den letzten 5 (10/15/20) Prognoserunden gegenüberstellen. Während die Korrelationskoeffizienten r nach Pearson gemäß Einteilung von Cohen (1992) starken Effekten entsprechen, zeigt Cohens d mittlere Effektstärken des Lernprozesses (Tabelle 4).

Tabelle 4: Effektstärken der Lernprozesse nach Pearsons r und Cohens d

Gegenüberstellung	Korrelationskoeffizient r nach Pearson	Cohens d
Erste 5 versus letzte 5 Prognoserunden	0,57	0,73
Erste 10 versus letzte 10 Prognoserunden	0,54	0,65
Erste 15 versus letzte 15 Prognoserunden	0,50	0,58
Erste 20 versus letzte 20 Prognoserunden	0,49	0,56

Allerdings zeigt sich auch, dass sich nur ein Teil der Probanden durch Erfahrung von der Algorithm Aversion abbringen lässt. Knapp die Hälfte der Probanden verzichtet auch noch am Ende der 40 Prognoserunden darauf, den Algorithmus einzusetzen. Im Durchschnitt der Prognoserunden 36-40 fallen noch immer knapp 49% aller Entscheidungen gegen den Algorithmus. Zu diesem Zeitpunkt dürften die Probanden erkannt haben, dass ihre intuitiven Aktienkursprognosen den Prognosen des Algorithmus weit unterlegen sind. Dennoch verweigern sie sich dem Algorithmus.

Das Phänomen Algorithm Aversion zeigt eine gewisse Wesensverwandtschaft mit dem Phänomen Overconfidence. Lerneffekte führen zu einer realistischeren Einschätzung der eigenen Fähigkeiten und somit zu einem Rückgang der Algorithm Aversion. Aber das Phänomen Algorithm Aversion beinhaltet offensichtlich weitere Aspekte, die mit einem allmählichen Erkennen der relativen Leistungsfähigkeit eines Algorithmus nicht zu beheben sind. Bei vielen Probanden bleiben auch dann Vorbehalte gegenüber dem Algorithmus bestehen, wenn sie durch eigene Erfahrung gelernt haben, dass ein Verzicht auf den Algorithmus ihren ökonomischen Interessen widerspricht.

4 Zusammenfassung

Wir untersuchen experimentell die Persistenz der Algorithm Aversion im Hinblick auf Lernprozesse. Wenn sich Wirtschaftssubjekte entscheiden müssen, ob sie eine Aufgabe von einem Algorithmus erledigen lassen oder ob sie sie selbst bewältigen wollen, kann eine etwaige Überschätzung der eigenen Fähigkeiten zu einer Ablehnung des Algorithmus führen. Overconfidence kann durch einen Lernprozess eingeeht werden. Wiederholte Aufgaben, ständige Feedbacks und ökonomische Anreize können dazu beitragen, dass die Wirtschaftssubjekte ihre eigene Befähigung allmählich besser einzuschätzen lernen. Wir wenden uns der Frage zu, ob solche Lernprozesse auch zu einer Reduzierung der Algorithm Aversion beitragen können.

In dem Experiment werden die Probanden aufgefordert, Aktienkursprognosen (der Kurs steigt oder der Kurs fällt) abzugeben. In 40 Prognoserunden können sie entweder selbst eine Einschätzung abgeben oder auf einen Prognosecomputer (Algorithmus) vertrauen. Intuitive Prognosen sind dabei in aller Regel wesentlich weniger erfolgreich als der Algorithmus. Die Auszahlung an die Probanden hängt vom Erfolg der Prognosen ab – unabhängig davon, ob die Prognosen vom Algorithmus oder von den Probanden stammen. Nach jeder Prognoserunde wird der Prognoseerfolg offengelegt. Es wird gezeigt, wie hoch bisher die Vergütung der Probanden ist und wie hoch sie wäre, wenn sie von Anfang an dem Algorithmus vertraut hätten.

Viele Probanden erkennen schon in den ersten zehn Prognoserunden, dass ihre intuitiven Prognosen dem Algorithmus deutlich unterlegen sind. Sie zeigen eine zunehmende Bereitschaft, dem Algorithmus zu vertrauen. Sowohl die Regressionsanalyse als auch der Wilcoxon-Signed-Rank-Test zeigen, dass der Lernprozess die Neigung zur Algorithm Aversion signifikant abschwächen kann. Mit Hilfe von Pearsons r und Cohens d wird gezeigt, dass der Lernprozess durchaus eine mittlere Effektstärke aufweist. Allerdings zeigt sich auch, dass sich bei einem erheblichen Teil der Probanden im Verlauf von 40 Spielrunden keine Abschwächung der Algorithm Aversion einstellt.

Danksagungen

Wir danken Gabriela Bender, Asri Özgümüs, Petrik Runst sowie den Teilnehmern des Doktorandenseminars der Professur für Wirtschaftspolitik und Mittstands-forschung an der Georg-August-Universität Göttingen für ihre Hilfe bei Rückfragen und ihre konstruktive Kritik während der Erstellung unserer Studie.

5 Literatur

- Anderson, A. (2013). Trading and Under-Diversification, *Review of Finance*, 17(5), 1699–1741.
- Anzanello, M. J. & Fogliatto, F. S. (2011). Learning curve models and applications: Literature review and research directions, *International Journal of Industrial Ergonomics*, 41(5), 573-583.
- Barber, B. M. & Odean, T. (2001). Boys Will Be Boys: Gender, Overconfidence, And Common Stock Investment, *Quarterly Journal of Economics*, 116(1), 261-292.
- Barber, B. M. & Odean, T. (2000). Trading Is Hazardous to Your Wealth: The Common Stock Investment Performance of Individual Investors, *The Journal of Finance*, 55(2), 773-806.
- Becker, O., Leitner, J. & Leopold-Wildburger, U. (2009). Expectation formation and regime switches, *Experimental Economics*, 12(3), 350-364.
- Beketov, M., Lehmann, K. & Wittke, M. (2018). Robo Advisors: quantitative methods inside the robots, *Journal of Asset Management*, 19, 363–370.
- Bhatia, A., Chandani, A. & Chhateja, J. (2020). Robo advisory and its potential in addressing the behavioral biases of investors — A qualitative study in Indian context, *Journal of Behavioral and Experimental Finance*, 25.
- Castelo, N., Bos, M. W. & Lehmann, D. R. (2019). Task-dependent algorithm aversion, *Journal of Marketing Research*, 56(5), 809-825.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed), Hillsdale, N.J., L. Erlbaum Associates.
- Cohen, J. (1992). A power primer, *Psychological bulletin*, 112(1), 155-159.
- D’Acunto, F., Prabhala, N. & Rossi, A. G. (2019). The Promises and Pitfalls of Robo-Advising, *The Review of Financial Studies*, 32(5), 1983–2020.
- 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.
- Dimmock, S. G., Kouwenberg, R., Mitchell, O. S. & Peijnenburg, K. (2016). Ambiguity Aversion and Household Portfolio Choice Puzzles: Empirical Evidence, *Journal of Financial Economics*, 119, 559-577.
- 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.

- Erlei, A., Nekdem, F., Meub, L., Anand, A. & Gadiraju, U. (2020). Impact of Algorithmic Decision Making on Human Behavior: Evidence from Ultimatum Bargaining, *Proceedings of the AAAI Conference on Human Computation and Crowdsourcing*, 8(1), 43-52.
- Filiz, I., Nahmer, T. und Spiwoks, M. (2019). Herd behavior and mood: An experimental study on the forecasting of share prices, *Journal of Behavioral and Experimental Finance*, 24, 1-10.
- Fischbacher, U. (2007). z-Tree: Zurich Toolbox for Ready-made Economic Experiments, *Experimental Economics*, 10(2), 171–178.
- Fritz, C. O., Morris, P. E. & Richler, J. J. (2012). Effect Size Estimates: Current Use, Calculations, and Interpretation, *Journal of Experimental Psychology: General*, 141(1), 2–18.
- Frydman, C. & Camerer, C. F. (2016). The Psychology and Neuroscience of Financial Decision Making, *Trends in Cognitive Sciences*, 20(9), 661-675.
- Gilovich, T., Vallone, R. & Tversky, A. (1985). The hot hand in basketball: On the misperception of random sequences, *Cognitive psychology*, 17(3), 295-314.
- Goetzmann, W. N. & Kumar, A. (2008). Equity Portfolio Diversification, *Review of Finance*, 12(3), 433-463.
- Hibbert, A. M., Lawrence, E. R. & Prakash, A. J. (2012). Can Diversification Be Learned? *The Journal of Behavioral Finance*, 13(1), 38-50.
- Jung, D., Dorner, V., Glaser, F. & Morana, S. (2018). Robo-Advisory - Digitalization and Automation of Financial Advisory, *Business & Information Systems Engineering*, 60(1), 81-86.
- Köbis, N. & Mossink, L. D. (2020). Artificial intelligence versus Maya Angelou: Experimental evidence that people cannot differentiate AI-generated from human-written poetry, *Computers in Human Behavior*, 114, 1-13.
- Ku, C. Y. (2020). When AIs Say Yes and I Say No: On the Tension between AI's Decision and Human's Decision from the Epistemological Perspectives, *Információs Társadalom*, 19(4), 61-76.
- Kudryavtsev, A., Cohen, G. & Hon-Snir, S. (2013). "Rational" or "Intuitive": Are Behavioral Biases Correlated Across Stock Market Investors? *Contemporary Economics*, 7(2), 31-53.
- Meub, L., Proeger, T., Bizer, K. & Spiwoks, M. (2015). Strategic coordination in forecasting - An experimental study, *Finance Research Letters*, 13(1), 155-162.
- Prahl, A. & Van Swol, L. (2017). Understanding algorithm aversion: When is advice from automation discounted? *Journal of Forecasting*, 36(6), 691-702.
- Proeger, T. & Meub, L. (2014). Overconfidence as a Social Bias: Experimental Evidence, in: *Economics Letters*, 122(2), 203-207.
- Roberts, H. V. (1959). Stock market "patterns" and financial analysis: Methodological suggestions, *Journal of Finance*, 1(14), 1–10.

- Rossi, A. G. & Utkus, S. P. (2020). Who Benefits from Robo-advising? Evidence from Machine Learning, SSRN Working Paper, <https://ssrn.com/abstract=3552671> or <http://dx.doi.org/10.2139/ssrn.3552671>
- Rühr, A., Streich, D., Berger, B. & Hess, T. (2019). A Classification of Decision Automation and Delegation in Digital Investment Systems, in: Proceedings of the 52nd Hawaii International Conference on System Sciences, S. 1435-1444.
- Singh, I. & Kaur, N. (2017). Wealth Management Through Robo Advisory, *International Journal of Research - Granthaalayah*, 5(6), 33-43.
- Uhl, M. W. & Rohner, P. (2018). Robo-advisors versus traditional investment advisors: An unequal game, *The Journal of Wealth Management*, 21(1), 44-50.
- Wärneryd, K.-E. (2001). Stock-market psychology, Cheltenham: Edward Elgar.
- Wright, T. P. (1936). Factors affecting the cost of airplanes, *Journal of the Aeronautical Sciences*, 3(4), 122-128.
- Zielonka, P. (2004). Technical analysis as the representation of typical cognitive biases, *International Review of Financial Analysis*, 13, 217–225.

6 Anhänge

6.1 Anhang 1: Spielanleitung

6.1.1 Das Spiel

In diesem Spiel werden Sie gebeten, Prognosen für die zukünftige Entwicklung eines Aktienkurses abzugeben. Sie prognostizieren in 40 Perioden den Kursverlauf einer Aktie, nämlich der Z-Aktie. Allerdings sagen Sie nicht den exakten Aktienkurs voraus, sondern nur, ob der Kurs der Aktie steigen wird oder ob er fallen wird. Der Kurs der Z-Aktie bleibt immer in Bewegung. Es kommt also nie zu einem unveränderten Kurs. Der Kurs steigt oder er fällt.

Der Aktienkurs der Z-Aktie in € zum Zeitpunkt t (K_t) ergibt sich stets aus vier fundamentalen Einflussfaktoren (A_t , B_t , C_t und D_t) und einem Zufallseinfluss (ε_t). Die fundamentalen Einflussfaktoren werden Ihnen vor jeder Prognoserunde bekannt gegeben. Ebenso ist der konkrete Einfluss der Fundamentaldaten auf den Aktienkurs bekannt.

Der Kurs (K_t) der Z-Aktie kommt wie folgt zustande:

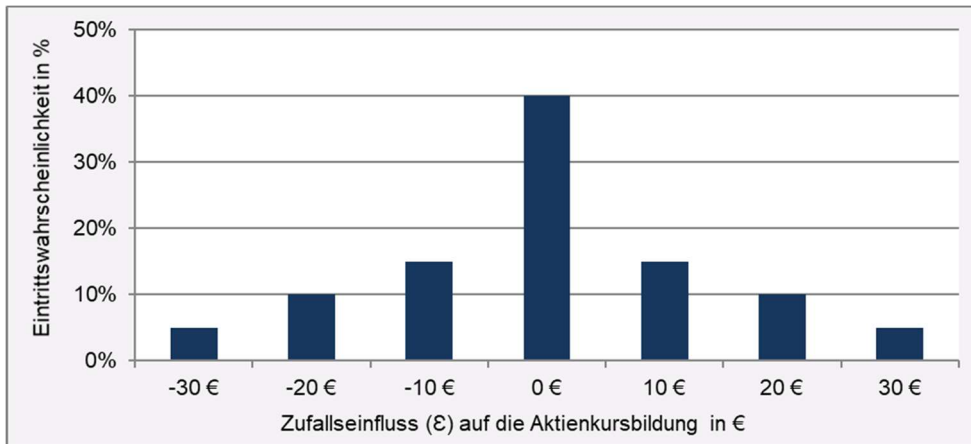
$$K_t = 32 \cdot A_t + 1 \cdot B_t - 18 \cdot C_t + 44 \cdot D_t + \varepsilon_t$$

Die fundamentalen Einflussfaktoren (A_t , B_t , C_t und D_t) würden ohne den Zufallseinfluss ε_t in jeder Periode zu einer Kursveränderung zwischen -10 und 0 € bzw. zwischen 0 und 10 € führen. Entwickeln sich die fundamentalen Einflussfaktoren alles in allem günstig, käme es ohne den Zufallseinfluss ε_t stets zu einer Kurssteigerung zwischen 0 € und 10 €. Das heißt: $0\text{€} < (K_t - \varepsilon_t) < +10\text{€}$. Entwickeln sich die fundamentalen Einflussfaktoren hingegen alles in allem ungünstig, käme es ohne den Zufallseinfluss ε_t stets zu einem Kursrückgang zwischen 0 € und 10 €. Das heißt: $0\text{€} > (K_t - \varepsilon_t) > -10\text{€}$.

Der Zufallseinfluss ε_t hat einen Erwartungswert von 0 und weist folgende Verteilung auf: Mit 40%iger Wahrscheinlichkeit ist der Zufallseinfluss ε_t gleich null ($\varepsilon_t = 0$). Mit jeweils 15%iger Wahrscheinlichkeit nimmt der Zufallseinfluss ε_t einen Wert von -10 € oder +10 € an. Mit jeweils 10%iger Wahrscheinlichkeit nimmt der Zufallseinfluss ε_t einen Wert von -20 € oder +20 € an. Und mit jeweils 5%iger Wahrscheinlichkeit nimmt der Zufallseinfluss ε_t einen Wert von -30 € oder +30 € an (Abb. 1).

Sie haben in jeder Prognoserunde die Möglichkeit, ihre eigene Einschätzung (Kurs steigt oder Kurs fällt) abzugeben oder die Entscheidung an einen Prognosecomputer zu delegieren. Der Prognosecomputer schätzt die Entwicklungsrichtung des künftigen Kurses der Z-Aktie in 70% der Fälle zutreffend ein.

Abbildung 5: Wahrscheinlichkeitsverteilung des Zufallseinflusses ϵ_t



6.1.2

Ablauf

Nach dem Lesen der Instruktionen und der Beantwortung der Kontrollfragen sehen Sie zum einen den Kursverlauf der Z-Aktie der letzten 40 Perioden und zum anderen einen detaillierten Kursverlauf der Z-Aktie der letzten 10 Perioden. Außerdem erhalten Sie die Werte für die Fundamentaldaten für die nächste Periode. Sie werden gebeten, eine Prognose für die Entwicklung des Aktienkurses in der nächsten Periode abzugeben. Nach der Abgabe der Prognose sehen Sie den tatsächlich eingetretenen Kurs der Z-Aktie in der nächsten Periode und erhalten das Ergebnis zu Ihrer Vorhersage. Insgesamt werden 40 Runden gespielt. Vor jeder Runde sehen Sie zum einen den Kursverlauf der Z-Aktie von Periode 1 bis zur aktuellen Periode und zum anderen einen detaillierten Kursverlauf der Z-Aktie der letzten 10 Perioden. Außerdem erhalten Sie jeweils die Werte für die Fundamentaldaten für die nächste Periode.

6.1.3

Auszahlung

Für jede erfolgreiche Aktienkursprognose erhalten Sie 0,50 €. Eine Prognose gilt dann als erfolgreich und wird dementsprechend vergütet, wenn die Prognose die tatsächliche Richtung der Kursveränderung korrekt voraussagt. Insgesamt können Sie bis zu 20 € verdienen. Die Auszahlung erfolgt am Ende.

6.1.4

Hinweise

- Bitte verhalten Sie sich während des Experiments ruhig!
- Bitte schauen Sie Ihren Nachbarn nicht auf den Bildschirm!
- Bis auf einen Stift und einen Taschenrechner sind **keine** Hilfsmittel (Smartphones, Smartwatches etc.) zugelassen.

6.2

Anhang 2: Kontrollfragen

Kontrollfrage 1: Welche Alternativen haben Sie bei der Prognoseabgabe?

- a) Ich kann nur eigene Prognosen abgeben.
- b) Ich kann entweder dem Algorithmus folgen oder eine eigene Prognose abgeben. *(Zutreffend!)*
- c) Ich kann entweder dem Algorithmus folgen, eine eigene Prognose abgeben oder einen Publikumsjoker wählen.

Kontrollfrage 2: Wie hoch ist die Erfolgsquote des Algorithmus?

- a) 40%
- b) 50%
- c) 70% *(Zutreffend!)*

Kontrollfrage 3: Wie hoch ist die Vergütung für eine erfolgreiche Prognose?

- a) 0,00 €
- b) 0,50 € *(Zutreffend!)*
- c) 1,00 €

Kontrollfrage 4: Wie hoch ist die Vergütung für eine unzutreffende Prognose?

- a) 0,50 €
- b) 1,00 €
- c) 0,00 € *(Zutreffend!)*

6.3 Anhang 3: Bildschirm

Unten sehen Sie die Ergebnisse für die Periode 41

Letzte Prognose des Algorithmus: Kurs fällt	Ihre letzte Prognose: Sie sind dem Algorithmus gefolgt	Letztes eingetretenes Ereignis: Kurs ist gestiegen	Wären Sie stets dem Algorithmus gefolgt, dann betrüge Ihr Gesamtverdienst bis jetzt: 0.00 Euro
---	--	--	--

Kursverlauf von Periode 1 bis zur aktuellen Periode

Periode	Kurs (€)
1	50
2	60
3	70
4	80
5	90
6	100
7	110
8	120
9	130
10	140
11	150
12	160
13	170
14	180
15	190
16	200
17	210
18	220
19	230
20	240
21	250
22	260
23	270
24	280
25	290
26	300
27	310
28	320
29	330
30	340
31	350
32	360
33	370
34	380
35	390
36	400
37	410
38	420
39	430
40	440
41	254

Kursverlauf der letzten 10 Perioden

Periode	Kurs (€)
32	180
33	179
34	203
35	211
36	218
37	227
38	232
39	241
40	246
41	254

Fundamentaltwerte für Periode 42

Fundamentaltwert A: 62
 Fundamentaltwert B: 225
 Fundamentaltwert C: 270
 Fundamentaltwert D: 66

Treffen Sie nun Ihre Auswahl für die Periode 42!
 Bitte entscheiden Sie sich nun für eine der drei Alternativen!

Ich wähle:

Ich gebe eine eigene Prognose ab: Der Kurs steigt
 Ich gebe eine eigene Prognose ab: Der Kurs fällt
 Ich folge der Prognose des Algorithmus

OK

6.4

Anhang 4: Kursverlaufsvarianten

Prognoserunde	Kursvariante A	Kursvariante B	Kursvariante C	Kursvariante D
1	267	264	254	255
2	275	273	273	284
3	284	282	277	292
4	272	280	265	289
5	299	278	252	307
6	296	316	261	302
7	294	315	256	310
8	313	333	289	299
9	311	330	287	328
10	349	356	283	326
11	357	364	252	335
12	376	381	280	304
13	364	388	288	283
14	353	377	307	321
15	351	376	306	316
16	389	410	304	305
17	398	408	281	302
18	396	406	278	300
19	405	395	285	308
20	413	414	314	337
21	381	432	323	346
22	410	421	322	335
23	428	408	330	344
24	436	417	308	332
25	425	426	336	310
26	423	434	335	308
27	422	423	334	327
28	421	421	332	325
29	430	418	339	333
30	438	427	358	341
31	446	444	323	349
32	454	431	331	325
33	463	398	310	304
34	461	392	313	312
35	450	400	322	311
36	448	408	311	320
37	427	384	308	317
38	408	392	326	314
39	387	370	324	343
40	366	355	333	349

Um eine Verzerrung durch Absprachen zwischen Probanden, die zu unterschiedlichen Zeitpunkten an dem Experiment teilnehmen, zu verhindern, wurden vier verschiedene Kursvarianten im Experiment verwendet.