Neobroker-Nutzung: Anlageverhalten unter digitalen Einflussfaktoren

Eine empirische Untersuchung von Anlagestrategien, App-Einflüssen und Risikofaktoren

Summary

Diese Studie untersucht, wie Neobroker und Trading-Apps den Kapitalmarktzugang und das Anlageverhalten privater Anleger:innen verändern. Grundlage bilden die Auswertung der aktuellen Forschung sowie eine Online-Befragung von 1.021 volljährigen Neobroker-Nutzer:innen in Deutschland. Die Ergebnisse zeigen eine ambivalente Wirkung: Für 72,0 Prozent ist der Neobroker der wichtigste Anlageweg, 53,4 Prozent machten darüber ihre erste Investmenterfahrung. ETFs und langfristige Strategien prägen die Nutzung, zugleich sind Verlusterfahrungen, bereute Entscheidungen und Investitionen ohne vollständiges Produktverständnis weit verbreitet. Während 56,6 Prozent bereits mindestens einen endgültigen Verlust realisiert haben, berichten nur 9,2 Prozent insgesamt von einer negativen Portfolioentwicklung.

Der wahrgenommene Einfluss von Kursalarmen, Push-Benachrichtigungen, In-App-Empfehlungen und vereinfachten Kaufprozessen steht statistisch mit häufigerem Trading, spontanen Entscheidungen und unvollständigem Produktverständnis in Zusammenhang. Besonders verdichten sich Risiken bei hoher Handelsfrequenz, Derivaten, Kryptowährungen und einer starken Reaktion auf digitale Impulse. Entscheidend für eine verantwortungsvolle Nutzung sind daher Finanzbildung, Produktverständnis, eine langfristige Anlagestrategie und bei Bedarf persönliche Beratung.

Inhalt

Einleitung 1

Problemstellung und Forschungsinteresse der Studie 1

Aufbau der Studie 3

Definition Neobroker 5

Eigenschaften und Geschäftsmodell von Neobrokern 5

Hohe Nutzerfreundlichkeit & niedrigschwelliger Zugang zu der Börse 5

Geringe Kosten 6

Vorteile und Kritik an Neobrokern 7

Zugang zu einem wichtigen Baustein der Geldanlage 7

Potenziale für steigendes Finanzinteresse & -bildung 7

Intransparente Kostenstrukturen & Interessenskonflikte 8

Fehlende Supportstrukturen 10

Manipulative App-Gestaltung 11

Die Auswirkung von Trading-Apps auf das Anlegerverhalten: Die aktuelle Forschungslage 14

Der Einfluss von sozialen Medien 20

Praxisteil: Umfrage zum Anlageverhalten und Erfahrungen von Neobroker-Nutzer:innen 23

Hinweise zu der statistischen Auswertung 23

Demografischer Hintergrund der Umfrageteilnehmer:innen 24

Umfrageergebnisse 27

Analyse der Umfrageergebnisse 70

Rolle von Neobrokern innerhalb der Anlagestrategie 70

Veränderte Handelsfrequenz 70

Verluste von Geld über Neobroker-Apps 71

Faktoren mit starker Verlust-Verbindung 71
Mehrkanalnutzer:innen vs. ausschließlich Neobroker-Nutzer:innen 72
Umfrageergebnisse zum Einfluss der DEPs auf Investmentverhalten 73
Kreuztabellenanalysen zum Einfluss der DEPs auf das Investmentverhalten 74
Unterschiede im Investmentverhalten unter den Altersgruppen 92
Bedeutung von Social Media und Finfluencer:innen 92
Finanzwissen und Verständnis für Risiken 93
Unterschiede bei Nutzer:innen von Derivaten und Kryptowährungen 94
Kurzfristige vs. langfristige Strategien 94
Reue über Anlageentscheidungen über einen Neobroker 95
Gewünschte Unterstützung 95
Übergreifende Schlussfolgerung der Umfrageanalyse 96
Beantwortung der Leitfragen 98
Kapitalmarktzugang und finanzielle Teilhabe 98
Verluste und Performance 99
App-Design und digitale Impulse 100
Strategien, Zielgruppen und soziale Medien 101
Implikationen für Finanzbildung, Beratung und Anlegerschutz 103
Methodische Einordnung und weiterer Forschungsbedarf 104
Fazit 106
Quellenverzeichnis 108
Abbildungsverzeichnis 112
Anhang 115

Einleitung

Der private Wertpapierhandel hat sich in den vergangenen Jahren stark verändert. Aktien, ETFs, Kryptowährungen und weitere Anlageprodukte können heute nicht mehr nur über klassische Banken, Filialberatung oder komplexe Online-Handelsplattformen gekauft werden. Neobroker und Trading-Apps ermöglichen es Privatanleger:innen, innerhalb kurzer Zeit ein Depot zu eröffnen, per Smartphone zu investieren und Wertpapiere mit wenigen Klicks zu handeln. Besonders junge und digital affine Anleger:innen erhalten dadurch einen einfachen Zugang zum Kapitalmarkt.

Diese Entwicklung besitzt ein erhebliches Potenzial. Niedrige Gebühren, intuitive Benutzeroberflächen, geringe Mindestbeträge und jederzeitiger Zugriff können dazu beitragen, dass mehr Menschen überhaupt mit dem Investieren beginnen. Während private Altersvorsorge und eigenverantwortlicher Vermögensaufbau für die finanzielle Sicherheit heute notwendig werden, kann ein niedrigschwelliger Kapitalmarktzugang ein wichtiger Bestandteil finanzieller Teilhabe sein.

Gleichzeitig wirft diese Entwicklung neue Fragen für Verbraucherschutz, Finanzbildung und langfristiges Anlageverhalten auf. Trading-Apps richten sich häufig an Selbstentscheider:innen, die ohne persönliche Beratung handeln. Damit treffen auch unerfahrene Anleger:innen eigenständig Entscheidungen über Produkte, deren Risiken sie möglicherweise nicht vollständig verstehen. App-Funktionen wie Push-Benachrichtigungen, Kursalarme, einfache Kaufprozesse, stark reduzierte Informationsdarstellungen und Social-Media-nahe Mechaniken können Anlageentscheidungen zusätzlich beschleunigen.

Die vorliegende Studie untersucht deshalb, wie Neobroker und Trading-Apps das Verhalten von Anleger:innen beeinflussen. Untersucht wird, ob digitale Anlageplattformen vor allem den Einstieg in Finanzmärkte erleichtern oder zugleich Verhalten begünstigen, das zu häufigeren Trades, höheren Risiken, impulsiven Entscheidungen und finanziellen Verlusten führen kann.

Problemstellung und Forschungsinteresse der Studie

Neobroker und Trading-Apps verändern nicht nur den Zugang zum Kapitalmarkt, sondern auch die Art, wie Privatanleger:innen Investmententscheidungen treffen. Besonders relevant ist dieser Einfluss bei unerfahrenen Anleger:innen, die wenig Börsenerfahrung besitzen, aber durch niedrige Gebühren, einfache App-Oberflächen und schnelle Kaufprozesse früh mit Aktien, ETFs, Kryptowährungen oder spekulativen Produkten in Kontakt kommen.

Die zentrale Problemstellung dieser Studie liegt deshalb in der Frage, ob Trading-Apps unerfahrene Nutzer:innen zu vorteilhaften Anlageentscheidungen befähigen oder ob sie Verhalten fördern, das mit finanziellen Verlusten, übermäßigem Trading und riskanteren Investments verbunden ist.

Die Studie untersucht konkret, wie Neobroker und Trading-Apps das Verhalten der Anleger:innen beeinflussen und in welchem Ausmaß dadurch finanzielle Verluste, häufigere Transaktionen und höhere Risikobereitschaft entstehen. Dabei geht es insbesondere um die Wirkmechanismen digitaler Anlageplattformen: Welche Rolle spielen einfache Bedienung, Gamification, Push-Benachrichtigungen, Kursalarme, Social-Media-Trends und App-Design für konkrete Anlageentscheidungen?

Im Zentrum stehen drei Leitfragen. Erstens wird untersucht, ob Anleger:innen durch Neobroker und Trading-Apps häufiger Geld verlieren. Dabei ist relevant, wie viele Nutzer:innen bereits reale Verluste erlitten haben, wie hoch diese Verluste ausfallen und welche Ursachen sie selbst dafür angeben.

Zweitens fragt die Studie, welche Rolle Gamification, Push-Benachrichtigungen und einfache Bedienung für das Anlageverhalten spielen. Trading-Apps reduzieren viele Reibungspunkte, die bei klassischen Anlagewegen bestehen. Ihre Funktionen können den Einstieg erleichtern, aber auch spontane Entscheidungen, kurzfristiges Handeln und eine höhere Handelsfrequenz begünstigen.

Drittens untersucht die Studie, welche Strategien Nutzer:innen von Trading-Apps verfolgen. Entscheidend ist dabei, ob Trading-App-Nutzer:innen häufig handeln, geeignete Produkte wählen, stärker auf Social Media oder Finfluencer:innen reagieren, ein anderes Risikoverständnis besitzen oder ihre Investments kürzer halten.

Aus diesen Leitfragen ergeben sich mehrere konkrete Forschungsfragen für den Praxisteil. Die Studie soll klären, wie viele Anleger:innen ausschließlich über Neobroker oder Trading-Apps investieren oder welche Rolle diese Plattformen innerhalb ihrer gesamten Anlagestrategie einnehmen. Erfasst werden soll außerdem, wie hoch die durchschnittlichen Gewinne oder Verluste der Nutzer:innen ausfallen und ob die Nutzung einer Trading-App mit einer höheren Tradingfrequenz verbunden ist.

Ein weiterer Schwerpunkt liegt auf dem Einfluss digitaler Impulse. Die Befragung untersucht, welche Bedeutung Push-Notifications, Kursalarme, App-Empfehlungen, Social Media, Nachrichten, Empfehlungen aus dem privaten Umfeld und eigene Analysen für Anlageentscheidungen haben. Dadurch soll sichtbar werden, ob Nutzer:innen ihre Entscheidungen überwiegend reflektiert treffen oder ob sie stark durch kurzfristige Signale und externe Aufmerksamkeit gelenkt werden.

Zudem prüft die Studie, wie gut Anleger:innen Risiken und Diversifikation verstehen. Unerfahrene Nutzer:innen können zwar technisch einfach investieren, verfügen aber nicht automatisch über ausreichendes Wissen zu Verlustwahrscheinlichkeiten, Streuung, Produktkosten, Hebelwirkung oder langfristigem Vermögensaufbau. Deshalb ist relevant, ob Anleger:innen bereits Produkte gekauft haben, die sie nicht vollständig verstanden haben, ob sie ihre ETF-Auswahl passend zu ihren Zielen und ihrer Risikobereitschaft einschätzen und welche Form von Finanzbildung oder Beratung sie sich wünschen.

Schließlich untersucht die Studie, ob Nutzer:innen sich durch Neobroker und Trading-Apps gezielt zu riskanteren Produkten oder häufigerem Handel motiviert fühlen. Hier

geht es um die subjektive Wahrnehmung der Anleger:innen: Empfinden sie die App als neutrales Werkzeug zur Ausführung eigener Entscheidungen oder als Plattform, die durch Design, Benachrichtigungen, Produktempfehlungen und einfache Kaufprozesse zusätzliche Handelsimpulse setzt?

Das Forschungsinteresse liegt damit im Spannungsfeld zwischen finanzieller Teilhabe und Anlegerschutz. Neobroker können den Einstieg in den Kapitalmarkt erleichtern und Finanzinteresse fördern. Gleichzeitig können dieselben Merkmale, die den Zugang so einfach machen, problematisch werden, wenn sie unerfahrene Anleger:innen zu häufigem, spontanem oder riskantem Handeln bewegen. Dieses Verhältnis zwischen Zugang, Verhalten, Risiko und Ergebnis soll die Studie theoretisch einordnen und im Praxisteil empirisch überprüfen.

Aufbau der Studie

Um die Wirkung von Neobrokern und Trading-Apps auf das Anlageverhalten einordnen zu können, verbindet diese Studie einen theoretischen Teil mit einer empirischen Auswertung. Der Theorieteil schafft zunächst die fachliche Grundlage: Er definiert, was unter Neobrokern und Trading-Apps verstanden wird, wie sich diese Anbieter von klassischen Banken und Online-Brokern unterscheiden und welche Geschäftsmodelle hinter dem beworben günstigen digitalen Wertpapierhandel stehen.

Darauf aufbauend untersucht der Theorieteil die Chancen und Kritikpunkte dieses Modells. Ein besonderer Schwerpunkt liegt anschließend auf der Frage, wie digitale Gestaltung das Verhalten von Anleger:innen beeinflusst.

Im nächsten Schritt wird die aktuelle Forschungslage zu Trading-Apps und Smartphone-Trading ausgewertet. Hier werden Studien betrachtet, die untersuchen, ob App-Nutzung mit höherer Tradingfrequenz, größerer Risikobereitschaft, spekulativeren Produkten, Trend-Chasing oder impulsiveren Entscheidungen verbunden ist. Diese Forschung ist für die Studie zentral, weil sie einen wissenschaftlichen Rahmen liefert, an dem die späteren Umfrageergebnisse gemessen werden können. Ergänzend betrachtet der Theorieteil den Einfluss von Social Media und Finfluencer:innen. Trading-Apps stehen nicht isoliert, sondern sind Teil eines digitalen Informationsumfelds.

Der Praxisteil baut auf diesen theoretischen Grundlagen auf und wertet eine quantitative Online-Befragung aus, die in Zusammenarbeit mit dem Markt- und Meinungsforschungsinstitut YouGov durchgeführt wurde. Zwischen dem 23. Juni und dem 5. Juli 2026 nahmen 1.021 volljährige Personen aus Deutschland teil, die nach eigenen Angaben eine Neobroker- oder Trading-App nutzen. Die Befragten wurden über das YouGov-Panel rekrutiert und hatten der Teilnahme vorab zugestimmt.

Der Fragebogen erfasste die genutzten Anlagewege und Finanzprodukte, Handelsfrequenz und Haltedauer, endgültig realisierte Verluste und deren Ursachen sowie bereute Anlageentscheidungen. Weitere Themen waren das selbst eingeschätzte Finanzwissen, das Verständnis gehandelter Produkte, Risikobereitschaft, spontane und

emotionale Entscheidungen, der Einfluss von App-Funktionen, Social Media und Finfluencer:innen sowie der Bedarf an Finanzbildung und persönlicher Beratung.

Die Ergebnisse werden zunächst deskriptiv dargestellt. Darauf folgen Gruppenvergleiche, Kreuztabellenanalysen und Regressionsmodelle, mit denen Zusammenhänge zwischen App-Einfluss, Anlageverhalten und finanziellen Ergebnissen untersucht werden.

Durch diesen Aufbau kann die Studie theoretische Erkenntnisse und praktische Erfahrungen der Nutzer:innen miteinander verbinden. So entsteht eine Grundlage, um die zentrale Frage der Studie zu beantworten: Erleichtern Neobroker und Trading-Apps vor allem den Zugang zu sinnvollem Vermögensaufbau oder verstärken sie bei unerfahrenen Anleger:innen finanzielle Verluste, übermäßiges Trading und riskantere Anlageentscheidungen?

Definition Neobroker

Neobroker sind Finanzdienstleister, die Privatpersonen Börsenhandel und verwandte Dienstleistungen mit Mobile-First-Ansatz über Trading-Apps anbieten. Sie grenzen sich von den Angeboten anderer Online-Broker ab, indem sie einen besonders niedrigschwelligen Zugang zu Online-Investitionen ermöglichen. Das erreichen sie durch einen hohen Fokus auf Benutzerfreundlichkeit, erweiterte Handelszeiten, niedrige oder keine Transaktionsgebühren sowie kostenfreie Depots.

Im Unterschied zu traditionellen Plattformen für den Online-Börsenhandel bieten sie dabei nur eine begrenzte Auswahl an Wertpapieren, aus meist ein bis zwei elektronischen Handelsplätzen wie Xetra (Deutsche Börse AG) oder gettex (Bayerische Börse AG). Typische Assetklassen, die hier gehandelt werden, sind Aktien, ETFs, Kryptowährungen und Sparpläne.

In Deutschland zugelassene Neobroker sind bei der Bundesanstalt für Finanzdienstleistungsaufsicht je nach Geschäftsmodell als Kredit- oder Wertpapierinstitut gemeldet. Nicht investierte Kundengelder können abhängig vom Anbieter und Kontomodell bei Partnerbanken oder in Geldmarktfonds verwahrt werden. Bankeinlagen unterliegen grundsätzlich bis zu 100.000 Euro je Kund:in und Bank der gesetzlichen Einlagensicherung, Geldmarktfonds dagegen nicht.

Wertpapiere im Kundendepot gehören grundsätzlich nicht zum Vermögen des Brokers und können bei einer Insolvenz auf ein anderes Institut übertragen werden. Eine Insolvenz des Brokers führt daher normalerweise nicht zum Verlust der Depotwerte. Kursverluste, Emittentenausfälle und vorübergehende Einschränkungen beim Zugriff auf das Depot bleiben jedoch möglich.

Zu den im Jahr 2026 führenden Neobrokern in Deutschland gehören Scalable Capital, Trade Republic, finanzen.net zero, Smartbroker+ und Traders Place.

Eigenschaften und Geschäftsmodell von Neobrokern

Zu den zentralen Eigenschaften von Neobrokern gehören

- hohe Nutzerfreundlichkeit,
- niedrigschwelliger Zugang zu der Börse und
- geringe Kosten.

Diese Eigenschaften resultieren aus dem modernen Geschäftsmodell der Trading-App-Anbieter:

Hohe Nutzerfreundlichkeit & niedrigschwelliger Zugang zu der Börse

Das schnelle und bequeme Trading über das Smartphone ist ein entscheidendes Verkaufsargument für das Angebot der Neobroker. Kund:innen können oft innerhalb

eines Tages mit einer Registrierung und Authentifizierungs-Methoden wie VideoIdent ein Depot eröffnen und direkt mit dem Trading beginnen. Dabei ist das Geschäftsmodell auf Selbstentscheider:innen ausgelegt, die keine Beratung für ihre Trades benötigen oder bezahlen möchten.

Dabei werben die meisten Anbieter mit Trading rund um die Uhr oder erweiterten Handelszeiten. Kombiniert mit der Smartphone-App können Nutzer:innen so jederzeit an jedem Ort flexibel Transaktionen durchführen.

Das ermöglichen sowohl der außerbörsliche Direkthandel (OTC = Over-the-Counter-Handel) als auch elektronische Börsenhandelssysteme mit Market Makern, etwa LS Exchange der Börse Hamburg und Quotrix der Börse Düsseldorf. Diese Handelsplätze bieten erweiterte Handelszeiten. Börsengebühren können entfallen; die Kosten können sich bei OTC-Anbietern stattdessen in höheren Spreads, also größeren Unterschieden zwischen An- und Verkaufskurs, zeigen.

Da nur eine kleine Auswahl an Handelsplätzen angeboten wird, gibt es weniger Handlungsschritte für Kund:innen, die so schnell und bequem traden können. Auch die Benutzeroberfläche und Inhalte der Trading-Apps tragen dazu bei, die einzelnen Schritte für einen Trade so simpel wie möglich zu gestalten. Wo möglich werden Hürden abgebaut und Anreize für Investitionen geboten. Mit Informationen zum Börsenhandel, Notifikationen und Preisalarmen, Gamification-Elementen und sozialem Austausch wird das Interesse der Kund:innen hochgehalten.

Geringe Kosten

Insbesondere junge Menschen werden zum einen durch das digitale Angebot gelockt, andererseits durch die niedrigen Kosten.[1] Investitionen können hier bereits mit wenigen Euro getätigt werden und laufende Gebühren entfallen größtenteils.

Diese günstigen Preise sind unter anderem möglich, da Neobroker auf einer geringen Kostenbasis mit reduzierten Verwaltungskosten aufbauen. Im Vergleich zu Banken, die Online-Trading anbieten, besitzen sie weniger Personal, keine Filialen und stark automatisierte Prozesse. Diese Einsparungen können sie direkt an ihre Kund:innen weitergeben.

Das sogenannte Einnahmemodell *Payment for Order Flow* (PFOF) war zudem lange ein entscheidender Faktor, der Neobroker günstiger gestaltet hat als traditionelle Online-Broker. Als Vermittler zwischen Kund:innen und Market-Maker-Systemen erhielten die Broker hier Rückvergütungen für jeden Trade. Dieses Provisionsmodell hat in den vergangenen Jahren allerdings große Kritik durch Finanzaufsichten erhalten[2], da es zu

[1] Alexander Eschment: Wie seriös ist das Angebot von Neobrokern? 01.04.2025. URL: https://www.zdfheute.de/ratgeber/neobroker-aktien-trading-app-geld-anlegen-anfaenger-100.html. [31.07.2026]

[2] Europäische Wertpapier- und Marktaufsichtsbehörde: Article 39a – Prohibition of receiving payment for order flow. URL: https://www.esma.europa.eu/publications-and-data/interactive-single-rulebook/mifir/article-39a-prohibition-receiving-payment. [31.07.2026]

einem Interessenkonflikt führt, und wurde inzwischen durch das Europäische Parlament und den Rat der Europäischen Union nach Artikel 39a MiFIR EU-weit verboten.

Mit dem Ende der deutschen Übergangsfrist für Payment for Order Flow am 30. Juni 2026 entfiel so eine wichtige Einnahmequelle der Neobroker. Die Anbieter setzen deshalb jetzt stärker auf eigene oder eng angebundene Handelsinfrastrukturen, offen ausgewiesene Ordergebühren und kostenpflichtige Zusatzmodelle. Ein allgemeiner Anstieg der Depot- und Sparplankosten ist bislang jedoch ausgeblieben.

Das günstige Grundprinzip bleibt damit bestehen: Depotführung und Sparpläne sind häufig weiterhin kostenlos, während für Einzelorders, die gezielte Wahl bestimmter Handelsplätze oder Premium-Modelle Gebühren anfallen. Hinzu kommen mögliche Spreads, Produkt- und Fremdkosten. Besonders über Sparpläne und die bevorzugten Handelsplätze der Anbieter ist kostengünstiges Investieren weiterhin möglich.

Vorteile und Kritik an Neobrokern

Finanzexpert:innen sehen in Neobrokern sowohl Vorteile als auch Risiken für Privatanleger:innen:

Zugang zu einem wichtigen Baustein der Geldanlage

Durch die niedrigen Gebühren werden die Trading-Apps mitunter als „Demokratisierung der Geldanlage“[3] bezeichnet. Hürden zu Investments werden abgebaut und sie werden als wichtiger Bestandteil der Finanzvorsorge besser zugänglich. Da bereits mit geringem Budget Investitionen wie Sparpläne gestartet werden können, erlauben die Broker auch ohne hohes Einkommen den Aufbau finanzieller Absicherungen. So wird insgesamt gelobt, dass die Trading-Apps vor allem junge Menschen an Investitionen und den Börsenhandel heranführen.[4,5]

Potenziale für steigendes Finanzinteresse & -bildung

Einige Forschende der Universitäten Trier und München haben in einer Untersuchung der langfristigen Auswirkung der Neobroker-Nutzung ermittelt, dass das Finanzwissen der Nutzer:innen parallel zu der Nutzungszeit von Trading-Apps ansteigt.[6] Die Neobroker haben also das Potenzial, Finanzwissen zu vermitteln.

---

[3] Steffen Preißler: Zocken an der Börse: Wenn der Aktienkauf fast nichts kostet. 01.02.2021. URL: https://www.abendblatt.de/wirtschaft/article231449407/Zocken-an-der-Boerse-Wenn-der-Aktienkauf-fast-nichts-kostet.html. [31.07.2026]

[4] Alexander Eschment: Wie seriös ist das Angebot von Neobrokern?

[5] Jonas Freibauer, Silja Grawert: Prolonged Neobroker usage: Analyzing investment behavior and its impact on trading specific financial products, in: Global Finance Journal, Volume 69, 2026, URL: https://www.researchgate.net/publication/397916270_Prolonged_Neobroker_usage_Analyzing_investment_behavior_and_its_impact_on_trading_specific_financial_products, S. 14. [31.07.2026]

[6] ebd.

Zeitgleich betont die Studie aber auch, dass insgesamt ein geringes Finanzwissen bei den Nutzer:innen von Trading-Apps ermittelt wurde.[7] Die niedrige Einstiegsschwelle zum Börsenmarkt kann daher auch ein Risiko darstellen, da sie Menschen ohne Hintergrundwissen erlaubt, eigenständig potenziell weitreichende Finanzentscheidungen zu treffen.

Intransparente Kostenstrukturen & Interessenskonflikte

Weit verbreitet ist die Sorge, dass Neobroker ein potenziell ausbeuterisches Geschäftsmodell verfolgen. Diese Kritik stützt sich vor allem auf zwei Aspekte: schwer erkennbare Kosten und die Gefahr, dass Nutzer:innen durch die Gestaltung der Apps zu häufigem oder riskantem Trading angeregt werden.

Aufgrund wegfallender Depotführungsgebühren und sehr niedriger Orderkosten werden Trading-Apps häufig als kostenfrei wahrgenommen. Tatsächlich können neben einer offen ausgewiesenen Abwicklungs- oder Ordergebühr weitere Kosten entstehen. Dazu gehören insbesondere Geld-Brief-Spannen, Produktkosten, Fremdkosten und bei bestimmten Anlageklassen zusätzliche Aufschläge. Diese Kosten sind teilweise bereits im Ausführungskurs oder im Preis des Finanzprodukts enthalten und werden daher weniger unmittelbar als eine Gebühr wahrgenommen als eine klassische Orderprovision.

Ein wesentlicher Interessenkonflikt bestand lange durch das Einnahmemodell Payment for Order Flow, kurz PFOF. Dabei erhielten Broker von Market Makern oder Handelsplätzen eine Vergütung dafür, dass sie Kundenaufträge an diese weiterleiteten. Für den Broker entstand dadurch ein finanzieller Anreiz, den Auftrag nicht zwingend über den für die Kund:innen günstigsten, sondern über den für sich lukrativsten Ausführungsweg abzuwickeln.

Die ESMA hat sich deshalb für ein Verbot des PFOF-Einnahmemodells ausgesprochen[8], dieses wurde später durch den europäischen Gesetzgeber umgesetzt und wird in Artikel 39a der europäischen Finanzmarktverordnung MiFIR geregelt.

Wertpapierfirmen dürfen seit dem 01.07.2026 keine Gebühren, Provisionen oder sonstigen Vorteile von Dritten dafür annehmen, dass sie Kundenaufträge an einen bestimmten Ausführungsplatz weiterleiten oder dort ausführen. Das Verbot gilt auch bei außerbörslichen Geschäften und dann, wenn die Kund:innen selbst einen bestimmten Ausführungsplatz auswählen.[9] Zulässig sind lediglich öffentlich ausgewiesene Rabatte eines Handelsplatzes, sofern sie vollständig den Kund:innen zugutekommen und keinen finanziellen Vorteil für den Broker erzeugen.

---

[7] Freibauer, Grawert: Prolonged Neobroker usage, S. 13.
[8] Faz.net: EU-Finanzaufsicht nimmt Neobroker unter die Lupe, 14.07.2021. URL: https://www.faz.net/aktuell/finanzen/eu-finanzaufsicht-nimmt-neobroker-unter-die-lupe-17436925.html. [31.07.2026]
[9] Europäische Wertpapier- und Marktaufsichtsbehörde: Article 39a – Prohibition of receiving payment for order flow. URL: https://www.esma.europa.eu/publications-and-data/interactive-single-rulebook/mifir/article-39a-prohibition-receiving-payment. [31.07.2026]

Die großen deutschen Neobroker haben ihre Ausführungsmodelle daraufhin angepasst, ohne das Niedrigpreismodell grundsätzlich aufzugeben. Trade Republic bietet bei Aktien und ETFs eine sogenannte Bestpreis-Ausführung an. Ein Algorithmus vergleicht die handelbaren Kurse relevanter Börsen. Der Auftrag wird anschließend gegen Trade Republic ausgeführt und aggregiert an Referenzbörsen weitergeleitet. Für diese Ausführung fällt eine Abwicklungskostenpauschale von einem Euro an. Alternativ können Kund:innen über eine Direktpreis-Order selbst einen von mehreren internationalen Handelsplätzen auswählen. Dafür berechnet Trade Republic zwei Euro. Spreads, Produktkosten und Kosten Dritter können zusätzlich anfallen.[10]

Scalable Capital setzt unter anderem auf die European Investor Exchange, die gemeinsam mit der Börse Hannover betrieben wird. Die Börse Hannover verantwortet den öffentlich-rechtlichen Börsenbetrieb und die Handelsüberwachung, während Scalable Capital die technische Infrastruktur und Liquidität bereitstellt. Daneben können Kund:innen auch über gettex und Xetra handeln. Je nach Preismodell und Ordervolumen fallen unterschiedliche Ordergebühren an; Sparpläne können ohne Ausführungsgebühr eingerichtet werden. Produktkosten, Spreads, Kryptogebühren und weitere Zuwendungen können zusätzlich entstehen.[11]

Kritiker:innen melden bereits, dass mit diesen Modellen der Interessenkonflikt nicht gelöst, sondern nur verändert wird.[12] Die direkte Rückvergütung eines externen Market Makers für den weitergeleiteten Kundenauftrag ist verboten. Wirtschaftliche Zielkonflikte können jedoch entstehen, wenn ein Neobroker selbst als Gegenpartei auftritt, Liquidität bereitstellt oder an der Infrastruktur des bevorzugten Handelsplatzes beteiligt ist. Der Anbieter kann dann ein eigenes wirtschaftliches Interesse daran besitzen, dass Kund:innen sein Ausführungsmodell oder den mit ihm verbundenen Handelsplatz nutzen.

Auch bei der Verwahrung nicht investierter Kundengelder bestehen Transparenzrisiken. Anbieter wie Trade Republic und Scalable Capital können Guthaben abhängig vom jeweiligen Kontomodell auf Bankkonten und Geldmarktfonds verteilen. Für Bankguthaben gilt grundsätzlich die gesetzliche Einlagensicherung von bis zu 100.000 Euro je Kund:in und Kreditinstitut. Geldmarktfonds unterliegen dagegen nicht der gesetzlichen Einlagensicherung.

Fondsvermögen wird getrennt vom Vermögen des Brokers verwahrt. Bei einer Insolvenz des Neobrokers bleiben die Fondsanteile daher grundsätzlich den Kund:innen zugeordnet. Verlustrisiken können durch Wertschwankungen, Ausfälle von im Fonds enthaltenen Wertpapieren oder Liquiditätsprobleme entstehen. Geldmarktfonds besitzen damit ein anderes Risiko- und Sicherungsprofil als klassische Bankeinlagen.

---

[10] Trade Republic: Best Price, Informationen zur Bestpreis- und Direktpreis-Ausführung. URL: https://support.traderepublic.com/en-de/3372dc64-59cb-4521-a424-1ee812f264a4. [31.07.2026]
[11] Scalable Capital: Scalable Capital expands derivatives offering and introduces best execution on public exchanges, 08.07.2026. URL: https://de.scalable.capital/en/newsroom/derivatives. [31.07.2026]
[12] Andreas Greiner: Das Ende von PFOF 2026: Wie Neobroker das Verbot umgehen und was Anleger jetzt wissen sollten, 07.04.2026. URL: https://www.broker-test.at/news/das-ende-von-pfof-2026-wie-neobroker-das-verbot-umgehen-und-was-anleger-jetzt-wissen-muessen/. [31.07.2026]

Die Aufteilung zwischen einlagengesicherten Bankguthaben und Geldmarktfonds ist für Kund:innen nicht immer unmittelbar erkennbar. Geldmarktfonds unterliegen Wertschwankungs-, Ausfall- und Liquiditätsrisiken und können so zu Verlusten führen.[13]

Bei Trade Republic können Zinsen beziehungsweise Erträge aus Guthaben bei Partnerbanken und aus Geldmarktfonds stammen. Die Verbraucherzentrale Baden-Württemberg kritisierte unter anderem die Darstellung der Verzinsung und die Aussage, Kundenguthaben würden auf Partnerbanken verteilt und dort jeweils durch die Einlagensicherung geschützt, obwohl Teile des Geldes in nicht einlagengesicherten Liquiditätsfonds liegen konnten. Zwei entsprechende Verfahren wurden am 6. Juli 2026 durch Vergleiche beendet.[14]

Bei Scalable Capital unterscheidet sich die Verwahrung nach dem gewählten Preismodell. Im kostenlosen FREE-Modell kann Guthaben bei Scalable Capital, Partnerbanken und qualifizierten Geldmarktfonds liegen. Im kostenpflichtigen PRIME+-Modell wird es nach Angaben des Anbieters auf Scalable Capital und Partnerbanken verteilt.[15]

Die zentrale Verbraucherschutzfrage besteht deshalb darin, ob Kund:innen vor der Kontoeröffnung und während der Nutzung eindeutig erkennen können, wo ihr Guthaben verwahrt wird, welche Kosten bei einem Trade tatsächlich entstehen und welches Sicherungssystem greift. Niedrige Ordergebühren, eigene Handelsinfrastrukturen und die Einbindung von Geldmarktfonds machen Neobroker nicht grundsätzlich unseriös. Sie erhöhen jedoch die Anforderungen an Kostentransparenz, Best Execution und die verständliche Darstellung von Interessenkonflikten.

Fehlende Supportstrukturen

Verwandt mit diesen unübersichtlichen Kostenfaktoren stehen auch die oft fehlenden Supportstrukturen in Kritik. Um die niedrigen Gebühren durch reduzierte Verwaltungsausgaben zu ermöglichen, setzen viele der Anbieter auf FAQ-Übersichten, KI-Chatbots und E-Mail-Kontakt, statt auf Direktkontakt über das Telefon. In Berichten des Verbraucherschutzes zu Neobrokern sind lange Reaktionszeiten oder eingeschränkte Kontakt-Optionen ein oft genanntes Problem.[16]

---

[13] Philipp Frohn: Verbraucherschützer kritisieren neue Tagesgeld-Offerte von Scalable, 20.03.2026. URL: https://www.wiwo.de/finanzen/geldanlage/scalable-capital-verbraucherschuetzer-kritisieren-neue-tagesgeld-offerte/100209533.html. [31.07.2026]

[14] Verbraucherzentrale: Klage gegen Trade Republic, Verfahren II, Stand 06.07.2026. URL: https://www.verbraucherzentrale.de/verbandsklagen/klage-gegen-trade-republic-verfahren-ii-104013. Ergänzend: Klage gegen Trade Republic, Verfahren I. URL: https://www.verbraucherzentrale.de/verbandsklagen/klage-gegen-trade-republic-verfahren-i-101735. [31.07.2026]

[15] Scalable Capital: Scalable Preismodelle und Guthabenverteilung. URL: https://de.scalable.capital/trading-gebuehren. [31.07.2026]

[16] Verbraucherzentrale: Neobroker: Kosten und Risiken des schnellen Wertpapier-Handels per App, 03.03.2026. URL: https://www.verbraucherzentrale.de/wissen/geld-versicherungen/sparen-und-anlegen/neobroker-kosten-und-risiken-des-schnellen-wertpapierhandels-per-app-62408. [31.07.2026]

Manipulative App-Gestaltung

Neben der Intransparenz bei Kostenstrukturen und Support werden vor allem die zum Trading verlockenden Funktionen der Trading-Apps kritisiert. Sie besitzen in der Verhaltensökonomie als *Digital Engagement Practices* (DEPs) bezeichnete Gestaltungselemente, also Praktiken, die auf digitalen Kanälen zu einer stärkeren Beteiligung führen sollen. Die Anwendung dieser Methoden nennt sich Digital Nudging, das digitale „Anstupsen".

Zu diesen Strategien gehören bei Trading-Apps zum Beispiel:

- Push-Notifikationen und Preisalarme
- Top-Traded-Listen von Assets
- Leaderboards & andere Peer-Informationen
- Achievement-Badges & Punktesysteme

Diese DEPs sind ein weit verbreiteter Bestandteil der Funktionen und visueller Gestaltung von Trading-Plattformen. Ein Problem werden sie, wenn sie von Usability und legitimer Werbeansprache zu täuschenden Mustern werden, den sogenannten „Dark Patterns".

Der Begriff wurde 2010 von dem Webdesigner und Usability-Experten Harry Brignull entwickelt.[17] Er beschreibt Dark Patterns als ein Benutzerschnittstellen-Design, das darauf abzielt, Nutzer:innen zu Handlungen entgegen ihren Interessen zu verleiten – etwa eine zum Klicken verleitende, auffällige Gestaltung des „Alle annehmen" Buttons bei Cookie-Bannern, während die Optionen „Ablehnen" oder „Anpassungen" gestalterisch in den Hintergrund geraten.

Der 2022 verabschiedete DSA verbietet seit Februar 2024 viele solcher Taktiken auf Online-Plattformen. Dennoch sind diese Designmuster noch immer weit verbreitet, da sie oft an der Schwelle zwischen zulässiger, werblicher Gestaltung und Täuschung oder Nötigung liegen.[18]

Das hohe Risiko der Manipulation über das App-Design macht Digital Nudging mit DEPs zu einem grundlegenden Baustein in der Diskussion über Gefahren bei der Nutzung von Neobroker-Trading-Apps. Damit hat das Thema das Augenmerk internationaler Finanzaufsichtsbehörden wie der ESMA[19] und der *Internationalen Organisation der*

---

[17] Harry Brignull: Dark Patterns: dirty tricks designers use to make people do stuff, 08.07.2010. Archiviert durch web.archive.org. URL: https://web.archive.org/web/20250620081436/https:/90percentofeverything.com/2010/07/08/dark-patterns-dirty-tricks-designers-use-to-make-people-do-stuff/. [31.07.2026]

[18] Jürgen Kühling, Cornelius Sauerborn: Rechtsgutachten über die rechtlichen Rahmenbedingungen sogenannter „Dark Patterns", 14.02.2022. URL: https://bevh.org/fileadmin/content/04_politik/Europa/Kuehling-Gutachten-BEVH-Dark-pattern-22-02-16-final.pdf, S. 14. [31.07.2026]

[19] ESMA Discussion Paper: On MiFID II investor protection topics linked to digitalisation, 14.12.2023. URL: https://www.esma.europa.eu/sites/default/files/2023-12/ESMA35-43-

Wertpapieraufsichtsbehörden (IOSCO)[20] gewonnen, die den Umgang mit DEPs zum Verbraucherschutz einschränken möchten.

Laut IOSCO gehören die folgenden Muster zu Dark Patterns bei Trading-Apps:[21,22]

- **Prompts, Reminder & Push-Notifications**
  Visuelle oder akustische Reize sowie Push-Nachrichten („Jetzt kaufen", „Markt bewegt sich stark"), die gezielt zu schnellen Entscheidungen oder erneutem Trading animieren und vergangene Aktivitäten reaktivieren.
- **Social Proof, Rankings & Trends**
  Anzeigen wie „beliebteste Aktien", „Top-Trades" oder „X Nutzer:innen kaufen gerade", die das Verhalten anderer als Orientierung nutzen und bestimmte Assets durch Herdentrieb-Verstärkung künstlich hervorheben.
- **Sensorische Hervorhebung & Interface-Manipulation**
  Farbgestaltung, Animationen oder Platzierungen, die Gewinne, steigende Kurse oder Kaufoptionen betonen, während Risiken, Verluste oder Alternativen visuell in den Hintergrund rücken.
- **Knappheits- und Dringlichkeitsmechaniken**
  Hinweise auf zeitlich begrenzte Chancen („nur noch kurz verfügbar", „Trend läuft gerade"), die Entscheidungsdruck erzeugen und rationale Abwägung reduzieren.
- **Verdeckte oder verzerrte Informationsdarstellung**
  Wichtige Informationen wie Gebühren, Spreads oder Risiken werden unklar, verspätet oder in komplexer Sprache dargestellt, wodurch die tatsächlichen Kosten schwer einschätzbar sind.
- **Preisangaben in abweichenden Währungen (Intermediate Currencies)**
  Darstellung von Werten in ungewohnten Einheiten (z. B. Prozent, Punkte, Hebelwirkung) oder durch komplexe Fachbegriffe, die das Verständnis von Risiko und Kosten erschweren.
- **Implizite Empfehlungen & Lenkung zu bestimmten Produkten**
  Features wie „Top Picks", „Trending" oder hervorgehobene Produkte, die wie Empfehlungen wirken und häufig risikoreichere oder margenträchtigere Assets priorisieren.
- **Vereinfachung kritischer Entscheidungen (Removal of Friction)**
  One-Click-Trading oder reduzierte Bestätigungsschritte, die impulsive Käufe erleichtern und die Reflexion vor riskanten Transaktionen minimieren.
- **Manipulative Voreinstellungen (Defaults)**
  Vorausgewählte Optionen wie Market Orders, hohe Hebel oder bestimmte

3682_Discussion_Paper_on_MiFID_II_investor_protection_topics_linked_to_digitalisation.pdf. [31.07.2026]

[20] IOSCO: Digital Engagement Practices (DEPs): Final Report, Mai 2025. URL: https://www.iosco.org/library/pubdocs/pdf/IOSCOPD794.pdf. [31.07.2026]

[21] ebd., S. 56f.

[22] ebd., S. 65f.

Produkte, die ohne aktive Änderung übernommen werden und das Risiko erhöhen können.

- **Gamification & Trading-Anreize**
  Belohnungssysteme, Fortschrittsanzeigen oder visuelles Feedback, die Trading als spielerische Aktivität darstellen und zu häufigeren Transaktionen motivieren.
- **Unzureichende Eignungsprüfung & Risikoanpassung**
  Zugang zu komplexen Produkten ohne angemessene Prüfung von Wissen, Erfahrung oder Risikoprofil der Nutzer:innen.
- **Fehlende Transparenz über Algorithmen & Personalisierung**
  Nutzer:innen können nicht nachvollziehen, warum bestimmte Inhalte, Produkte oder Trends angezeigt werden oder nach welchen Kriterien Empfehlungen erfolgen.
- **Interessenkonflikte im Plattformdesign**
  Gestaltung der App begünstigt Geschäftsmodelle wie hohe Handelsfrequenz oder margenträchtige Produkte, ohne diese Zielkonflikte offenzulegen.
- **Prozesshemmnisse bei sicherheitsrelevanten Handlungen (Sludges)**
  Erschwerte Abläufe bei Auszahlungen, Kontoschließung oder Risikoanpassungen, während Käufe und Trades besonders einfach gestaltet sind.

Anhand dieser Liste wird deutlich, wie subtil Neobroker mitunter vorgehen können, um ihren Gewinn zu steigern, ohne dabei die Interessen ihrer Kund:innen zu unterstützen.

Mit einer Kombination aus Anlegerschutz, Transparenz und kontinuierlicher Kontrolle hat die IOSCO darauf basierend „Best Practices“[23] zum Umgang mit DEPs auf Trading-Plattformen entwickelt. Sie sollen die Risiken verhaltenssteuernder Designmechanismen im digitalen Trading-Umfeld begrenzen.

Als Leitlinien sind diese Vorgaben aber reine Vorschläge ohne Prüfungen oder Konsequenzen, die zudem stark darauf aufbauen, dass sich die Neobroker eigenständig zu den Best Practices verpflichten. Daher liegt es vor allem in der Verantwortung der Nutzer:innen selbst, Trading-Apps von Neobrokern verantwortungsbewusst zu nutzen und sich der Manipulationsstrategien der Anbieter bewusst zu sein. Gerade bei diesen oft unterbewusst wirkenden Mechanismen ist dies aber eine große Herausforderung, insbesondere für junge und unerfahrene Anleger:innen.

[23] IOSCO: Digital Engagement Practices (DEPs): Final Report, S. 65f.

Die Auswirkung von Trading-Apps auf das Anlegerverhalten: Die aktuelle Forschungslage

Mehrere internationale Studien untersuchen bereits, wie sich Trading-Apps auf das Anlageverhalten ihrer Nutzer:innen auswirken. Im deutschen Raum nennenswert sind hier insbesondere die einzelnen und gemeinsamen Arbeiten der Finanz-Professor:innen Silja Grawert (Hochschule München) und Marc Oliver Rieger (Universität Trier) mit Finanz-Forscher Jonas Freibauer (Universität Trier).

Ihre Veröffentlichungen "The Role of Trading Apps in Shaping Investment Behavior"[24], "The Effects of Trading Apps on Investment Behavior Over Time"[25], "Prolonged Neobroker Usage: Analyzing Investment Behavior and its Impact on Trading Specific Financial Products"[26] und "Effects of Trading Apps on Investment Behavior"[27] beschäftigen sich im Detail mit den positiven und negativen Effekten niedrigschwelliger Investment-Angebote in App-Form.

Hier befragten sie unter anderem 503 Neobroker-Nutzer:innen in Deutschland in Hinsicht auf Demografie und Anlage-Charakteristika[28,29] und begleiteten Teilgruppen an Anleger:innen über einen Zeitraum von 14 Monaten, um die langfristigen Auswirkungen der Neobroker-Nutzung zu ermitteln.[30] Auch die Dissertation von Jonas Freibauer analysiert das Verhalten und Charakteristika von Trading-App-Nutzer:innen über einen längeren Zeitraum hinweg.[31]

Die Ergebnisse der Untersuchungen zeigen über die Studien hinweg wiederkehrende Muster:

- **Niedrige Eintrittsbarrieren und steigende Kapitalmarktteilnahme**

  Trading-Apps senken die Eintrittsbarrieren zum Kapitalmarkt deutlich. Niedrige Kosten, mobile Verfügbarkeit und einfache Bedienbarkeit führen dazu, dass insbesondere junge und zuvor inaktive Anleger:innen erstmals investieren. Ein

[24] Jonas Freibauer, Marc Oliver Rieger, Silja Grawert: The Role of Trading Apps in Shaping Investment Behavior, in: Swiss Journal of Business Vol. 79, no. 2, Juni 2025, S. 147–176. URL: https://www.researchgate.net/publication/392557711_The_Role_of_Trading_Apps_in_Shaping_Investment_Behavior. [31.07.2026]
[25] Jonas Freibauer, Marc Oliver Rieger, Silja Grawert: The effects of trading apps on investment behavior over time, in: European Journal of Finance, 12.09.2024, S. 1–25, URL: https://www.researchgate.net/publication/383986187_The_effects_of_trading_apps_on_investment_behavior_over_time. [31.07.2026]
[26] Freibauer, Grawert: Prolonged Neobroker usage.
[27] Jonas Freibauer: Effects of Trading Apps on Investment Behavior, Dissertation Uni Trier, 06.12.2024. URL: https://ubt.opus.hbz-nrw.de/frontdoor/deliver/index/docId/2418/file/PhD_thesis_Freibauer.pdf. [31.07.2026]
[28] Freibauer, Rieger, Grawert: The Role of Trading Apps in Shaping Investment Behavior.
[29] Freibauer, Rieger, Grawert: The effects of trading apps on investment behavior over time.
[30] Freibauer, Grawert: Prolonged Neobroker usage.
[31] Freibauer: Effects of Trading Apps on Investment Behavior.

erheblicher Anteil der Nutzer:innen weist dabei geringe Vorerfahrung auf und betritt den Kapitalmarkt über Neobroker überhaupt zum ersten Mal.

- **Erhöhte und steigende Risikobereitschaft der Nutzer:innen**

  Alle Studien zeigen eine systematisch erhöhte Risikobereitschaft von Neobroker-Nutzer:innen im Vergleich zu klassischen Investor:innen. Diese Risikotoleranz steigt zudem mit der Dauer der App-Nutzung weiter an, was auf einen kausalen Einfluss der Plattformnutzung auf das Risikoverhalten hindeutet.

- **Persistente Defizite in der finanziellen Bildung**

  Zwar verbessert sich das Finanzwissen im Zeitverlauf der App-Nutzung leicht, das allgemeine Niveau bleibt jedoch niedrig. Insbesondere grundlegende Funktionsweisen der Finanzmärkte sowie Geschäftsmodelle der Anbieter werden häufig nicht vollständig verstanden.

- **Verhaltenssteuerung durch App-Design und Informationsumfeld**

  Trading-Apps beeinflussen das konkrete Anlageverhalten messbar. Nutzer:innen handeln häufiger als klassische Investor:innen, greifen verstärkt auf spekulative Anlageklassen wie Derivate, Kryptowährungen oder spezialisierte ETFs zurück und orientieren sich stärker an externen Informationsquellen wie Social Media oder Finanzplattformen. Gleichzeitig zeigen sich Einflüsse von App-Design-Elementen wie Gamification oder Push-Benachrichtigungen, die impulsive Entscheidungen begünstigen und zu kurzfristigerem Handeln führen.

- **Renditeeffekte ohne Risikoadjustierung**

  Im Hinblick auf die Performance erzielen Neobroker-Nutzer:innen im Durchschnitt höhere Renditen als klassische Investor:innen. Diese sind jedoch nicht risikoadjustiert und stehen in engem Zusammenhang mit höherer Handelsfrequenz sowie der Nutzung riskanter Finanzprodukte. Eine objektive Überlegenheit gegenüber klassischen Anlagestrategien lässt sich daraus nicht ableiten.

- **Stabilisierung des Nutzungsverhaltens im Zeitverlauf**

  Alle Studien zeigen, dass sich das Verhalten der Nutzer:innen über die Zeit stabilisiert: Während die Handelsfrequenz initial erhöht ist, steigt sie langfristig nicht weiter signifikant an. Gleichzeitig nimmt das investierte Kapital zu, und Nutzer:innen bleiben aktiv am Markt beteiligt.

Insgesamt ergibt sich ein ambivalentes Bild: Trading-Apps fördern einerseits die finanzielle Inklusion und erhöhen die Kapitalmarktteilnahme, führen andererseits jedoch zu einer stärkeren Ausprägung von risikoorientiertem und teilweise spekulativem Anlageverhalten.

Damit lässt sich ein klares Wirkmodell ableiten:

Input:

- Niedrige Einstiegshürden
- Aktivierendes App-Design (Gamification, UX)

↓

Verhalten:

- Mehr Teilnahme
- Höheres Risiko
- Mehr spekulative Produkte
- Teilweise impulsives Trading

↓

Outcomes:

- Durch höheres Risiko höhere Renditen möglich
- Gleichzeitig:
    - ineffizientes Verhalten
    - potenziell schlechtere langfristige Ergebnisse

Alle vier Arbeiten der deutschen Forscher:innen zeigen also zusammengefasst ein konsistentes Bild: Trading-Apps erhöhen die Kapitalmarktteilnahme deutlich, verändern jedoch systematisch das Verhalten der Nutzer:innen hin zu mehr Risiko, spekulativen Investments und teilweise irrationalen Entscheidungen – bei gleichzeitig weiterhin geringer finanzieller Kompetenz.

Forscher:innen des National Bureau of Economic Research in Cambridge, USA, betrachteten Daten zweier deutscher Banken mit eigenen Trading-Apps, um Schlüsse zu dem Einfluss von Smartphones auf das Investmentverhalten zu ziehen.[32] Diese Informationen zu dem Trading-Verhalten von 15.000 Kund:innen enthielten neben der Höhe und Häufigkeit von Transaktionen auch Daten dazu, über welches Endgerät (PC oder Smartphone) sie gehandelt wurden.

[32] Ankit Kalda et al.: Smart(Phone) Investing? A Within Investor-Time Analysis of New Technologies and Trading Behavior, in: NBER Working Paper No. 28363, Januar 2021. URL: https://www.nber.org/system/files/working_papers/w28363/w28363.pdf. [31.07.2026]

Die Ergebnisse dieser Untersuchung[33] zeigen klare und konsistente Effekte der Smartphone-Nutzung auf das Anlageverhalten:

- **Erhöhte Risikoneigung bei Smartphone-Trades**

  Investor:innen treffen über Smartphones signifikant riskantere Anlageentscheidungen als über Endgeräte wie Computer. Sie kaufen häufiger Aktien und andere risikobehaftete Assets mit höherer Volatilität und ausgeprägteren Renditeschwankungen.

- **Stärkere Präferenz für spekulative („lottery-type“) Investments**

  Smartphone-Nutzer:innen investieren überdurchschnittlich häufig in Anlagen mit lotterieähnlichen Eigenschaften, also solche mit hoher Unsicherheit und potenziell extremen Auszahlungen. Die Wahrscheinlichkeit, solche Assets zu kaufen, steigt durch Smartphone-Nutzung also deutlich an.

- **Ausgeprägtes Trend-Chasing-Verhalten**

  Ein zentraler Befund ist die verstärkte Tendenz, in bereits stark gestiegene („heiße“) Aktien zu investieren. Nutzer:innen von Smartphones kaufen signifikant häufiger Wertpapiere mit hoher vergangener Performance, was auf ein verstärktes kurzfristiges, momentumgetriebenes Verhalten hinweist.

- **Keine Substitution, sondern Verstärkung des Gesamtverhaltens**

  Die Effekte beschränken sich nicht nur auf einzelne Trades über Smartphones. Vielmehr zeigt sich, dass Anleger:innen nach Einführung der Smartphone-Nutzung auch auf anderen Endgeräten riskanter und spekulativer investieren. Dies spricht gegen eine reine Verlagerung von Trades und deutet auf eine nachhaltige Verhaltensänderung hin.

- **Persistente Effekte statt kurzfristiger Nutzungseffekte**

  Die beobachteten Veränderungen im Anlageverhalten sind nicht nur temporär, sondern bleiben über längere Zeit stabil. Die Nutzung von Smartphones führt somit nicht nur zu kurzfristigen Anpassungen, sondern zu dauerhaften Verhaltensmustern.

Die Ergebnisse legen nahe, dass Smartphones stärker impulsives und intuitives Entscheidungsverhalten fördern. Die jederzeitige Verfügbarkeit, einfache Bedienbarkeit und schnelle Ausführung von Trades begünstigen weniger reflektierte und stärker emotional geprägte Anlageentscheidungen und diese Muster wirken sich seit der Nutzung von Smartphone-Trading auch auf andere Anlagewege aus.

[33] Ankit Kalda et al.: Smart(Phone) Investing?, S. 27f.

Auch die chinesischen Forscher Chongfeng Wu und Haibo Wu ermittelten, dass Investor:innen über das Smartphone stärker „attention grabbing“, also Aufmerksamkeit erzwingende, Assets kaufen, die in limitierten Preisevents als „Top Ranked“ angezeigt wurden. Als Gründe dafür nennen sie unter anderem die begrenzte Größe des Smartphone-Bildschirms, auf dem die Top-Einträge einer Liste an Assets stärker betont werden und die die Suche nach weiterführenden Informationen schwieriger gestaltet.[34]

Ergänzend zu den genannten Studien liefert auch die Arbeit „Blessing or Curse? The Influence of Neobrokers on the Investment Behavior of Young Investors“[35] von Maximilian Janussek (TU München) aus dem Jahr 2022 empirische Evidenz zu den Auswirkungen von Trading-Apps auf das Anlegerverhalten.

In einer quantitativen Online-Befragung ermittelte er 224 Datensätze für seine Auswertung zu dem Einfluss von Neobrokern auf das Investmentverhalten ihrer Nutzer:innen. Die Ergebnisse bestätigen und konkretisieren zentrale Muster der bisher genannten Forschung:

- **Klare Zielgruppenstruktur: jung und digital affin**

  Neobroker sprechen vor allem jüngere Anleger:innen an. In der Untersuchung dominieren Nutzer:innen zwischen 18 und 34 Jahren deutlich, was die starke Ausrichtung auf digital geprägte Zielgruppen unterstreicht.

- **Fokus auf kurzfristige und spekulative Strategien**

  Die Nutzung von Neobrokern erfolgt primär für kurzfristige Investments. Langfristige Ziele wie Altersvorsorge oder Vermögensaufbau spielen eine deutlich geringere Rolle.

- **Erhöhte Handelsfrequenz gegenüber klassischen Brokern**

  Neobroker-Nutzer:innen handeln signifikant häufiger. Während klassische Bankkund:innen im Schnitt nur alle sechs Monate aktiv werden, liegt die Handelsfrequenz bei Neobroker-Nutzer:innen im Bereich von monatlichen bis vierteljährlichen Transaktionen.

- **Signifikant höhere Risikobereitschaft**

  Die Risikotoleranz von Neobroker-Kund:innen liegt messbar über der von Nutzer:innen traditioneller Anbieter. In der Studie erreichen sie im Durchschnitt

[34] Haibo Wu, Chongfeng Wu: Mobile device use and the ranking effect on trading behavior: Evidence from natural experiments, in: Pacific-Basin Finance Journal, Vol. 85, 2024. URL: https://www.sciencedirect.com/science/article/abs/pii/S0927538X24000684. [31.07.2026]

[35] Maximilian Janussek: Blessing or Curse? The Influence of Neobrokers on the Investment Behavior of Young Investors, in: Junior Management Science 7, 2022, S. 1375–1399. URL: https://jums.academy/wp-content/uploads/2022/12/MA_Janussek.pdf. [31.07.2026]

höhere Risikoscores und zeigen eine deutlich stärkere Bereitschaft, riskante Investments einzugehen.

- **Direkter Einfluss des App-Designs auf Entscheidungen**

  Ein zentrales Ergebnis ist der nachweisbare Einfluss der Darstellung von Informationen auf das Verhalten. Bereits unterschiedliche Chart-Darstellungen (z. B. Tages- vs. Jahresansicht) verändern die Risikowahrnehmung signifikant und beeinflussen die Handelsentscheidung.

- **Gamification und vereinfachte UX als Verhaltenssteuerung**

  Die intuitive Gestaltung sowie spielerische Elemente fördern häufigere Interaktionen und senken die Hemmschwelle für Trades. Dadurch wird Trading teilweise als unterhaltungsähnliche Aktivität wahrgenommen.

Janussek kommt wie die anderen Studien zu einem differenzierten Fazit: Neobroker erleichtern den Zugang zum Kapitalmarkt erheblich, fördern jedoch gleichzeitig kurzfristiges, risikoreiches und teilweise wenig fundiertes Anlageverhalten.[36]

Diese Ergebnisse ergänzen die bestehende Forschung konsistent: Sie bestätigen sowohl die erhöhte Marktteilnahme als auch die systematische Verschiebung hin zu häufigerem, risikoreicherem und stärker durch Interface-Design beeinflusstem Anlageverhalten.

[36] Janussek: Blessing or Curse?, S. 1393–1397.

Der Einfluss von sozialen Medien

Neobroker-Apps integrieren gezielt Elemente aus sozialen Medien, um Nutzerinteraktion, Engagement und Handelsaktivität zu erhöhen. Diese Mechaniken orientieren sich an etablierten Plattformlogiken (z. B. Instagram, TikTok, Twitter/X) und übertragen sie in einen Finanzkontext. Die wichtigsten Elemente lassen sich systematisch einordnen:

- **Gamification-Mechaniken**

  Dazu gehören visuelle Belohnungssysteme wie Konfetti-Animationen nach Trades, Fortschrittsanzeigen oder Performance-Highlights im Portfolio. Diese Elemente ähneln den Feedback-Loops[37] sozialer Medien (Likes, Reaktionen) und verstärken kurzfristige Dopamin-Effekte.[38] Ziel ist es, wiederholte Nutzung und häufigeres Trading zu fördern.

- **Push-Benachrichtigungen und Echtzeit-Updates**

  Nutzer:innen erhalten kontinuierlich Hinweise zu Kursbewegungen, „Trending Stocks“ oder persönlichen Gewinnen und Verlusten. Diese Mechanik entspricht dem Notification-Design sozialer Netzwerke und erzeugt eine permanente Aufmerksamkeitsschleife, die impulsives Verhalten begünstigen kann.[39]

- **Social-Trading-Ansätze**

  Einige Apps zeigen aggregierte Daten wie „Andere Nutzer:innen kaufen gerade…“ oder „Beliebte Aktien heute“. Teilweise existieren auch Ranglisten oder Einblicke in Portfolios anderer Anleger:innen. Diese Transparenz sozialer Aktivitäten ähnelt Feeds oder Trends in sozialen Netzwerken und kann Herdenverhalten (Herding) verstärken.[40] In Trading-Apps mit Copy-Trading-Funktion können Nutzer:innen sogar die Portfolio-Zusammenstellung anderer Accounts per Klick nachmachen und von deren wahrgenommenem Wissen und Erfolg profitieren.

---

[37] Artemisa Dores et al.: The Effects of Social Feedback Through the “Like” Feature on Brain Activity: A Systematic Review, in: Healthcare 13, No. 1, 2025, S. 89. URL: https://doi.org/10.3390/healthcare13010089. [31.07.2026]

[38] Lauren Sherman et al.: The Power of the Like in Adolescence: Effects of Peer Influence on Neural and Behavioral Responses to Social Media, in: Psychological science, Vol. 27 (7), 2016, S. 1027–1035. URL: https://pubmed.ncbi.nlm.nih.gov/27247125/. [31.07.2026]

[39] Cary Stothart, Ainsley Mitchum, Courtney Yehnert: The Attentional Cost of Receiving a Cell Phone Notification, in: Journal of Experimental Psychology: Human Perception and Performance, August 2015. URL: https://www.researchgate.net/publication/279457726_The_Attentional_Cost_of_Receiving_a_Cell_Phone_Notification [31.07.2026]

[40] Philipp Masur et al.: Behavioral contagion on social media: Effects of social norms, design interventions, and critical media literacy on self-disclosure, in: PloS one Vol. 16 (7), 19.07.2021. URL: https://pmc.ncbi.nlm.nih.gov/articles/PMC8289004. [31.07.2026]

- **Community- und Kommunikationsfunktionen**

  Dazu zählen Kommentarbereiche, Diskussionsforen oder die Integration externer Social-Media-Inhalte (z. B. Reddit-Trends, Twitter-Stimmungen). Nutzer:innen orientieren sich dadurch stärker an Meinungen anderer statt ausschließlich an Fundamentaldaten.[41]

- **Vereinfachung und visuelle Aufbereitung von Informationen**

  Inhalte werden stark reduziert, emotionalisiert und visuell optimiert – etwa durch einfache Charts, farbliche Hervorhebungen (grün/rot) oder leicht verständliche Kennzahlen. Diese „Snackable Content"-Struktur entspricht typischen Social-Media-Formaten und senkt die kognitive Einstiegshürde.[42]

- **Personalisierungs-Algorithmen**

  Basierend auf Nutzerverhalten werden Inhalte, Aktien oder Nachrichten individuell priorisiert angezeigt – vergleichbar mit algorithmischen Feeds auf Social-Media-Plattformen. Dadurch entsteht eine Art „Finanz-Feed", der selektiv Informationen präsentiert und potenziell Filterblasen erzeugt.[43]

- **Niedrige Interaktionsbarrieren**

  Die Möglichkeit, mit wenigen Klicks zu handeln, ähnelt dem schnellen Liken oder Teilen von Inhalten. Diese Reduktion von Reibung fördert spontane Entscheidungen[44] statt reflektierter Investitionen.

In der Summe übertragen Neobroker zentrale Prinzipien sozialer Medien – Aufmerksamkeit, Interaktion, soziale Orientierung und Belohnungssysteme – direkt auf Finanzentscheidungen. Das verändert nicht nur die Nutzererfahrung, sondern auch nachweislich das Anlageverhalten, insbesondere in Richtung häufigerer und kurzfristiger Trades.

Neben den in den Apps integrierten Mechanismen wirken auch externe Einflüsse aus sozialen Medien auf das Anlageverhalten von Neobroker-Nutzer:innen. Eine zentrale Rolle spielen dabei sogenannte Finfluencer:innen – also Content Creator, die auf Plattformen wie YouTube, TikTok, Instagram oder X Inhalte zu Finanzthemen

---

[41] Matthew Salganik, Peter Sheridan Dodds, Duncan Watts: Experimental Study of Inequality and Unpredictability in an Artificial Cultural Market, in: Science, Vol. 311, 10.02.2006. URL: https://www.princeton.edu/~mjs3/salganik_dodds_watts06_full.pdf. [31.07.2026]

[42] Kevin Chen: Impacts of Short-Form Media Use on Sustained Attention and Memory: A Behavioral Study of TikTok Consumption in Young Adults. Undergrad Honors Thesis Version 1, 2025, in: Stanford Digital Repository. URL: https://purl.stanford.edu/zb094wm9033. [31.07.2026]

[43] Matteo Cinelli et al.: The echo chamber effect on social media, in: PNAS Vol. 118, No. 9, 2021. URL: https://www.pnas.org/doi/pdf/10.1073/pnas.2023301118. [31.07.2026]

[44] Richard Thaler, Cass Sunstein: Nudge: The Final Edition, Penguin Books 2021, S. 23–151.

veröffentlichen. Sie erreichen insbesondere junge, digital affine Zielgruppen[45] und fungieren für viele Nutzer:innen als niedrigschwellige Informationsquelle.

Solche Inhalte können das Finanzinteresse fördern und Wissen leichter zugänglich machen.[46] Gleichzeitig werden komplexe Zusammenhänge häufig verkürzt, visuell zugespitzt und mit konkreten Handlungsimpulsen verbunden. Persönliche Erfolgsgeschichten, veröffentlichte Portfolios und die direkte Ansprache können Nähe und Vertrauen erzeugen,[47] obwohl die fachliche Qualifikation, Vergütungen oder eigene wirtschaftliche Interessen nicht immer eindeutig erkennbar sind.

Empirische Untersuchungen und Berichte von Aufsichtsbehörden zeigen, dass solche Inhalte das Anlageverhalten beeinflussen können. Nutzer:innen orientieren sich verstärkt an Trends, reagieren auf kurzfristige Marktentwicklungen oder investieren in Assets, die aktuell hohe Aufmerksamkeit in sozialen Medien erhalten.[48] Dadurch können soziale Bestätigung, Trend-Chasing und die Hinwendung zu besonders aufmerksamkeitsstarken oder riskanteren Produkten begünstigt werden. In Verbindung mit der unmittelbaren Handelbarkeit über Neobroker verkürzt sich zudem der Weg zwischen der Wahrnehmung eines Beitrags und der tatsächlichen Transaktion.

[45] Miranda Reiter, Di Qing, Morgen Nations: Who Uses Social Media for Investment Advice?, in: Journal of Financial Planning, September 2023. URL: https://www.financialplanningassociation.org/learning/publications/journal/SEP23-who-uses-social-media-investment-advice-OPEN. [31.07.2026]
[46] ebd.
[47] Delia Cristina Balaban, Julia Szambolics, Mihai Chirică: Parasocial relations and social media influencers' persuasive power. Exploring the moderating role of product involvement, in: Acta Psychologica, Vol. 230, Oktober 2022. URL: https://www.sciencedirect.com/science/article/pii/S0001691822002463?via%3Dihub. [31.07.2026]
[48] Hoyun Kim: Social media engagement and retail investors' short-termism, in: Finance Research Letters, Vol. 85, Part E, 2025. URL: https://www.sciencedirect.com/science/article/pii/S154461232501503X. [31.07.2026]

Praxisteil: Umfrage zum Anlageverhalten und Erfahrungen von Neobroker-Nutzer:innen

In Zusammenarbeit mit dem Markt- und Meinungsforschungsinstitut YouGov wurde für diese Studie im Sommer 2026 eine Umfrage mit deutschen Nutzern und Nutzerinnen von Trading-Apps durchgeführt, um die Erfahrungen und das Anlageverhalten dieser analysieren zu können.

Die Daten dieser Befragung basieren auf Online-Fragebögen beantwortet durch Mitglieder des YouGov-Panels, die Neobroker nutzen und der Teilnahme vorab zugestimmt haben. Für diese Befragung wurden im Zeitraum 23.06. bis 05.07.2026 insgesamt 1.021 Personen befragt, auf die dies zutraf.

Im Folgenden werden die Ergebnisse dieser Fragebögen ausgewertet.

Hinweise zu der statistischen Auswertung

Die Auswertung der 1.021 Befragten wurde mit Microsoft Excel und dem Open-Source-Datenanalyseprogramm JASP durchgeführt. Berücksichtigt wurden jeweils nur gültige Antworten; fehlende Angaben sowie nicht auswertbare Antwortoptionen wurden ausgeschlossen. Daher können die Fallzahlen zwischen den Analysen variieren. Bei Mehrfachantwortfragen kann die Summe der Prozentwerte über 100 % liegen.

Für die Gruppenvergleiche wurden Antwortkategorien zusammengefasst. Häufiges Trading umfasst tägliche oder wöchentliche Transaktionen, häufige spontane Entscheidungen die Antworten „häufig“ und „sehr häufig“. Eine App-Funktion galt als einflussreich, wenn sie „etwas“ oder „sehr“ beeinflusste.

Die Zusammenhänge wurden zunächst mit Kreuztabellen, Pearson-Chi-Quadrat-Tests, Odds Ratios und Cramérs V geprüft. Wegen der mehrfachen Tests erfolgte eine FDR-Korrektur nach Benjamini-Hochberg. Ergänzend wurden binär-logistische Regressionen berechnet und dabei Alter, Geschlecht, Finanzwissen und Dauer der App-Nutzung kontrolliert. Die Ergebnisse werden als adjustierte Odds Ratios mit 95-%-Konfidenzintervallen dargestellt.

Die vollständigen Contingency Tables, Chi-Quadrat-Ausgaben und Logistic Regression Tables aus JASP sind im Anhang dokumentiert. Aufgrund des Querschnittsdesigns zeigen die Analysen Zusammenhänge, erlauben jedoch keine eindeutigen Aussagen über Ursache und Wirkung.

Demografischer Hintergrund der Umfrageteilnehmer:innen

1.021 Personen des YouGov-Panels sind laut eigenen Angaben Nutzer:innen von Neobroker-Apps und haben sich zur Beantwortung der Fragen bereiterklärt. Sie teilen sich in 774 Männer und 247 Frauen auf.

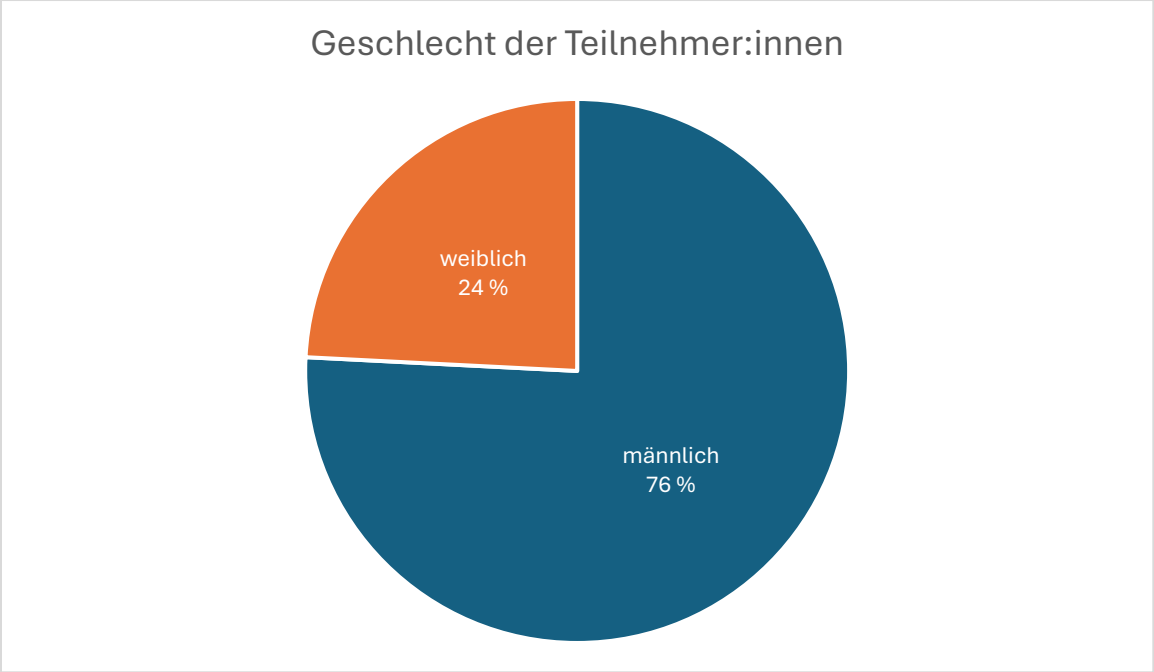


Abbildung 1: Geschlecht der Teilnehmer:innen

Die am stärksten vertretene Altersgruppe waren Teilnehmer:innen über 55 Jahren (292 Teilnehmer:innen), gefolgt von 234 Personen zwischen 35 und 44 Jahren. Die kleinste Gruppe der Befragten war der Teil der jüngsten Altersspanne zwischen 18 und 24 Jahren.

Da die Umfrageergebnisse keine Gewichtungsvariable enthalten, sollten die Ergebnisse aufgrund des hohen Männeranteils und der Altersverteilung daher nicht ohne Weiteres als repräsentativ für alle deutschen Trading-App-Nutzer:innen gesehen werden.

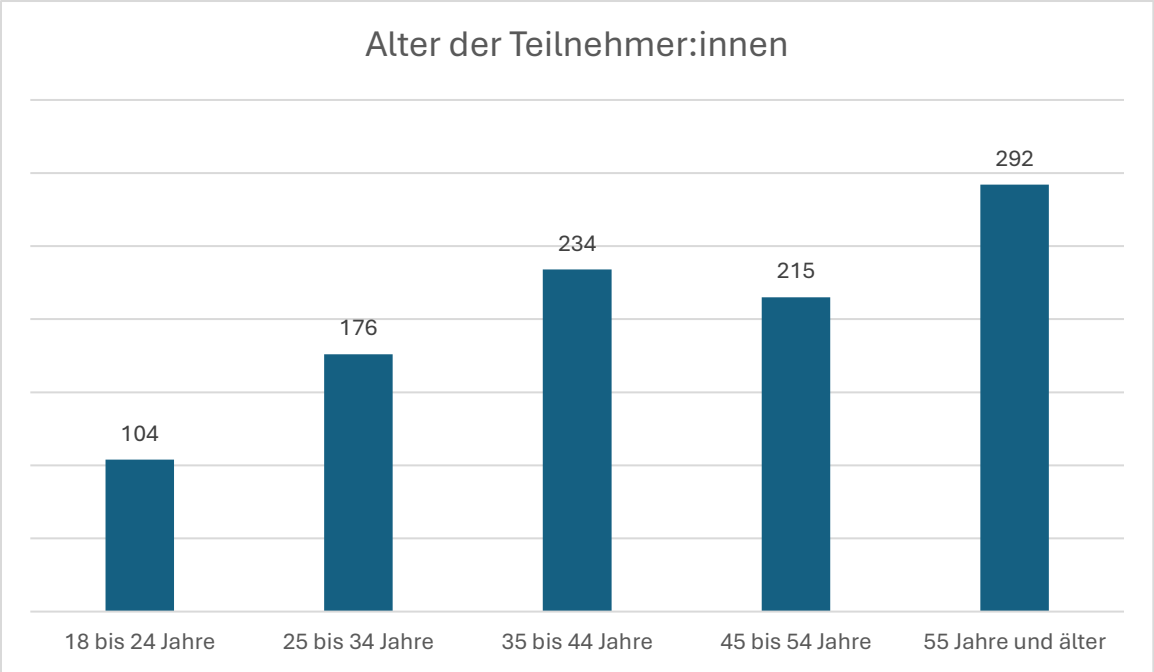


Abbildung 2: Alter der Teilnehmer:innen

Die mit Abstand meisten der Teilnehmer:innen sind Bewohner und Bewohnerinnen der Bundesländer Nordrhein-Westfalen, Baden-Württemberg und Bayern.

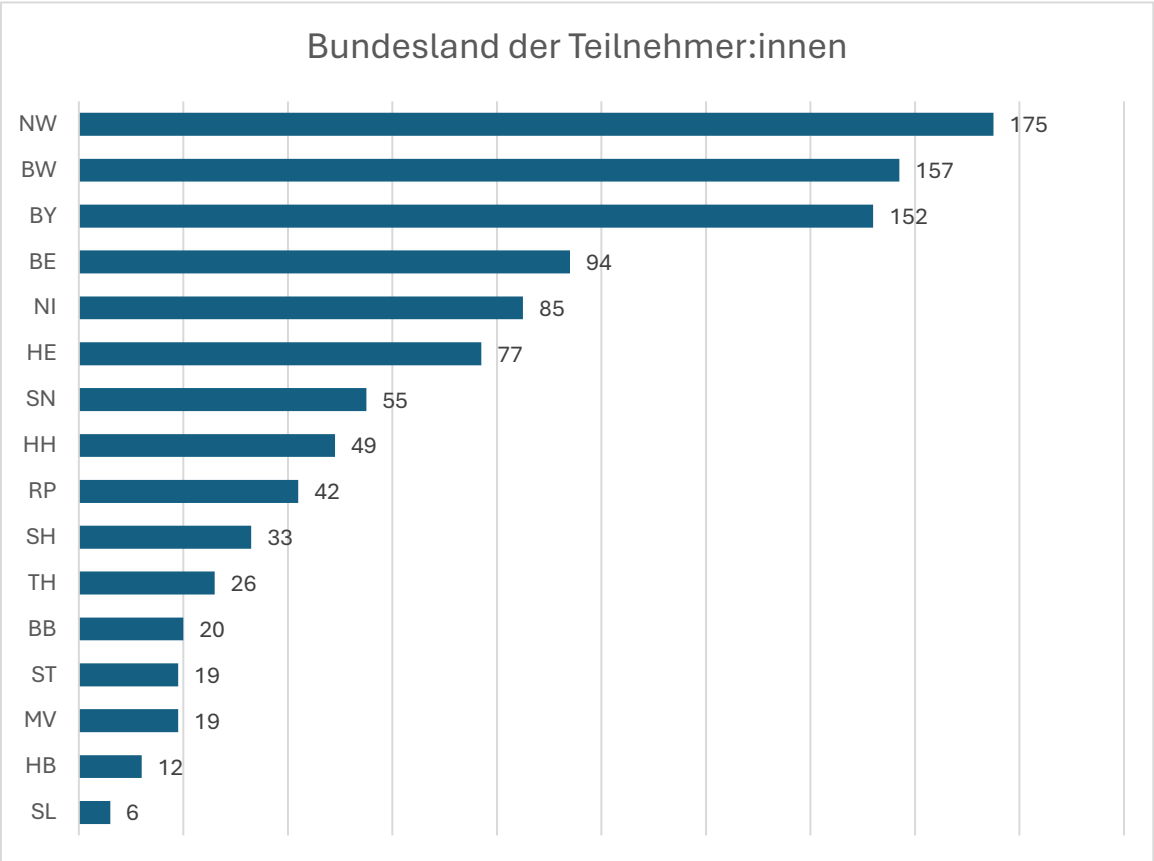


Abbildung 3: Bundesland der Teilnehmer:innen

81 % der Befragten des YouGov-Panels, die eine gültige Antwort gegeben haben, erhalten Einkommen überwiegend durch ihre Berufstätigkeit, gefolgt von 115 Rentner- und Pensionär:innen (11 %).

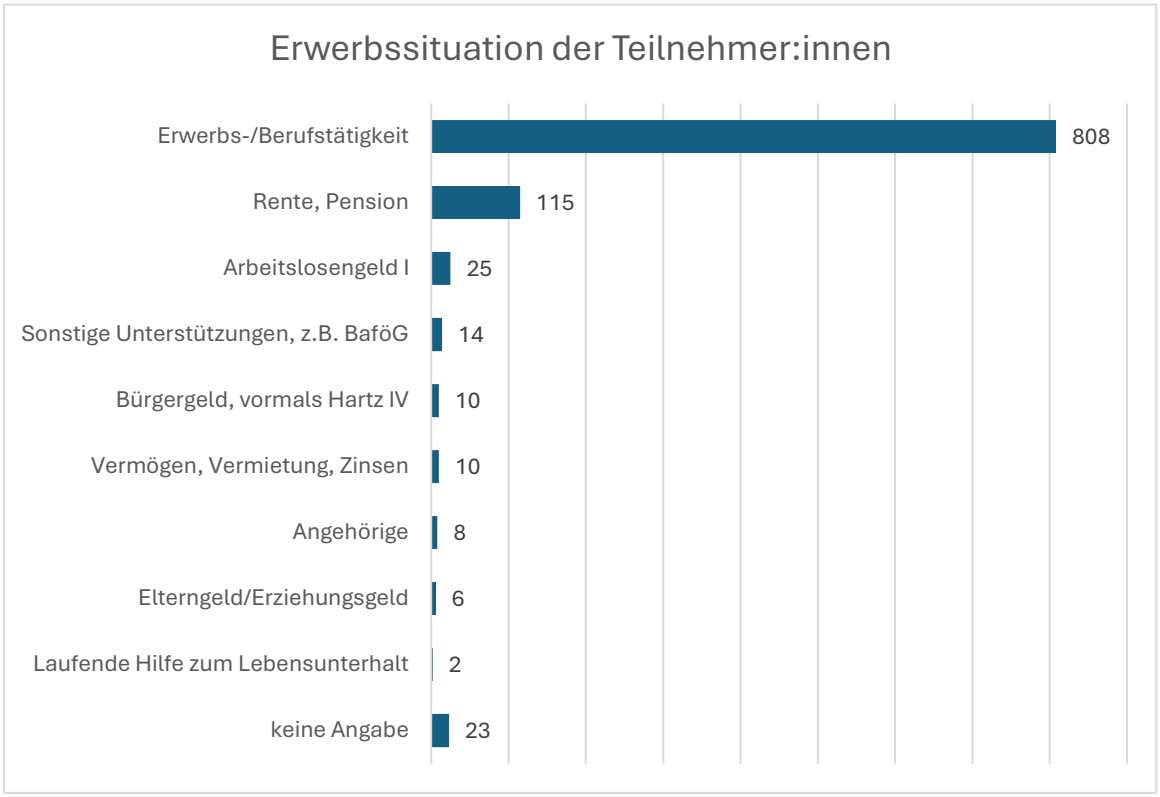


Abbildung 4: Erwerbssituation der Teilnehmer:innen

Das Nettoeinkommen der Haushalte teilt sich dabei wie folgt auf, mit dem größten Anteil der Teilnehmer:innen (33 %) mit einem monatlichen Einkommen von über 5.000 €.

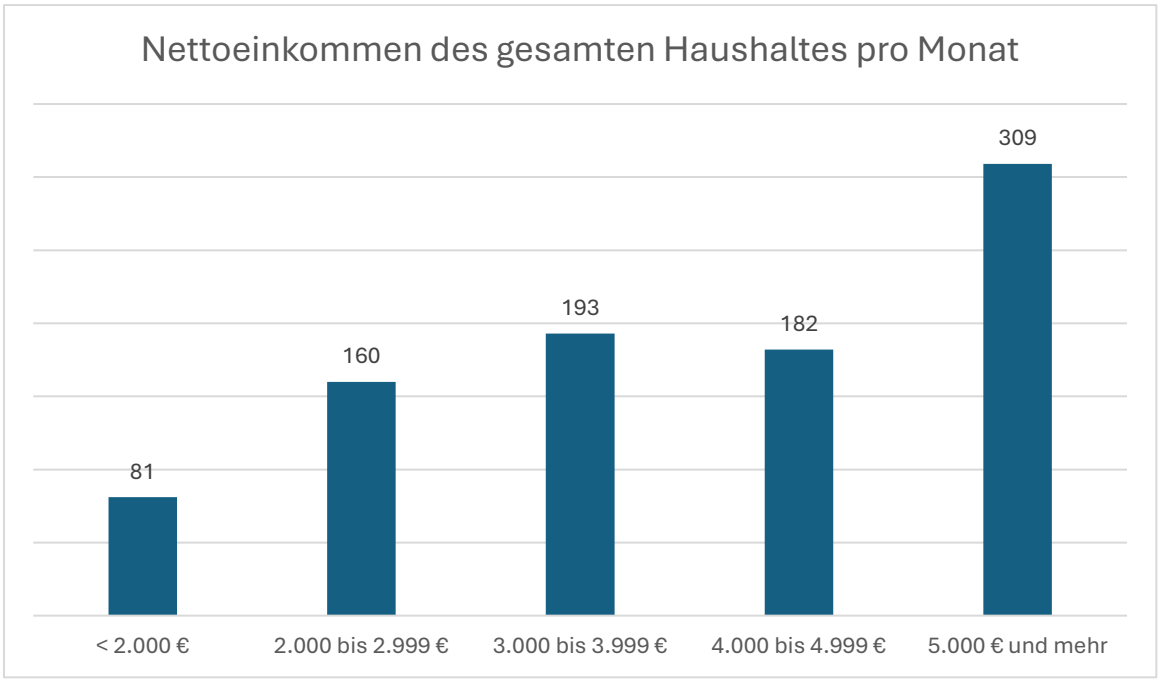


Abbildung 5: Nettoeinkommen der Teilnehmer:innen-Haushalte

Die so dargestellte Demografie der Teilnehmer:innen des YouGov-Panels hat schließlich die für diese Studie konzipierten Fragen zu ihrem Anlageverhalten und Erfahrungen mit Neobroker-Trading-Apps beantwortet.

Umfrageergebnisse

Die Teilnehmer:innen wurden zunächst gefragt, welche Wege sie insgesamt für ihre Investments nutzen. Da Mehrfachantworten möglich waren, konnten neben dem Neobroker weitere Anlagewege ausgewählt werden. 658 der 1.021 Befragten nutzen mindestens zwei verschiedene Anlagewege. Dies entspricht 64,4 % der gültigen Antworten.

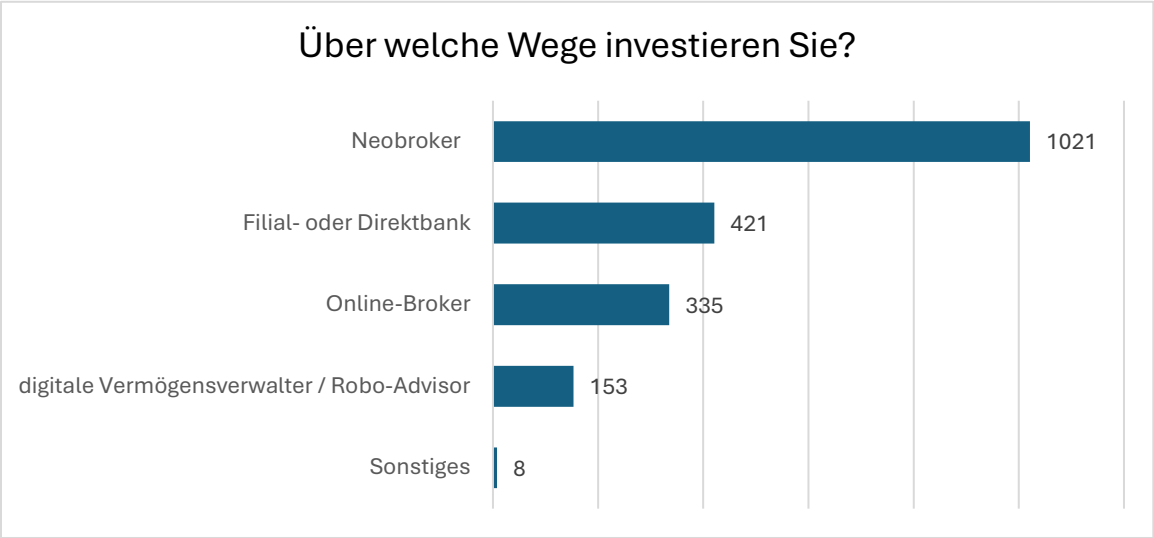


Abbildung 6: Genutzte Investitionswege

35,6 % investieren ausschließlich über einen Neobroker und nutzen keinen der weiteren abgefragten Anlagewege.

Anschließend wurde erhoben, welche Anlageprodukte die Teilnehmer:innen aktuell besitzen oder nutzen. Auch hierbei handelte es sich um eine Mehrfachantwortfrage. Alle 1.021 Befragten machten mindestens eine gültige Angabe.

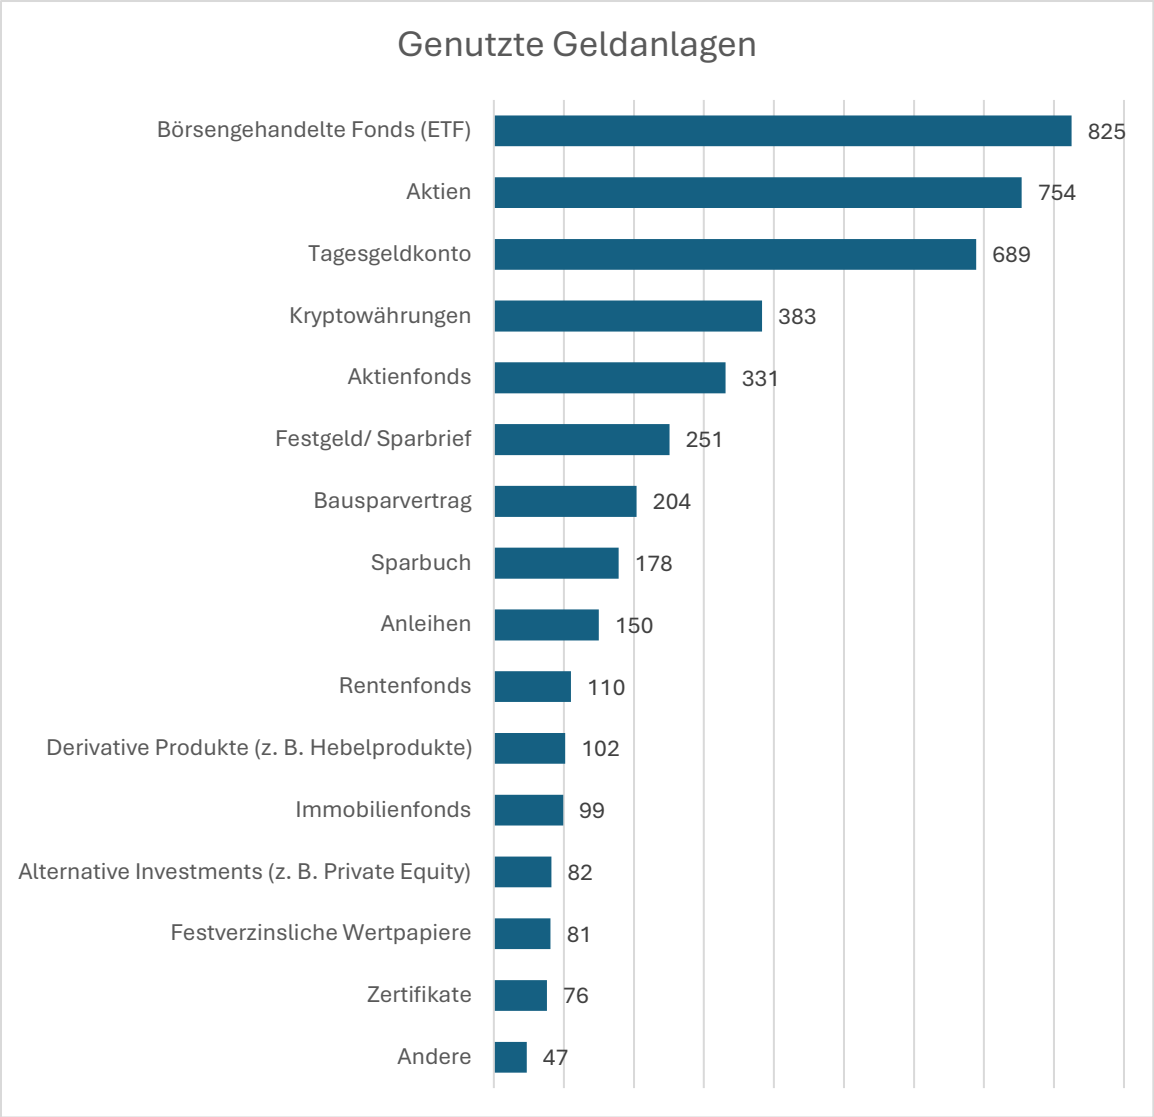


Abbildung 7: Genutzte Geldanlagen

Mit 80,8 % sind ETFs das am häufigsten genutzte Anlageprodukt. Es folgen Aktien mit 73,8 % und Tagesgeldkonten mit 67,5 %.

Auch unter den Personen, die ausschließlich über einen Neobroker investieren, sind Tagesgeldkonten verbreitet: 59,5 % von ihnen gaben an, ein solches Konto zu besitzen. Entsprechende verzinste Guthabenangebote gehören inzwischen auch bei einzelnen Neobrokern wie Scalable Capital zum Leistungsumfang.

Weitere häufig genutzte Anlageprodukte sind Kryptowährungen mit 37,5 %, Aktienfonds mit 32,4 %, Festgeld oder Sparbriefe mit 24,6 %, Bausparverträge mit 20,0 %, Sparbücher mit 17,4 %, Anleihen mit 14,7 % und Rentenfonds mit 10,8 %.

Derivative Produkte wie Hebelprodukte werden von 10,0 % genutzt, Immobilienfonds von 9,7 %, alternative Investments von 8,0 %, festverzinsliche Wertpapiere von 7,9 % und Zertifikate von 7,4 %. Weitere, nicht näher spezifizierte Anlageprodukte nannten 4,6 %.

Daraufhin wurden die Teilnehmer:innen gefragt, über welchen Weg sie hauptsächlich investieren. Eine Person wählte „weiß nicht/keine Angabe“ und wurde bei der Prozentberechnung nicht berücksichtigt.

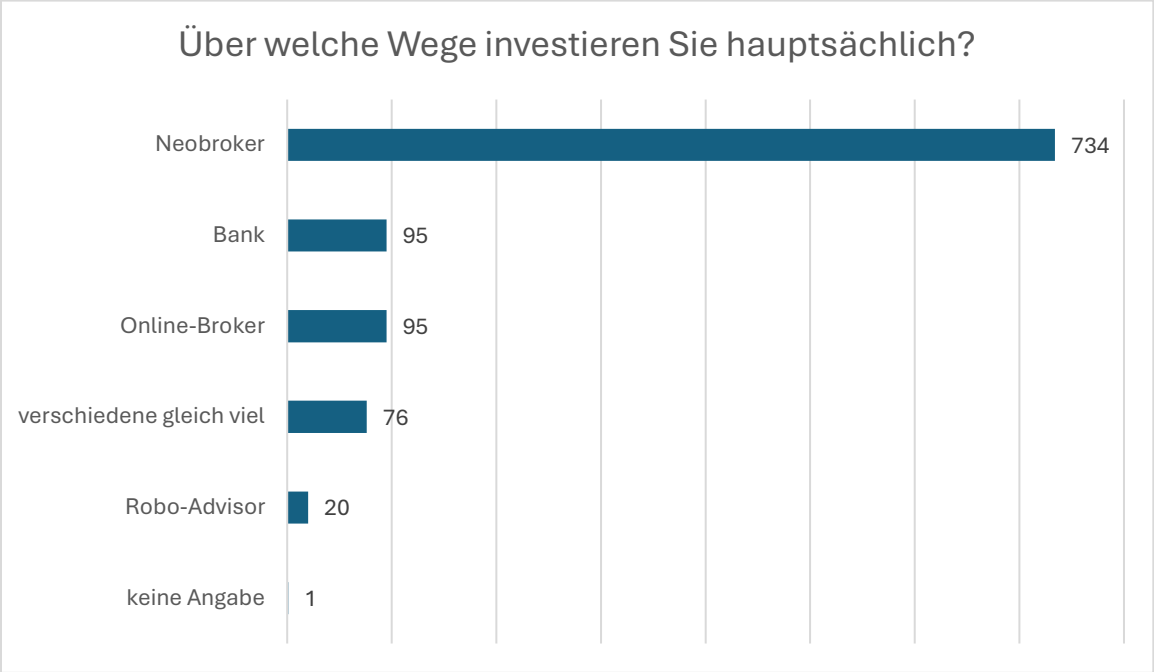


Abbildung 8: Meistgenutzte Investmentwege

Mit 72,0 % der gültigen Antworten ist der Neobroker der mit Abstand am häufigsten genutzte Hauptanlageweg. Jeweils 9,3 % investieren hauptsächlich über eine traditionelle Bank oder einen Online-Broker. Weitere 7,5 % nutzen verschiedene Anlagewege ungefähr gleich häufig. Nur 2,0 % verwenden hauptsächlich einen digitalen Vermögensverwalter beziehungsweise Robo-Advisor.

Über alle Anlagewege hinweg investieren die Befragten am häufigsten mehrmals im Jahr (61,3 %) oder mehrmals im Monat (57,0 %). Tägliche Investitionen nennen 29,7 %, während 26,1 % mehrmals pro Woche handeln. Deutlich seltener investieren die Teilnehmer:innen nur einmal im Jahr (8,3 %) oder weniger als einmal jährlich (6,7 %). Da die Handelsfrequenz für jeden genutzten Anlageweg getrennt angegeben wurde, waren mehrere Nennungen pro Person möglich.

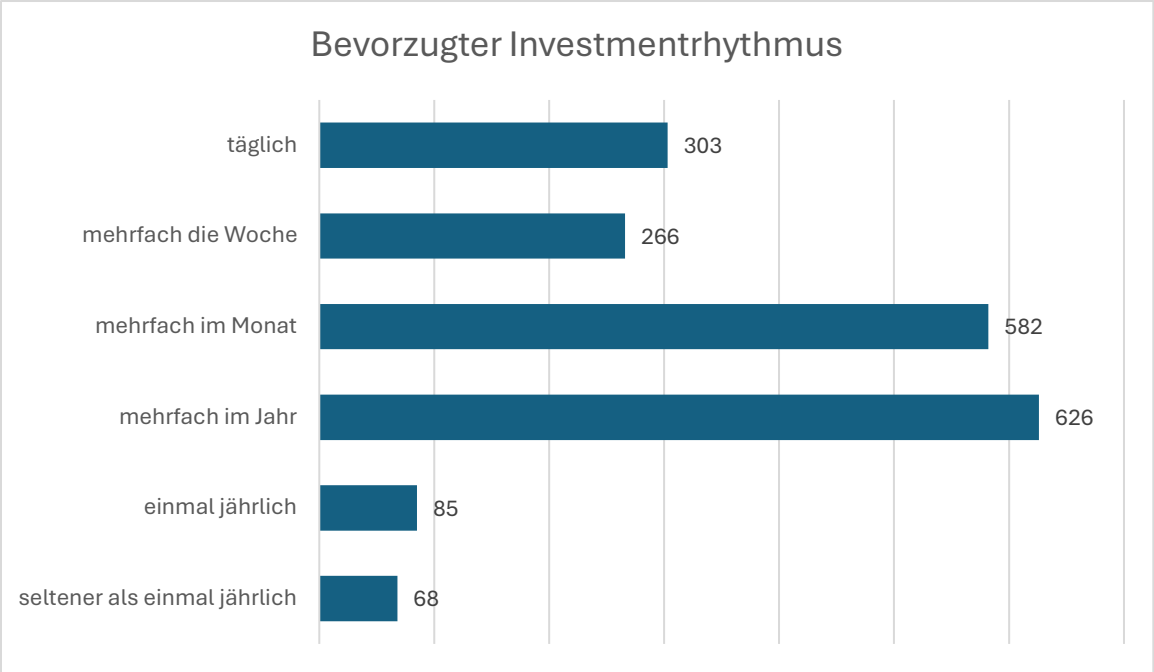


Abbildung 9: Bevorzugter Investmentrhythmus

Gemessen an den absoluten Nennungen ist der Neobroker – mit Ausnahme der Kategorie „seltener als einmal im Jahr“ – in allen Zeitintervallen der meistgenutzte Anlageweg. 34,5 % der Befragten handeln über ihren Neobroker mehrmals im Monat, weitere 33,4 % mehrmals im Jahr. Bei traditionellen Banken entfielen die meisten Angaben ebenfalls auf die Kategorie „mehrmals pro Jahr“. Diese wurde von 162 der 421 Banknutzer:innen genannt.

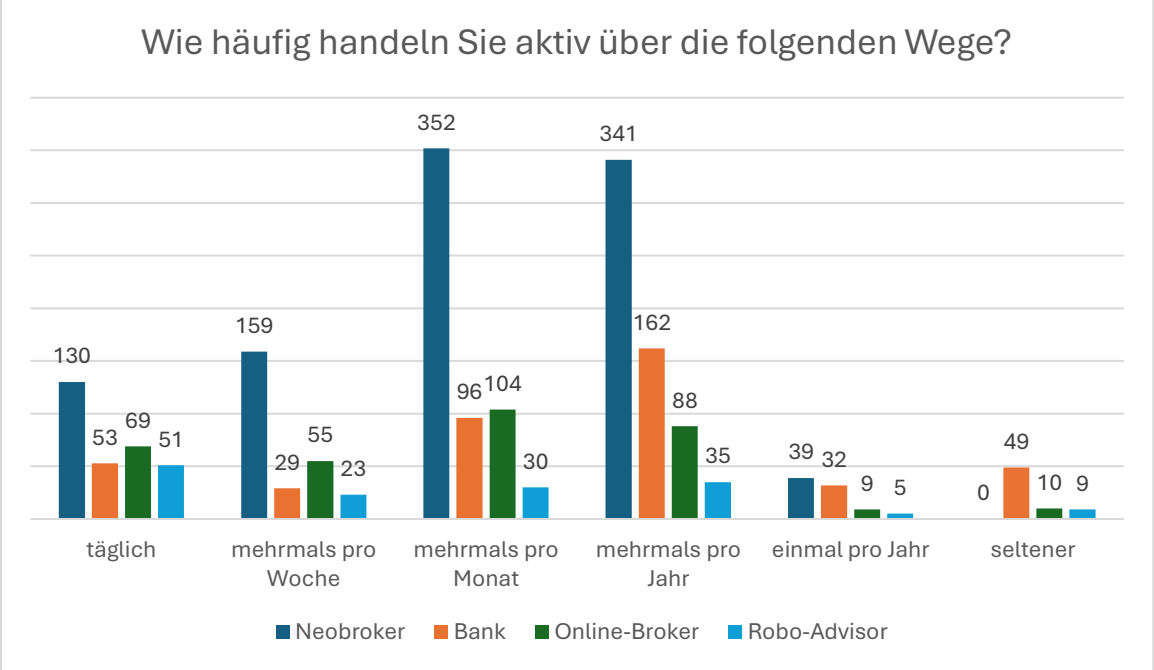


Abbildung 10: Häufigkeit genutzter Investmentwege

Im nächsten Schritt wurden die Teilnehmer:innen gefragt, wie sie ihr allgemeines Finanzwissen auf einer Skala von „sehr gut“ bis „sehr schlecht“ einschätzen. Drei

Personen machten hierzu keine Angabe und wurden bei der Prozentberechnung nicht berücksichtigt.

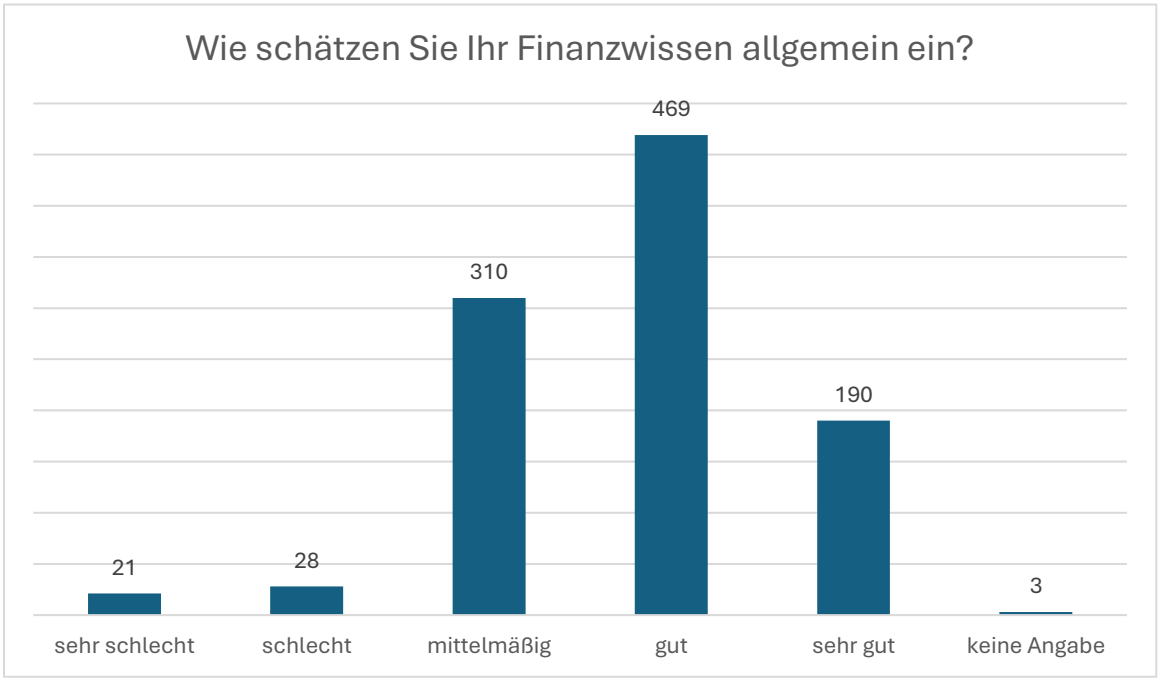


Abbildung 11: Selbsteinschätzung Finanzwissen allgemein

Insgesamt bewerten 64,7 % der gültig Antwortenden ihr Finanzwissen als gut oder sehr gut. Davon stufen es 46,1 % als gut und 18,7 % als sehr gut ein. Weitere 30,5 % bezeichnen ihr Wissen als mittelmäßig. Nur 4,8 % bewerten ihre Finanzkenntnisse als schlecht oder sehr schlecht.

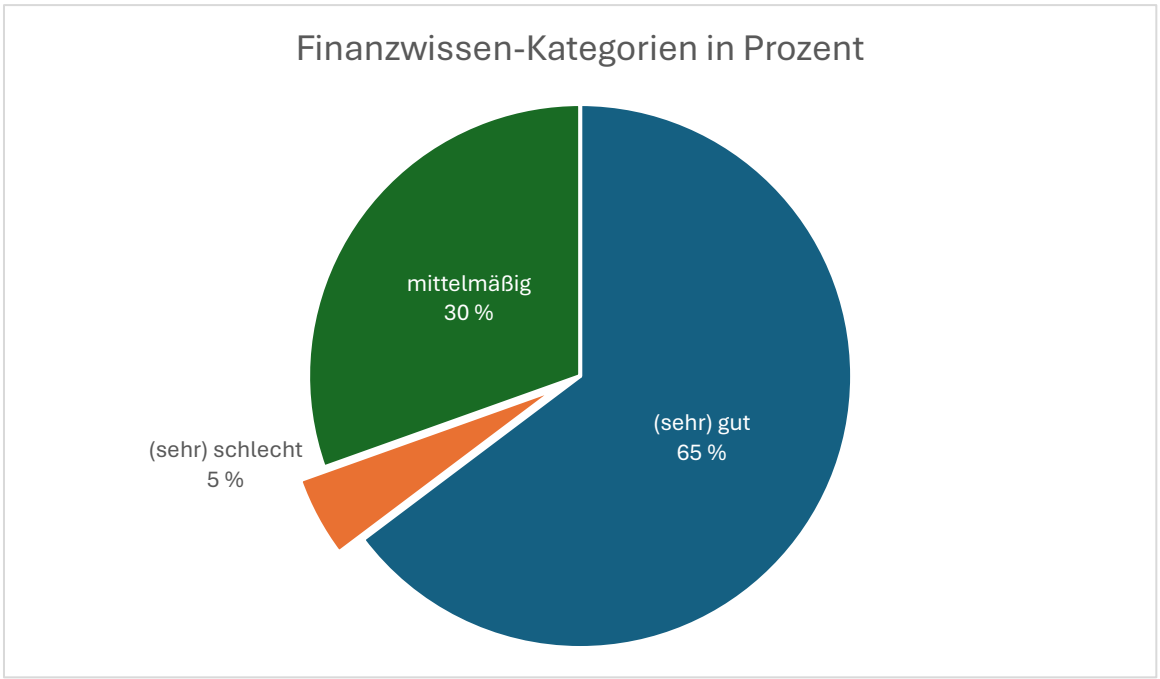


Abbildung 12: Prozentuale Aufteilung Stärke des Finanzwissens

Ergänzend wurde gefragt, wie gut sich die Teilnehmer:innen aktuell aufgestellt fühlen, um fundierte Investmententscheidungen zu treffen. Vier Personen machten hierzu keine auswertbare Angabe. Die Antworten ähneln der Einschätzung des allgemeinen Finanzwissens, fallen jedoch etwas zurückhaltender aus: 63,6 % fühlen sich gut oder sehr gut aufgestellt, 30,2 % mittelmäßig und 6,2 % schlecht oder sehr schlecht. Das Vertrauen in die eigene praktische Entscheidungsfähigkeit ist damit geringfügig schwächer ausgeprägt als die Einschätzung des allgemeinen Finanzwissens.

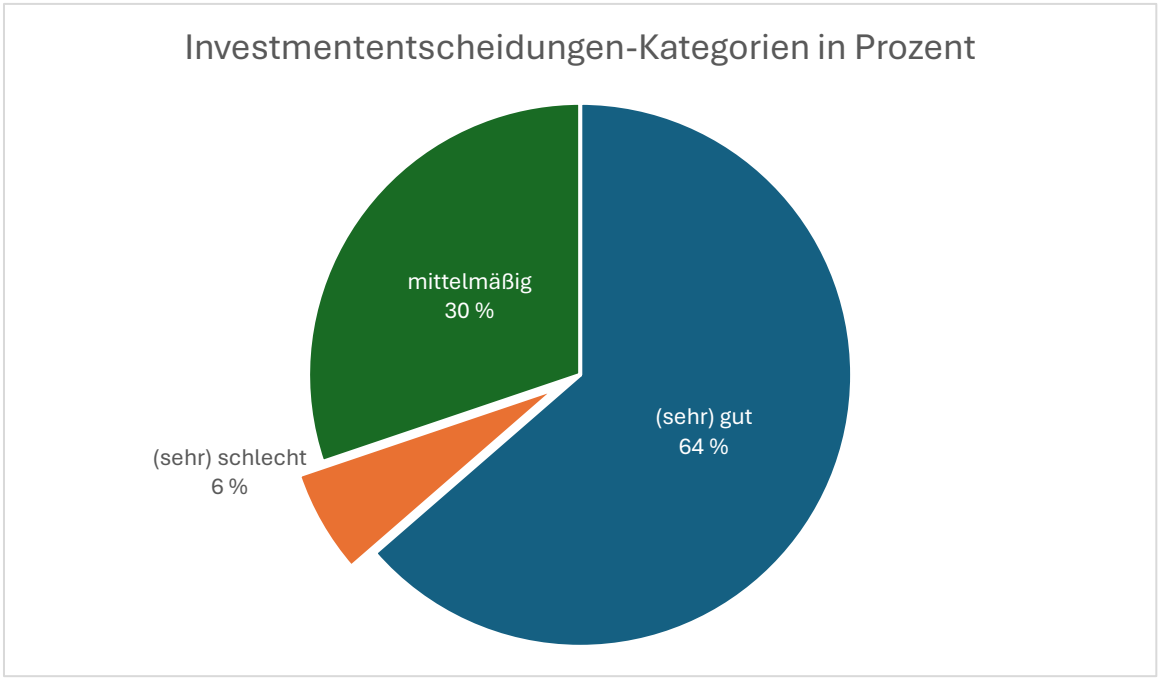


Abbildung 13: Prozentuale Aufteilung Vertrauen in Investmententscheidungen

Entsprechend bewerten weniger Teilnehmer:innen ihre Fähigkeit zu fundierten Investmententscheidungen als „sehr gut“: Der Anteil sinkt gegenüber der Einschätzung des allgemeinen Finanzwissens von 18,7 % auf 16,8 %. Gleichzeitig steigt der Anteil der Bewertung „schlecht“ von 2,8 % auf 4,1 %.

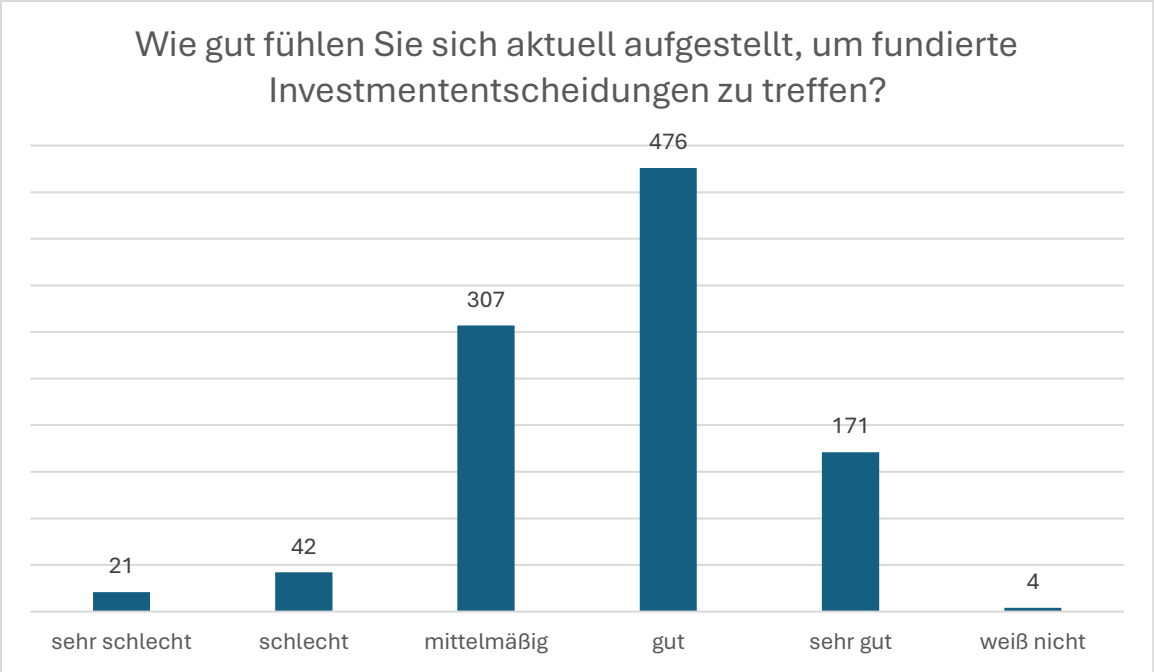


Abbildung 14: Selbsteinschätzung Vertrauen in Investmententscheidungen

Im Anschluss wurde erhoben, über welchen Weg die Teilnehmer:innen erstmals investiert hatten. 39 Personen machten hierzu keine auswertbare Angabe und wurden bei der Prozentberechnung nicht berücksichtigt.

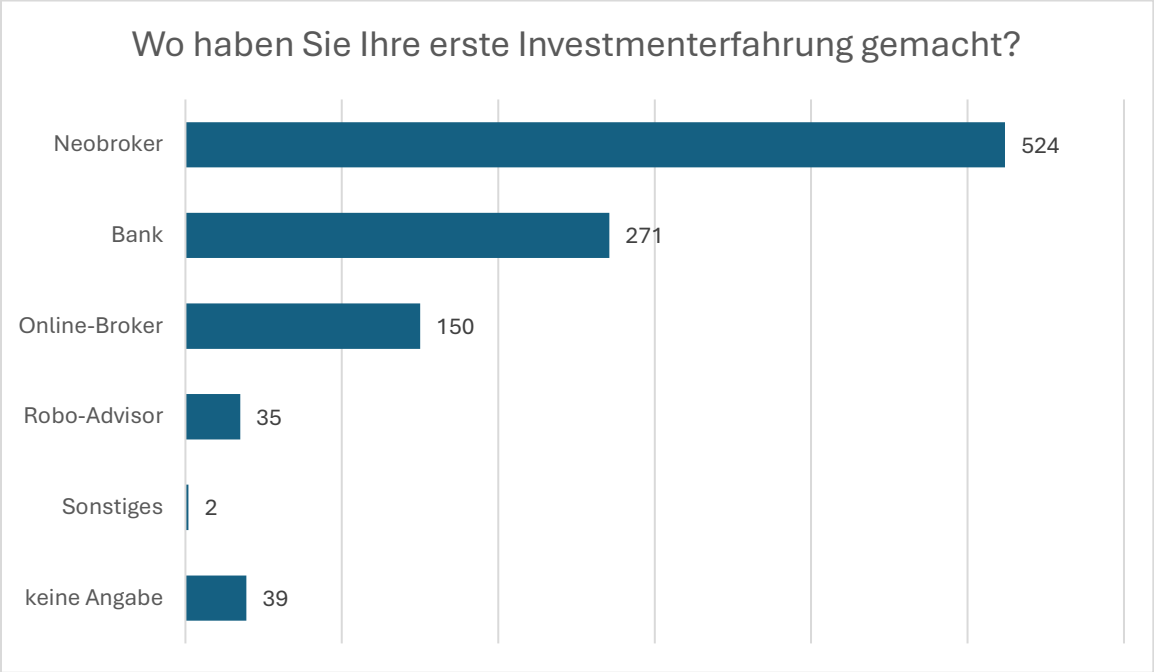


Abbildung 15: Methode erster Investments

Für 53,4 % der gültig Antwortenden war ein Neobroker der erste Zugang zu Investments. Es folgen traditionelle Banken mit 27,6 % und klassische Online-Broker mit 15,3 %. Weitere 3,6 % sammelten ihre erste Investmenterfahrung über einen Robo-Advisor, während sonstige Wege mit 0,2 % kaum eine Rolle spielten.

Danach wurde gefragt, seit wann die Teilnehmer:innen aktiv über eine Trading- oder Neobroker-App investieren. Vier Personen machten hierzu keine Angabe. Die größte Gruppe nutzt eine solche App seit zwei bis fünf Jahren (48,6 %). Weitere 22,0 % investieren seit sechs bis zehn Jahren und 18,2 % seit mehr als zehn Jahren über entsprechende Anwendungen. Mit 11,2 % ist der Anteil der Personen am geringsten, die erst seit einem Jahr aktiv über eine Trading-App investieren.

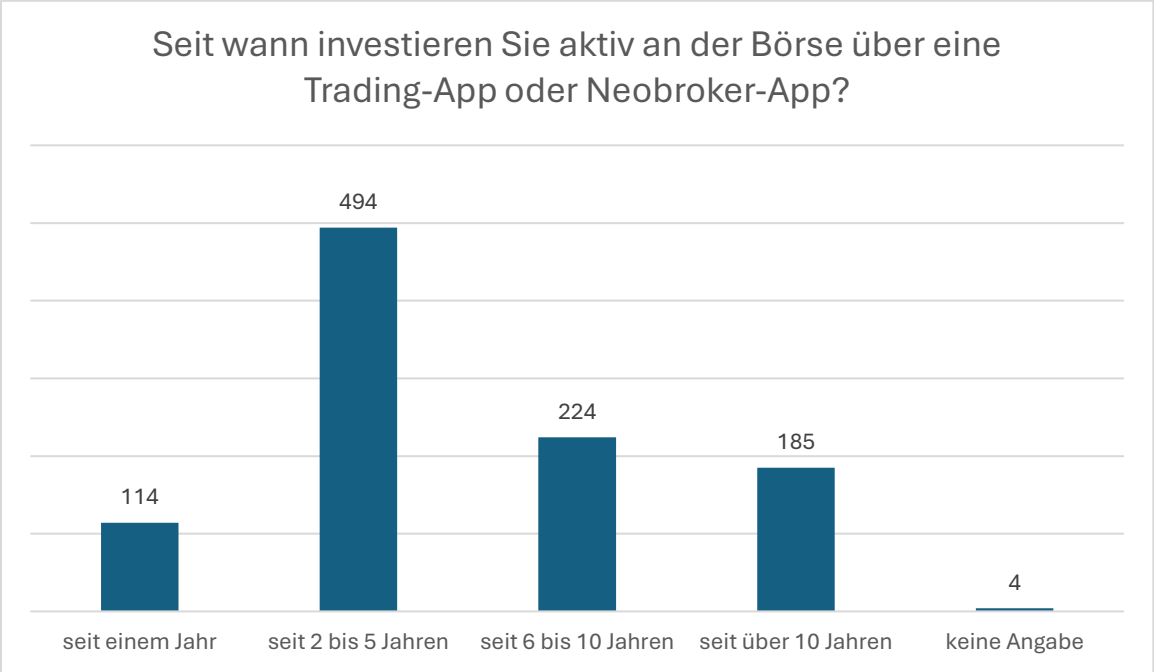


Abbildung 16: Seit wann investieren Teilnehmer:innen über Neobroker

Die Antworten zur Handelsfrequenz über Trading-Apps zeigen ebenfalls einen Schwerpunkt auf monatlichen Transaktionen. 16 Personen machten hierzu keine auswertbare Angabe. 48,4 % der gültig Antwortenden handeln ungefähr einmal im Monat, 22,2 % einmal pro Woche und 20,6 % seltener als einmal monatlich. Täglich handeln 8,9 %.

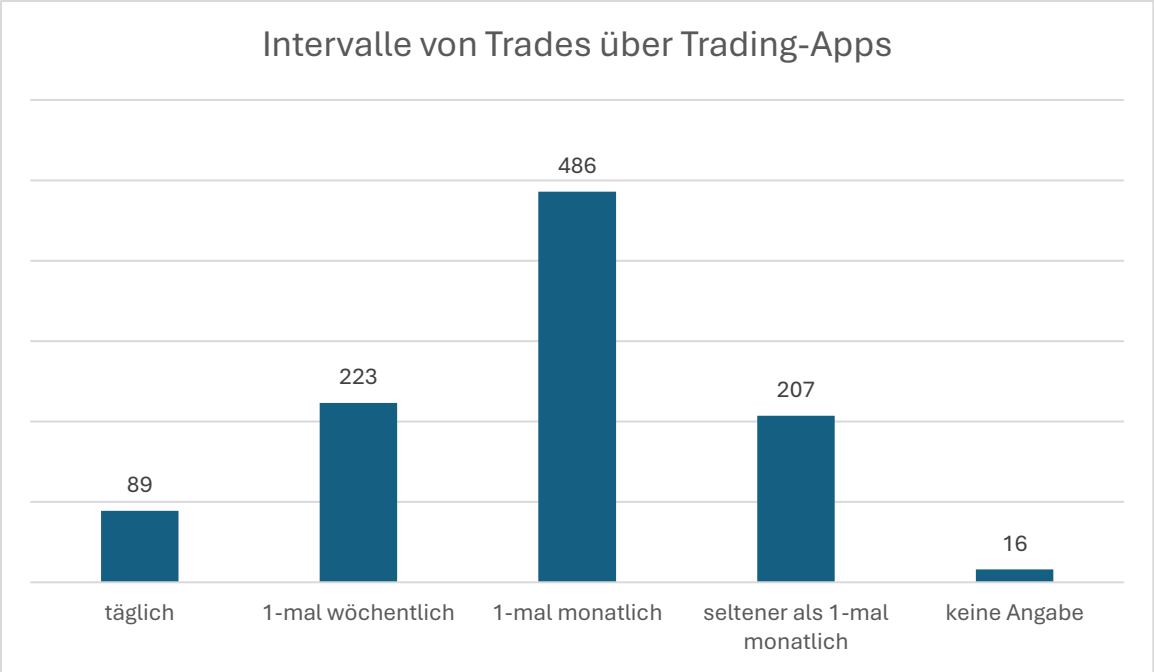


Abbildung 17: Trade-Intervalle über Trading-Apps

Anschließend wurde ermittelt, wie viel Geld die Befragten durchschnittlich pro Anlage, Trade oder Sparplan investieren. Zu dieser Frage lagen 794 gültige Antworten vor.



Abbildung 18: Durchschnittliche Höhe von Investments

Mit 23,2 % investiert die größte Gruppe durchschnittlich zwischen 201 und 500 Euro. Die zweitgrößte Gruppe setzt mit 16,6 % höchstens 50 Euro ein. Es folgen Beträge zwischen 501 und 1.000 Euro mit 13,9 %, zwischen 51 und 100 Euro mit 12,3 % sowie zwischen 101 und 200 Euro mit 12,0 %. Weitere 8,3 % investieren durchschnittlich zwischen 2.001 und 5.000 Euro und 7,4 % zwischen 1.001 und 2.000 Euro. Mehr als 5.000 Euro pro Anlage, Trade oder Sparplan setzen 6,3 % ein.

Ergänzend wurde gefragt, welchen Anteil ihres monatlichen Einkommens die Teilnehmer:innen für Investments verwenden. Hierzu lagen 899 gültige Antworten vor.

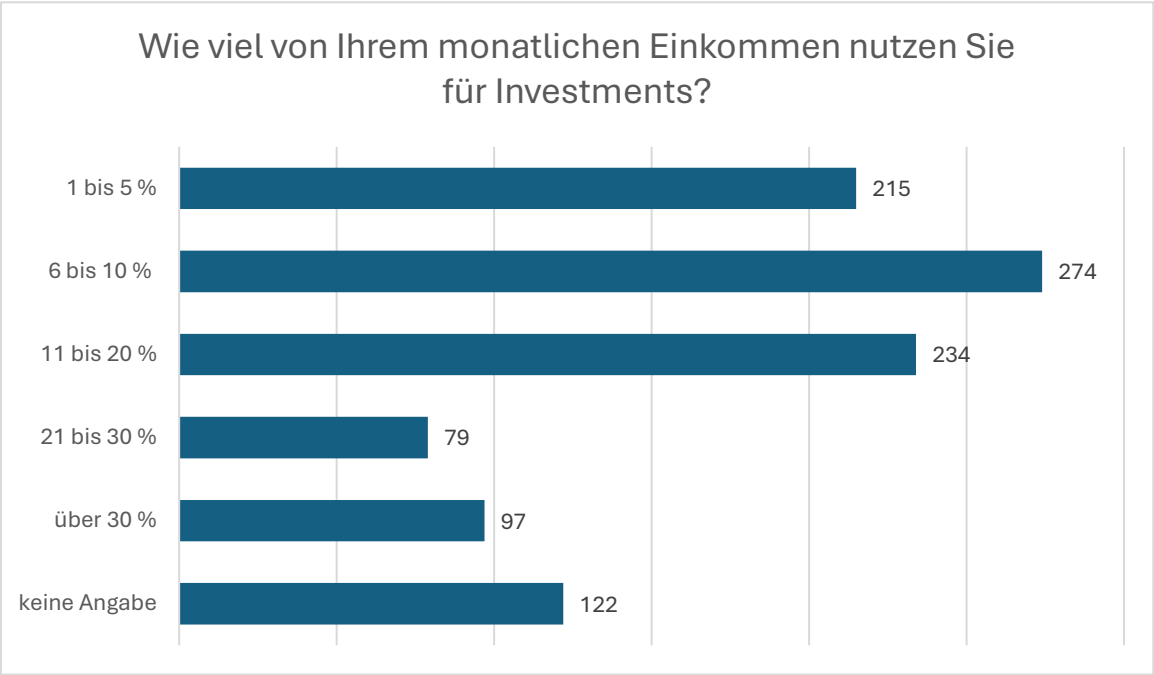


Abbildung 19: Höhe des für Trades genutzten Einkommens

Insgesamt investieren 80,4 % höchstens 20 % ihres monatlichen Einkommens und halten sich damit an den weit verbreiteten Expertenrat, nicht mehr als dies für Investments auszugeben.

Mit 30,5 % bildet die Gruppe, die zwischen 6 und 10 % ihres Einkommens investiert, den größten Anteil. Weitere 26,0 % verwenden zwischen 11 und 20 %, während 23,9 % lediglich 1 bis 5 % einsetzen. Einen Anteil zwischen 21 und 30 % investieren 8,8 %. Mehr als 30 % ihres monatlichen Einkommens verwenden 10,8 % der gültig Antwortenden.

Anschließend wurde abgefragt, aus welchen Gründen sich die Teilnehmer:innen für die Nutzung von Neobroker-Trading-Apps entschieden haben. Neun Personen machten keine auswertbare Angabe und wurden bei der Prozentberechnung nicht berücksichtigt.

Mit 75,5 % ist das günstige Trading beziehungsweise die niedrige Gebührenstruktur der am häufigsten genannte Entscheidungsgrund. Es folgen die einfache Bedienung und der schnelle Einstieg mit 66,2 % sowie der flexible Zugriff per Smartphone mit 64,7 %. Empfehlungen aus dem Freundes- oder Familienkreis spielten für 25,8 % eine Rolle.

Empfehlungen über Social Media oder durch Influencer:innen wurden von 11,3 % genannt.

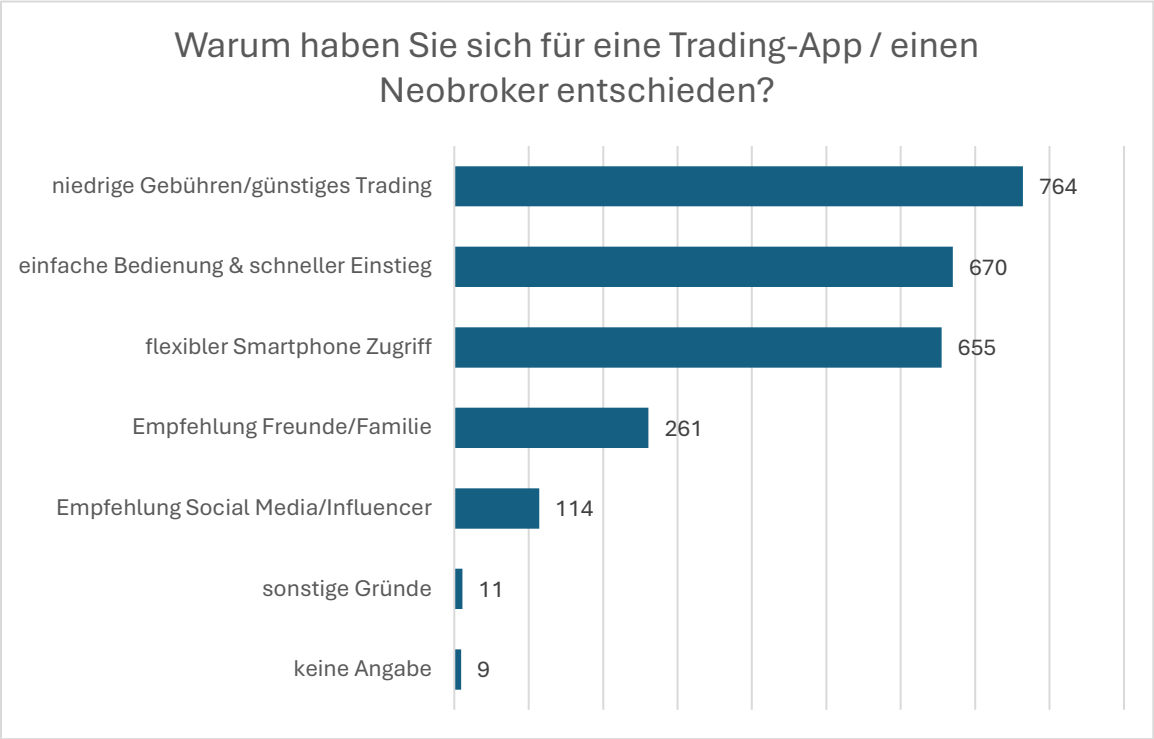


Abbildung 20: Beweggründe für Neobroker-Nutzung

Die Frage gab den Teilnehmer:innen unter der Option „sonstige Gründe“ die Möglichkeit, eine eigene Antwort zu verfassen. 6 der ursprünglich 17 in Textform angegebenen Antworten wurden für diese Auswertung bestehenden Kategorien zugeordnet, was in dem Diagramm bereits berücksichtigt wurde. Zu diesen gehören:

Niedrige Gebühren/günstiges Trading (2 Nennungen ergänzt)

- Ich will keine Provisionen zahlen und selbst verantwortlich sein
- Günstig und gutes Girokonto

Flexibler Smartphone-Zugriff (2 Nennungen ergänzt)

- Banking App beinhaltet die Funktion
- Flexibel

Einfache Bedienung & schneller Einstieg (2 Nennungen ergänzt)

- Kein Menschenkontakt
- Bessere live Daten [sic]

Die restlichen 11 Antworten konnten zu den folgenden drei ergänzenden Kategorien zusammengefasst werden:

Finanzielle Anreize (6 Nennungen)

- Gute Zinsen
- Attraktive Zinsen direkt an den Kunden
- Stabile und hohe Zinsen auf Cash-Reserven
- Boni
- Prämie
- Startguthaben

Passende Portfolio- & Investmentziele (4 Nennungen)

- Große Auswahl an Produkten
- Verteilung des Geldes
- Vorsorge für das Alter
- erfolgsversprechend

Institutionelle Empfehlung/geprüfter Fachrat (1 Nennung)

- Stiftung Warentest Finanzen

Es folgte die Frage, ob sich das Investmentverhalten der Teilnehmer:innen durch die Nutzung einer Neobroker- oder Trading-App verändert hat. 24 Personen machten hierzu keine auswertbare Angabe und wurden bei der Prozentberechnung nicht berücksichtigt.

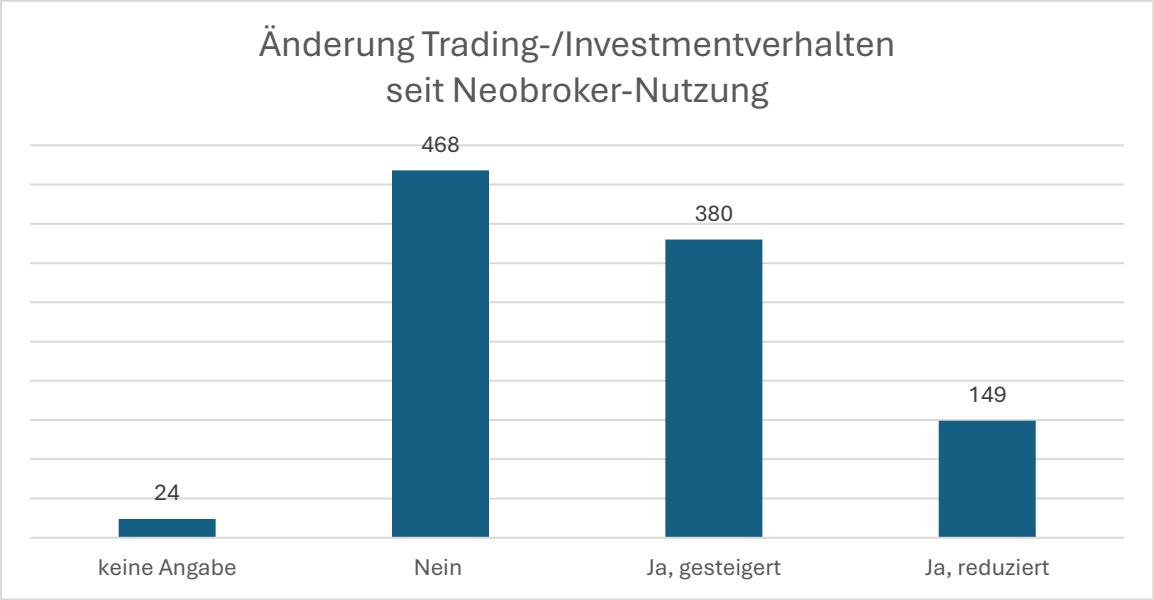


Abbildung 21: Änderungen im Investmentverhalten seit Neobroker-Nutzung

Unter den gültig Antwortenden bestätigten 53,1 % eine Veränderung ihres Investmentverhaltens. Dabei gaben 38,1 % an, seit der Nutzung mehr zu investieren

oder zu handeln, während 14,9 % ihr Investmentverhalten reduziert hatten. Bei 46,9 % hatte sich das Verhalten nach eigener Einschätzung nicht verändert.

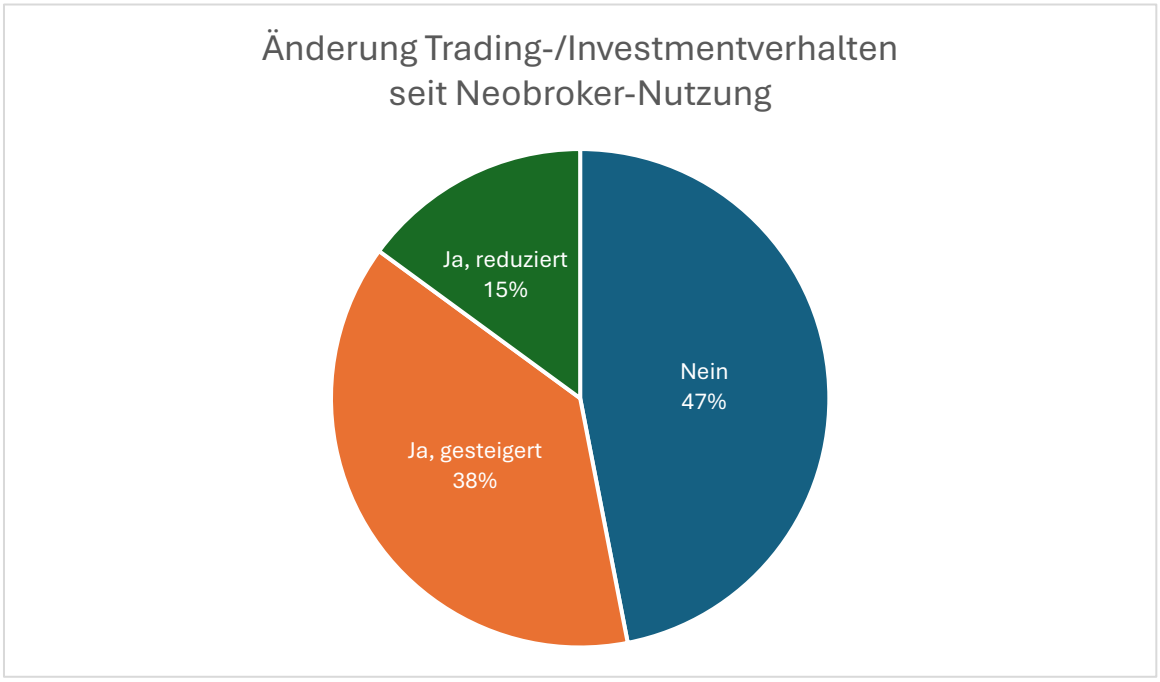


Abbildung 22: Prozentuale Aufteilung von Änderungen im Investmentverhalten

Die 529 Personen, die eine Veränderung wahrgenommen hatten, wurden anschließend gefragt, nach welcher Nutzungsdauer diese erstmals spürbar geworden war. 47 Personen machten hierzu keine auswertbare Angabe. Bei der Mehrheit trat die Veränderung innerhalb der ersten zwei Jahre auf: 37,8 % bemerkten sie nach sechs bis zwölf Monaten, 23,4 % nach ein bis zwei Jahren und 21,4 % bereits innerhalb der ersten sechs Monate. Weitere 12,4 % nahmen eine Veränderung nach zwei bis fünf Jahren wahr, während sie bei 5,0 % erst nach mehr als fünf Jahren eintrat.

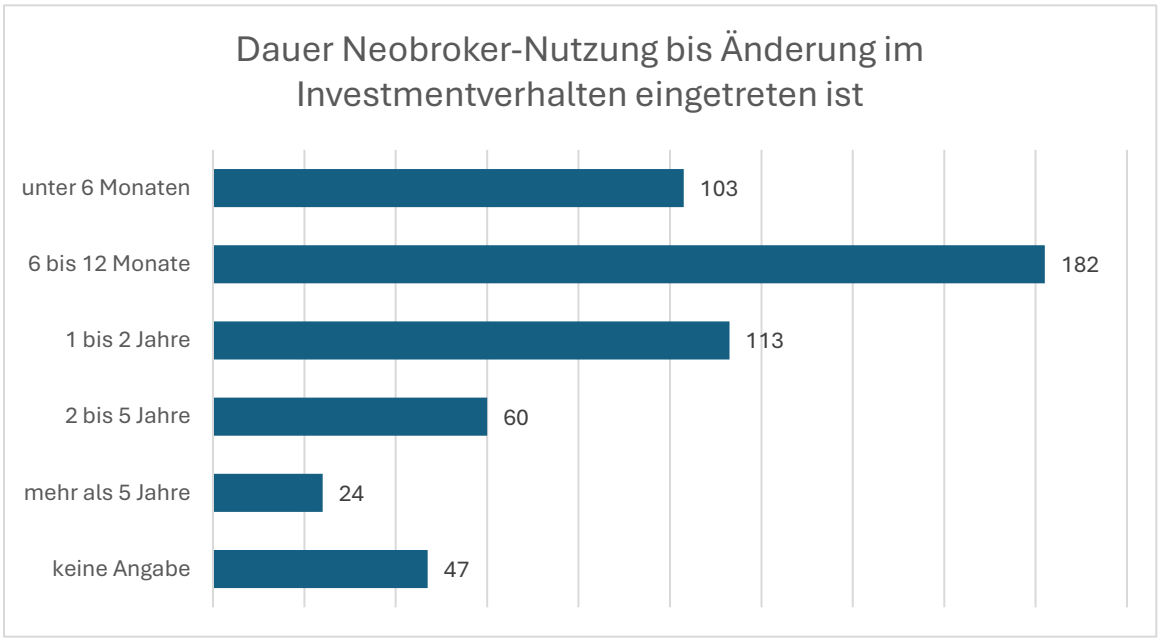


Abbildung 23: Zeitspanne Neobroker-Nutzung vor eingetretenen Änderungen

Mit der Frage „Welche Auswirkungen hat die Nutzung des Neobrokers / der Trading-App auf Ihr Trading- / Investmentverhalten?“ wurde schließlich erfragt, wie sich diese Änderungen bemerkbar machen. Die Frage diente zudem als Gegenprüfung der Einschätzung, ob eine Änderung im Investmentverhalten aufgetreten ist, und wandte sich wieder an alle 1.021 Teilnehmer:innen. 13 Personen wählten „weiß nicht/keine Angabe“ und wurden bei der Berechnung der Anteile nicht berücksichtigt.

Am häufigsten nannten die gültig Antwortenden regelmäßige Investments, etwa durch Sparpläne, mit 44,2 %. Weitere 40,5 % informieren sich seit der Nutzung stärker über Finanzthemen. 29,2 % treffen Entscheidungen schneller oder spontaner, während 28,5 % häufiger handeln als zuvor. Bessere Ergebnisse berichten 27,7 %, sicherere Entscheidungen 26,0 % und eine höhere Risikobereitschaft 15,3 %. Keine Auswirkungen stellten 10,5 % fest, während 8,6 % angaben, seit der Nutzung mehr Verluste erlitten zu haben. Sonstige Auswirkungen wurden von 0,4 % genannt.

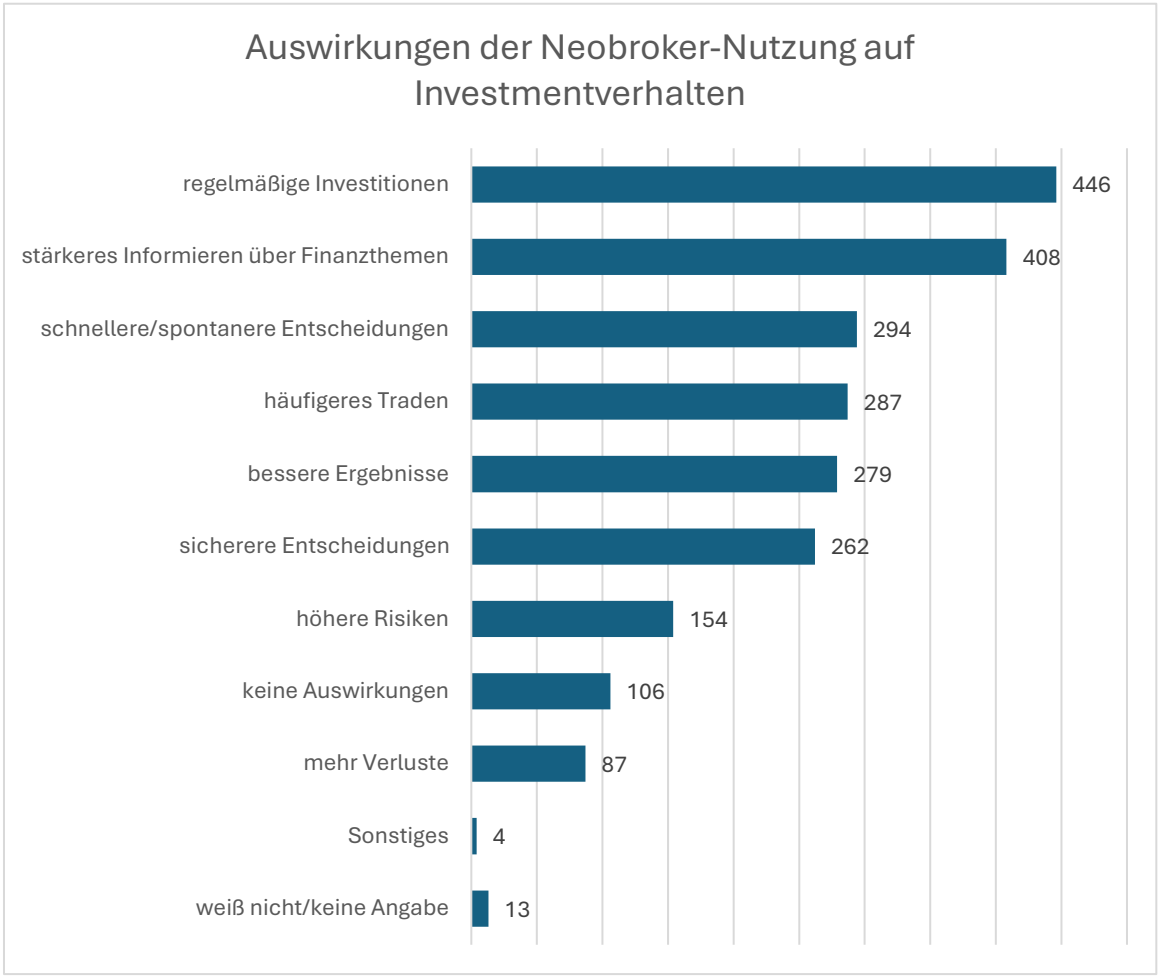


Abbildung 24: Auswirkungen Neobroker-Nutzung auf Investmentverhalten

7 Personen hatten ursprünglich „Sonstiges“ angegeben. 3 der 6 in Textform angegebenen Auswirkungen wurden für diese Auswertung erneut bestehenden Kategorien zugeordnet und in dem Diagramm bereits verrechnet.

Schnellere/spontanere Entscheidungen (2 Nennungen ergänzt)

- Ich kann kleinere Spontankäufe mit günstiger Ordergebühr tätigen und fühle mich somit flexibler.
- ich reagiere schneller auf Marktbewegungen

Mehr Verluste (1 Nennung ergänzt)

- Hat dafür gesorgt, dass ich mit Zocken viel Geld verloren habe. Seitdem bin ich nur bei ETFs

Die restlichen drei Antworten konnten zu den folgenden zwei ergänzenden Kategorien zusammengefasst werden:

Erweiterung auf andere Anlageklassen (2 Nennungen)

- Immobilien
- Immobilienkauf

Kostenersparnis (1 Nennung)

- Man spart an hoheGebühren [sic]

Anders als zuvor 468 Personen, die keine Änderung in ihrem Verhalten gesehen haben, gaben hier nur 106 Befragte (10,5 %) an, dass sie keine Auswirkungen gespürt hatten. Eine Deckung der Teilnehmer:innen, die bei beiden Fragen keine Änderung angegeben haben, trifft nur bei 89 Personen zu.

Mit Ausschluss der Personen, die „weiß nicht“ angegeben haben, bleiben hier 376 der zuvor 468 Befragten übrig, die in der letzten Frage keine Änderung in ihrem Investmentverhalten angegeben hatten, jetzt aber Änderungen angeben. Diese teilen sich wie folgt auf:

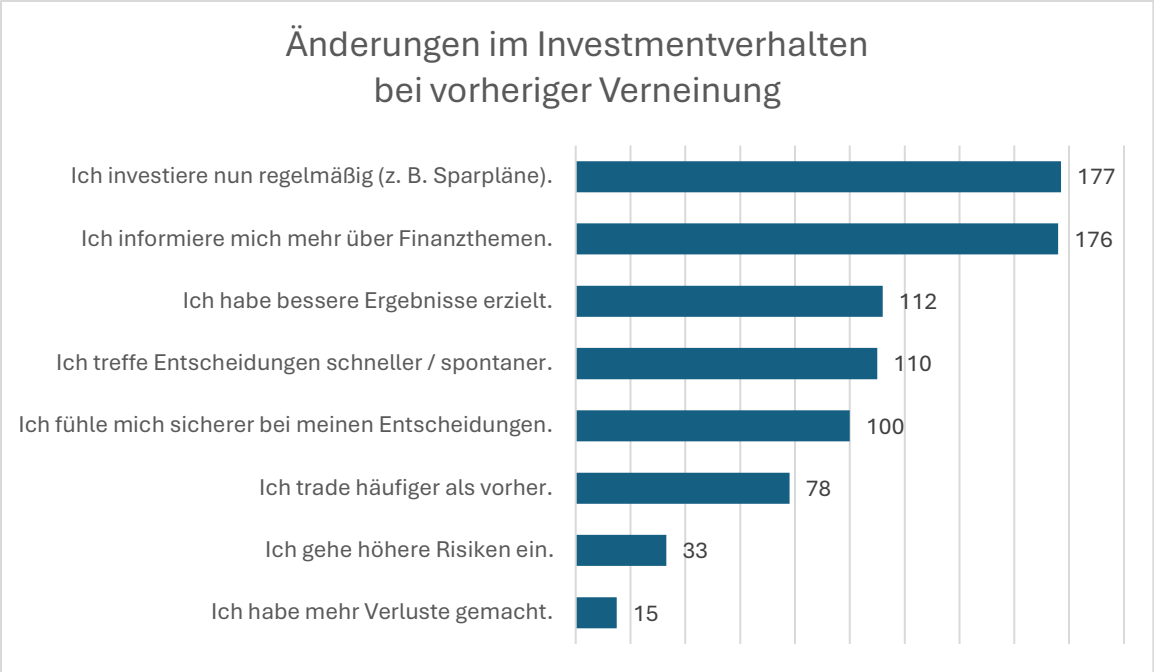


Abbildung 25: Änderungen bei Personen, die diese zuvor verneint haben

Warum diese 376 Personen zuvor keine Änderung angegeben hatten, diese hier aber spezifizieren, ist unklar. Womöglich hat ihnen erst die vorgegebene Auswahl möglicher Änderungen vor Augen geführt, wie diese aussehen können, und dass dies doch für sie zutrifft.

Umgekehrt gaben 14 Personen zunächst an, dass die Neobroker-Nutzung ihr Tradingverhalten verändert habe, wählten in der späteren Frage jedoch die Antwort, die App habe keine Auswirkungen. Fünf dieser Befragten hatten zuvor eine Verringerung und neun eine Steigerung ihres Investmentverhaltens angegeben. Es bestehen also Unsicherheiten in der Selbstwahrnehmung einiger Teilnehmer:innen.

Frage 16 untersuchte, ob die Teilnehmer:innen bereits eine Investmententscheidung über einen Neobroker bereut hatten. 15 Personen machten hierzu keine auswertbare Angabe, sodass 1.006 gültige Antworten vorlagen.

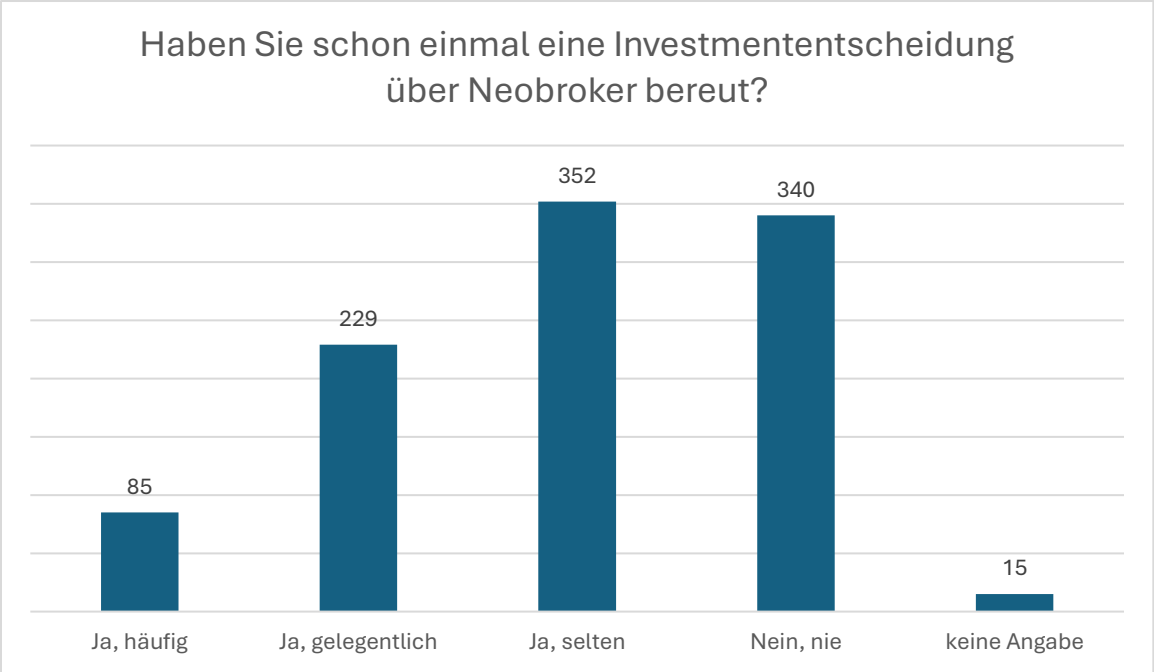


Abbildung 26: Reue über Investmententscheidungen über Neobroker

Insgesamt hatten 66,2 % mindestens einmal eine solche Entscheidung bereut. Am häufigsten wurde die Antwort „Ja, selten“ mit 35,0 % gewählt, gefolgt von „Ja, gelegentlich“ mit 22,8 %. Weitere 8,4 % bereuten ihre Anlageentscheidungen häufig. Dagegen gaben 33,8 % an, bisher keine Investmententscheidung über einen Neobroker bereut zu haben.

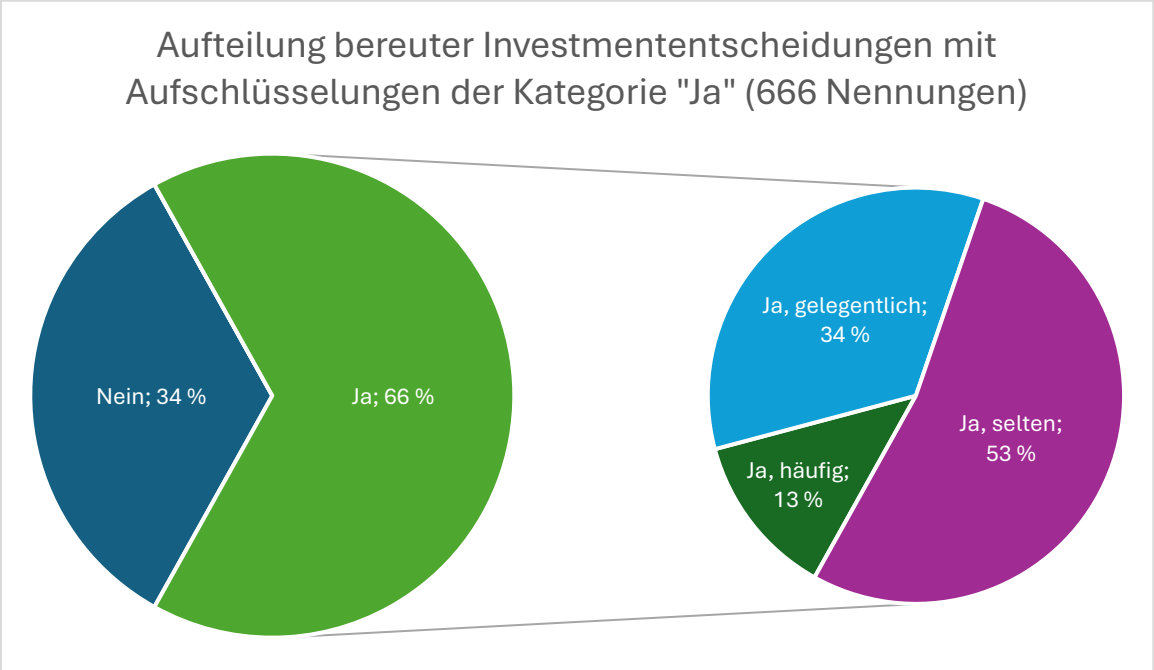


Abbildung 27: Prozentuale Aufteilung der Reue über Investmententscheidungen

Die 666 Personen, die mindestens eine Entscheidung bereut hatten, wurden anschließend nach den Gründen gefragt. Hierzu lagen 655 gültige Antworten vor. Da

mehrere Gründe ausgewählt werden konnten, summieren sich die Prozentwerte auf mehr als 100 %.

Am häufigsten nannten die Befragten einen zu späten Kauf oder Verkauf mit 47,2 %. Es folgen zu impulsive Entscheidungen mit 43,7 % und ein zu hohes eingegangenes Risiko mit 35,9 %. Zu wenig Wissen oder ein unzureichendes Verständnis gaben 28,7 % als Grund an. Weitere 25,2 % bereuten eine Entscheidung, weil sie falschen Informationen oder Trends gefolgt waren. Sonstige, nicht näher spezifizierte Gründe wurden von 4,6 % genannt.

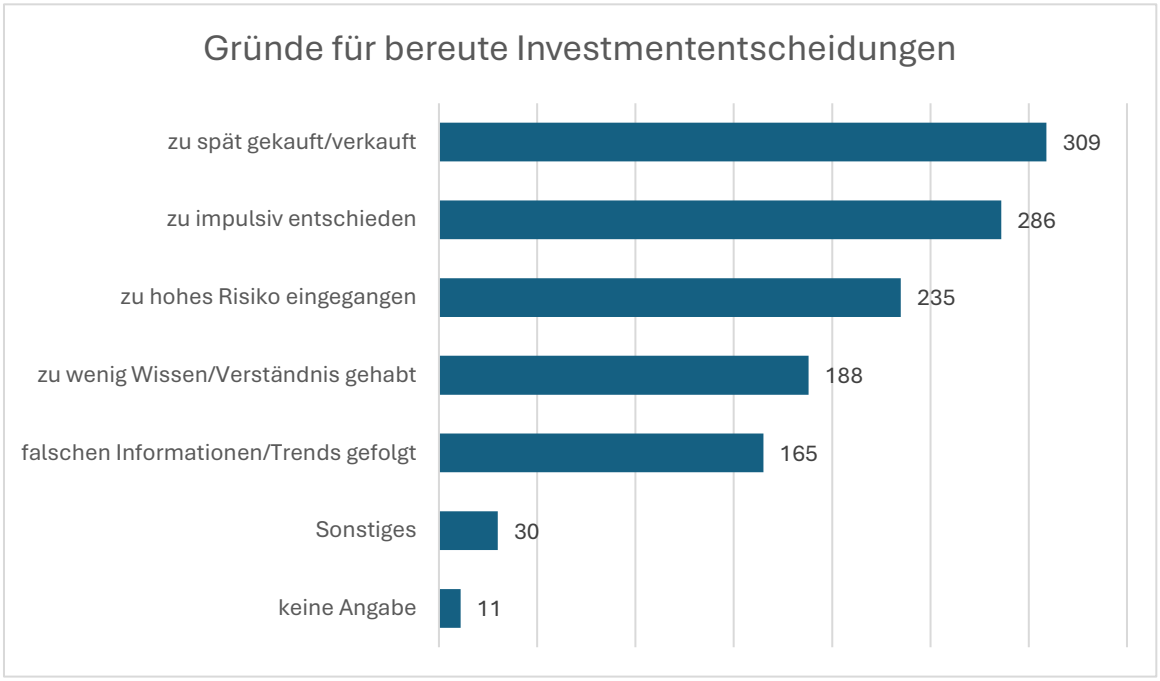


Abbildung 28: Gründe für bereute Investmententscheidungen

Trotz der weit verbreiteten Reue über einzelne Entscheidungen entwickelte sich das gesamte Trading-App-Portfolio bei der Mehrheit der Befragten positiv.

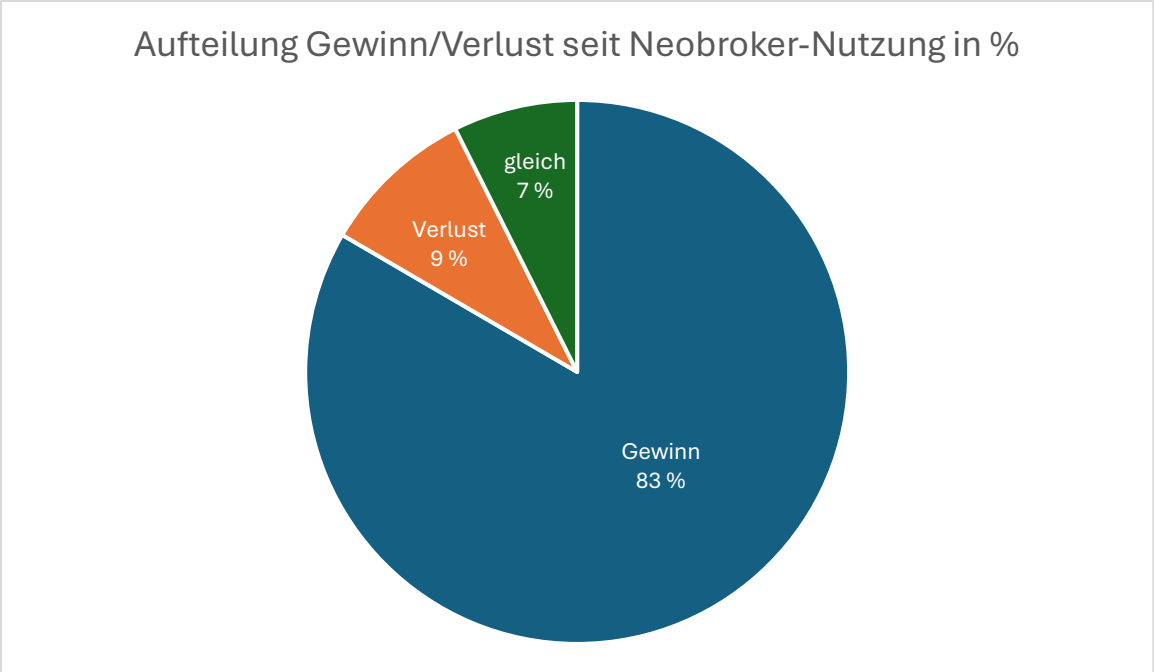


Abbildung 29: Prozentuale Aufteilung Gewinne/Verluste seit Neobroker-Nutzung

Nach Ausschluss von 75 Antworten mit „weiß nicht“ oder „keine Angabe“ lagen 946 gültige Einschätzungen vor. Von diesen berichteten 83,4 % einen Gewinn, 7,4 % eine ungefähr gleichbleibende Portfolioentwicklung und 9,2 % einen Verlust.

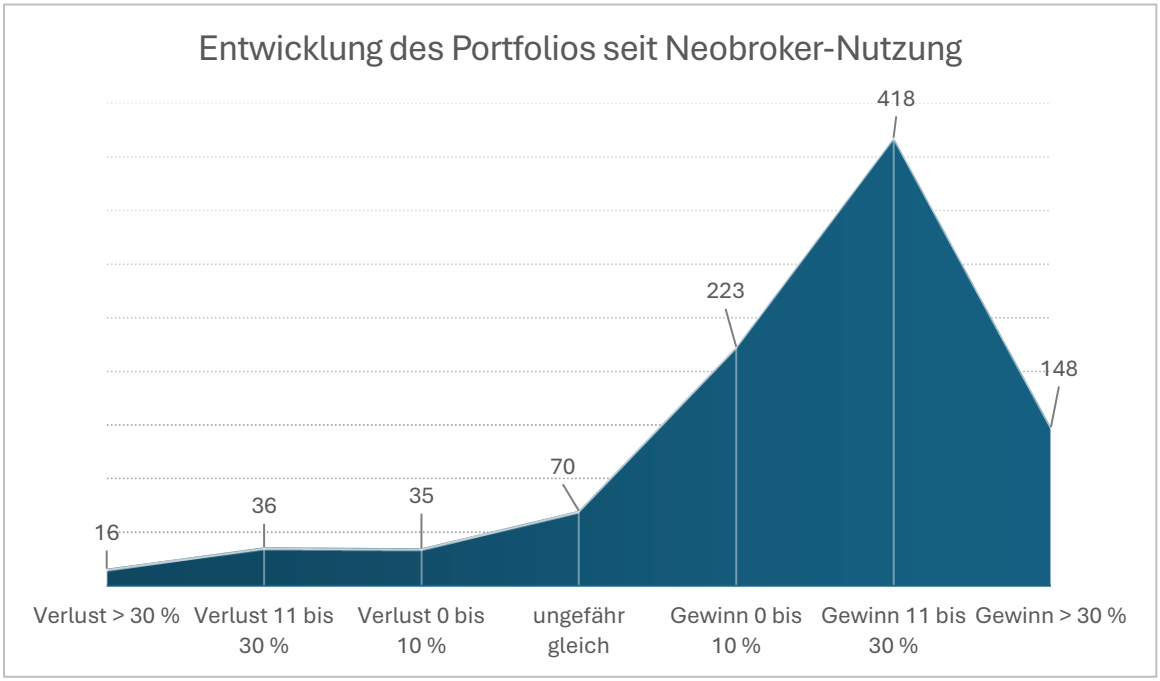


Abbildung 30: Portfolio-Entwicklung seit Neobroker-Nutzung

Innerhalb der Gewinnkategorie erzielten 53,0 % einen Zuwachs zwischen 11 und 30 %. Weitere 28,3 % berichteten einen Gewinn von bis zu 10 %, während 18,8 % eine Wertsteigerung von mehr als 30 % angaben.

Unter den Befragten mit einer negativen Portfolioentwicklung erlitten 41,4 % einen Verlust zwischen 11 und 30 %. Nahezu ebenso häufig waren Verluste von bis zu 10 % mit 40,2 %. Einen Verlust von mehr als 30 % meldeten 18,4 % der Personen mit negativer Portfolioentwicklung.

Bezogen auf alle gültigen Antworten entsprechen die einzelnen Verlustkategorien 3,8 % für Verluste zwischen 11 und 30 %, 3,7 % für Verluste bis zu 10 % und 1,7 % für Verluste von mehr als 30 %.

In Frage 19 wurde untersucht, ob die Teilnehmer:innen bereits investiert hatten, ohne das jeweilige Produkt vollständig zu verstehen. 20 Personen machten hierzu keine auswertbare Angabe, sodass 1.001 gültige Antworten vorlagen.

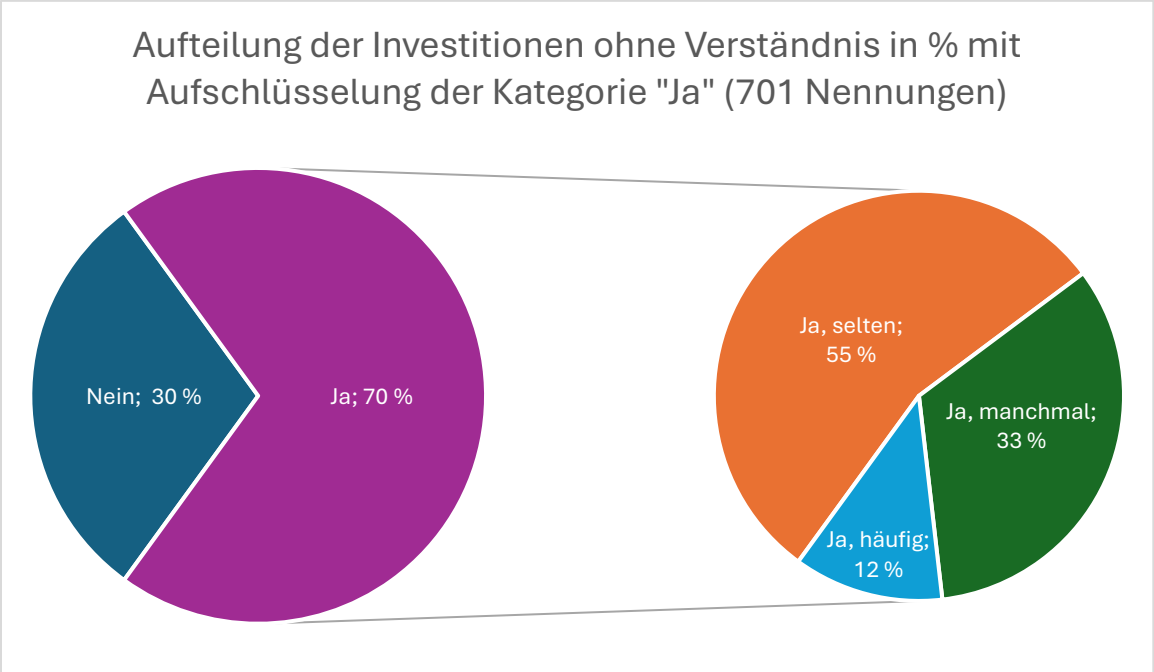


Abbildung 31: Prozentuale Aufteilung der Häufigkeit von Investitionen ohne Verständnis des Produkts

Von den gültig Antwortenden hatten 70,0 % mindestens einmal ohne vollständiges Produktverständnis investiert. Dabei wählten 38,4 % die Antwort „Ja, selten“, 23,4 % „Ja, manchmal“ und 8,3 % „Ja, häufig“. Weitere 30,0 % gaben an, bislang nur in Produkte investiert zu haben, die sie vollständig verstanden.

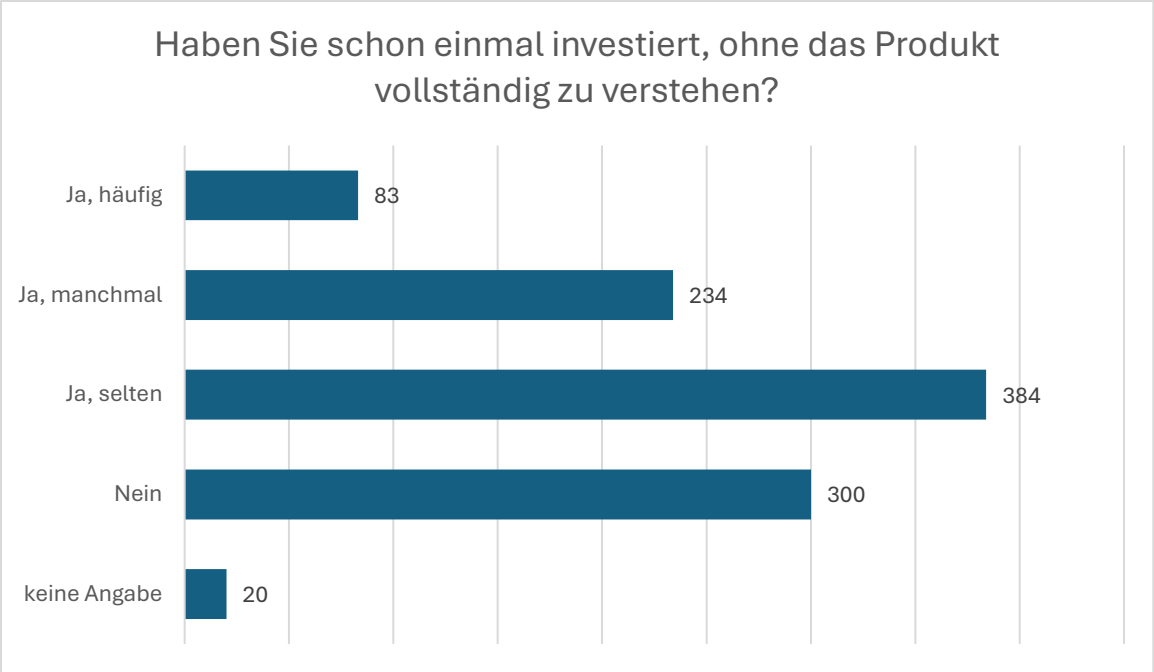


Abbildung 32: Häufigkeit von Investitionen ohne Verständnis des Produkts

Innerhalb der Gruppe, die bereits ohne vollständiges Verständnis investiert hatte, entfielen 54,8 % auf „Ja, selten“, 33,4 % auf „Ja, manchmal“ und 11,8 % auf „Ja, häufig“.

Anschließend wurde gefragt, ob die Teilnehmer:innen durch einen Trade über einen Neobroker bereits endgültig Geld verloren hatten. 32 Personen machten hierzu keine auswertbare Angabe. Unter den 989 gültig Antwortenden bestätigten 56,6 % eine solche Verlusterfahrung, während 43,4 % bislang keinen endgültigen Verlust über die Trading-App erlitten hatten.

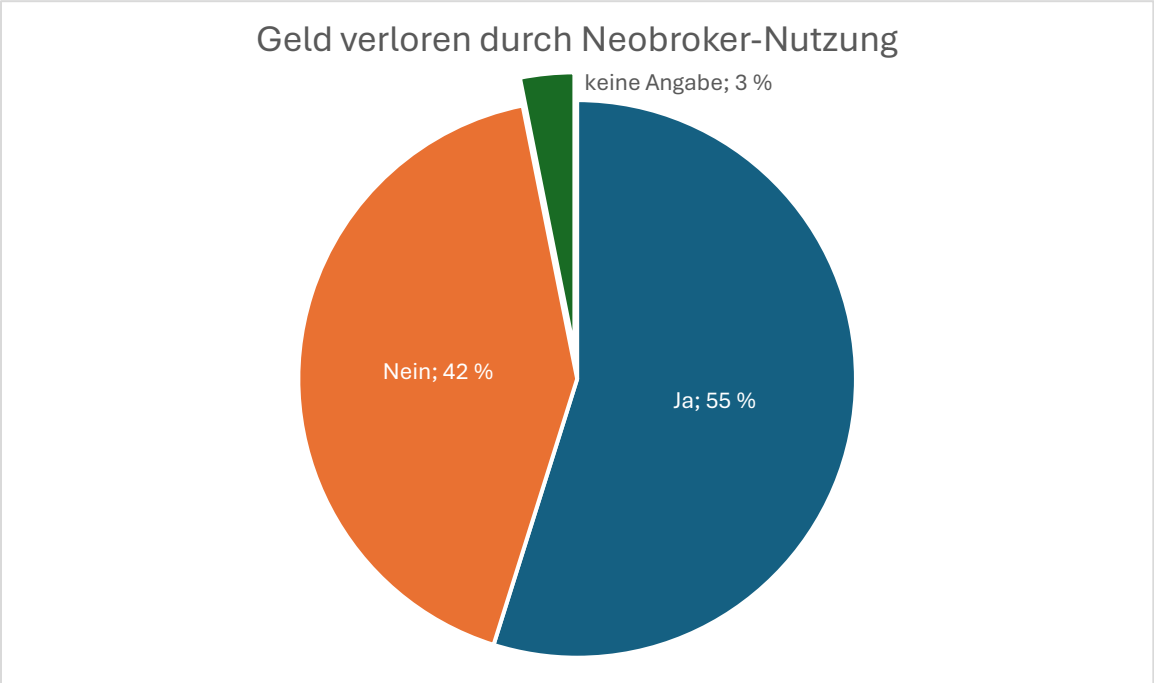


Abbildung 33: Wurde Geld über Neobroker-Investments verloren

Die 560 Personen mit Verlusterfahrung wurden anschließend nach der Höhe ihres bislang größten Verlusts gefragt. Nach Ausschluss von 26 nicht auswertbaren Antworten lagen 534 gültige Angaben vor. Bei 42,9 % betrug der höchste Verlust bis zu 500 Euro. Weitere 35,6 % verloren zwischen 501 und 2.000 Euro, 18,2 % zwischen 2.001 und 10.000 Euro und 3,4 % mehr als 10.000 Euro.

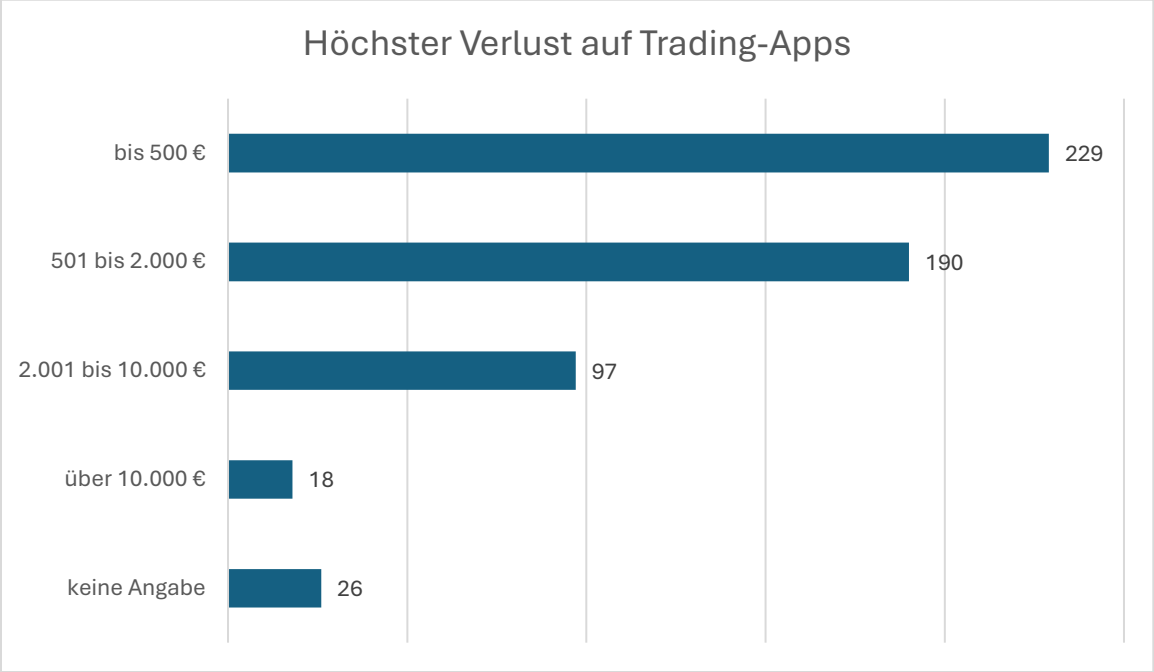


Abbildung 34: Höhe von Verlusten über Neobroker-Investments

Zusätzlich wurden die Betroffenen nach den Ursachen ihrer Verluste gefragt. Hierzu lagen 552 gültige Antworten vor. Da mehrere Gründe ausgewählt werden konnten, summieren sich die Prozentwerte auf mehr als 100 %.

Am häufigsten wurden Verluste durch Einzelaktien beziehungsweise eine unzureichende Diversifikation mit 43,3 % genannt. Es folgen das Weltgeschehen und allgemeine Marktentwicklungen mit 37,0 % sowie impulsive Entscheidungen mit 31,0 %. Kryptowährungen führten nach Einschätzung von 19,7 % zu Verlusten, Derivate beziehungsweise Hebelprodukte bei 19,0 %. Zu häufiges Trading nannten 11,6 % als Verlustursache.

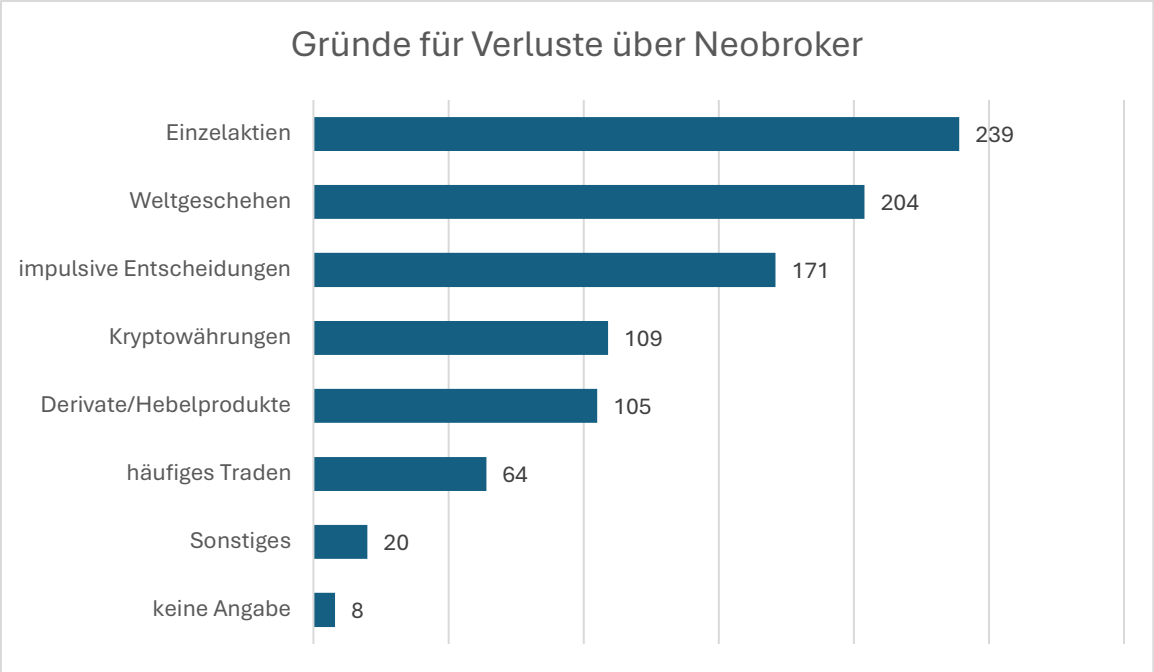


Abbildung 35: Gründe für Verluste über Neobroker

Die Option „Sonstiges“ wurde von 20 Personen gewählt. 19 von ihnen erläuterten den jeweiligen Verlustgrund in einer eigenen Textantwort. Diese lassen sich in sieben übergeordnete thematische Kategorien bündeln:

1. Betrug & Wirtschaftskriminalität (3 Nennungen)

- Wirecard Investment
- Betrug des Managements bei solar Millennium Anleihe [sic]
- Betrug [sic]

2. Insolvenz & Unternehmenspleiten (3 Nennungen)

- Insolvenz (2× genannt)
- Insolvenz der Firma

3. Hohes Risiko & mangelndes Risikomanagement (3 Nennungen)

- fehlendes Risikomanagement
- Zu hohes Risiko
- Spielgeld/Optionsscheine aber nur 50 euro [sic]

4. Timing, Erfahrungsmangel & schlechte Ratschläge (3 Nennungen)

- Zeitpunkt, Erfahrungsmangel
- Zu spät verkauft

- Folgen von Finanztipps in Zeitschriften

5. Unternehmensereignisse & Kapitalmaßnahmen (3 Nennungen)

- Klage gegen das Unternehmen
- Übernahme durch eine andere Firma
- Anleihe wurde von Emittenten früher rückbezahlt

6. Bewusste Strategieentscheidungen & geplante Verluste (2 Nennungen)

- bewusst realisierter Verlust
- Entscheidung zu anderer Anlagestrategie

7. Externe Marktmechanismen & Pech (2 Nennungen)

- Leerverkäufe
- Dumm gelaufen

Unter Frage 23 „Wie häufig treffen Sie spontane Anlageentscheidungen?“ lagen 1.014 gültige Antworten vor. Etwas mehr als die Hälfte der Befragten trifft selten oder nie spontane Anlageentscheidungen. Der gemeinsame Anteil dieser beiden Kategorien beträgt 50,9 %. Weitere 33,9 % entscheiden manchmal spontan. Nur 15,2 % gaben an, häufig oder sehr häufig spontane Anlageentscheidungen zu treffen.

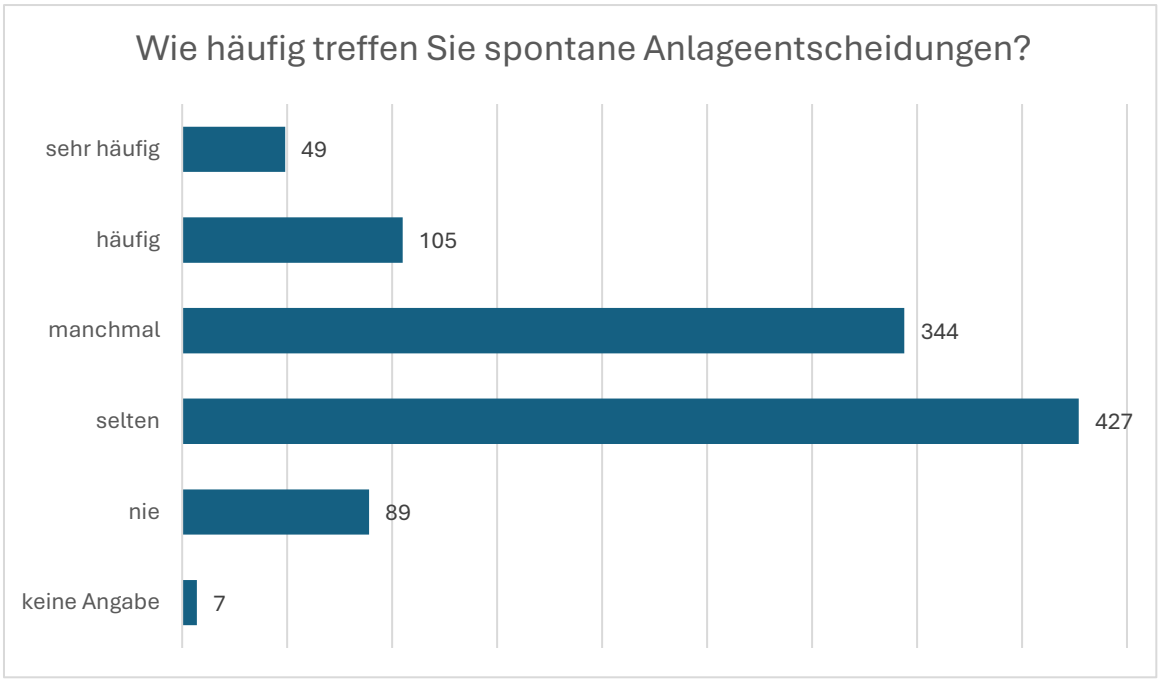


Abbildung 36: Häufigkeit spontaner Anlageentscheidungen

Anschließend wurden die Teilnehmer:innen mit ETFs gefragt, ob ihre ETF-Auswahl zu ihren Anlagezielen und ihrer Risikobereitschaft passt.

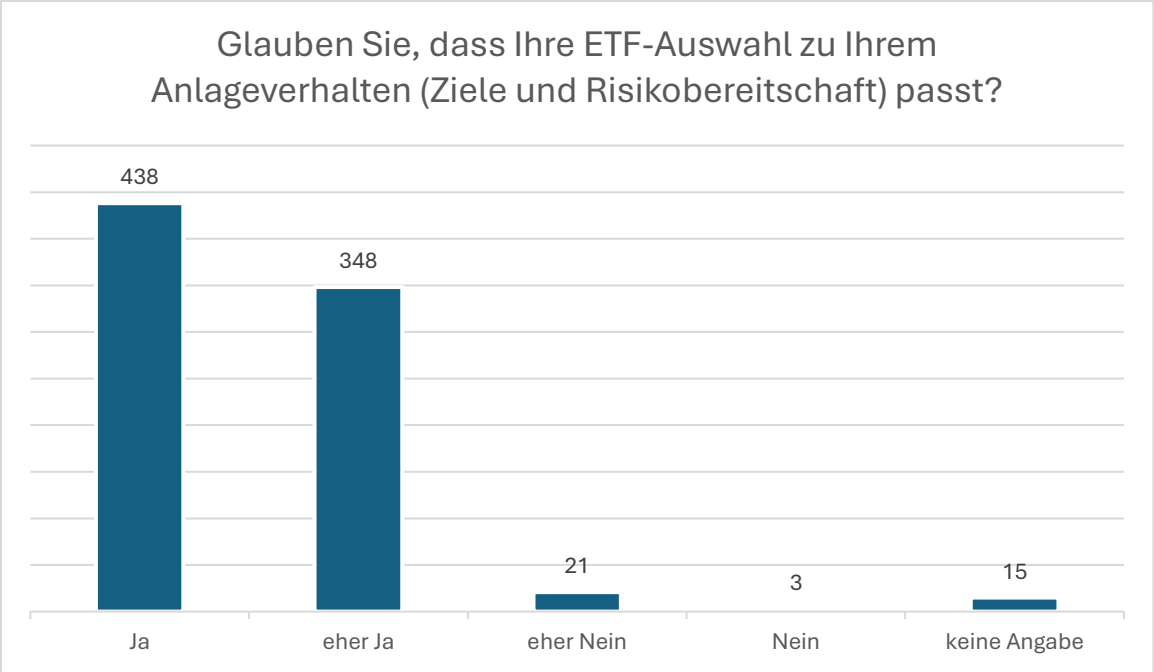


Abbildung 37: Passgenauigkeit ETF-Auswahl zu Anlagezielen

Nach Ausschluss von 15 nicht auswertbaren Antworten lagen 810 gültige Angaben vor. Mit 97,0 % hält die überwiegende Mehrheit ihre ETF-Auswahl für passend. Davon antworteten 54,1 % mit „Ja“ und 43,0 % mit „eher ja“. Lediglich 3,0 % bewerteten ihre Auswahl als eher nicht passend.

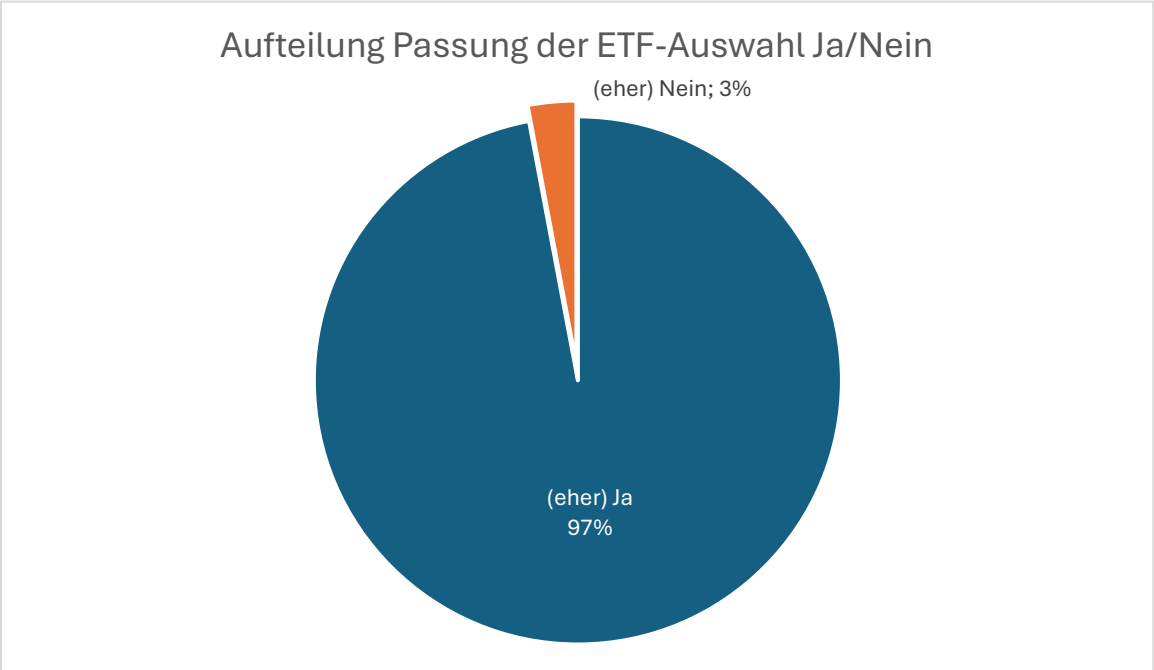


Abbildung 38: Prozentuale Aufteilung Passgenauigkeit ETF-Auswahl

Die nächste Frage behandelte die Auswahlgründe für das erste Investment über einen Neobroker. Da mehrere Antworten möglich waren, summieren sich die Prozentwerte auf mehr als 100 %. Nach Ausschluss von 29 nicht auswertbaren Antworten lagen 992 gültige Angaben vor.

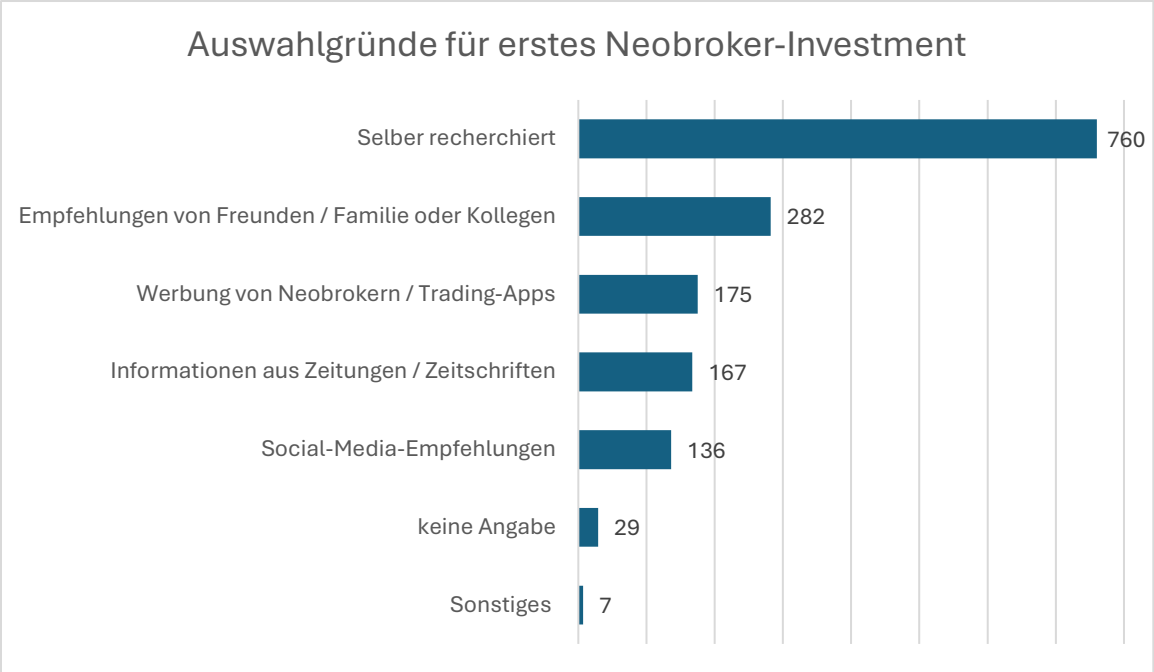


Abbildung 39: Auswahlgründe für erstes Neobroker-Investment

Mit 76,6 % war die eigene Recherche der mit Abstand häufigste Auswahlgrund. Empfehlungen aus dem Freundes-, Familien- oder Kollegenkreis spielten bei 28,4 % eine Rolle. Weitere 17,6 % nannten Werbung des Neobrokers beziehungsweise der Trading-App. Informationen aus digitalen oder gedruckten Zeitungen, Zeitschriften und Finanzportalen beeinflussten 16,8 %, während 13,7 % Empfehlungen aus sozialen Medien angaben.

Ursprünglich hatten 20 Personen die Option „Sonstiges“ gewählt. 19 davon machten eine eigene Textangabe. Ein Großteil dieser Antworten ließ sich bestehenden Kategorien zuordnen und wurde in den Prozentwerten und im Diagramm bereits berücksichtigt. Dazu gehören:

Selber recherchiert (3 Nennungen ergänzt)

- *Literatur*
- *Trends und Zukunftsfähigkeit*
- *Auf Basis meines eigenen Strategie-Setups*

Social-Media-Empfehlungen (2 Nennungen ergänzt)

- *YouTube-Videos von unterschiedlichsten Creators*
- *Finanz Influencer*

Empfehlungen von Freunden / Familie oder Kollegen (1 Nennung ergänzt)

- *Empfehlung*

Informationen aus Zeitungen / Zeitschriften (erweitert durch digitale Finanzportale als modernes Gegenstück, 7 Nennungen ergänzt)

- *Stiftung Finanztest*
- *Stiftung Warentest*
- *Spezielle Finanzwebsites*
- *Finanzwebsite*
- *Empfehlungen von Finanz-Websites*
- *Finanzfluss.de*
- *Finanztip*

Übrig bleiben die folgenden 6 Nennungen zu zwei neuen Kategorien:

Intuition, Experimente & Technologie (4 Nennungen)

- *Bauchgefühl / Gefühl:* (2× genannt)
- *Aktie gekannt gekauft zum vwrständnis* [sic]
- *KI*

Klassische Finanzberatung / Bankvertrieb (2 Nennungen)

- *Vertreter*
- *Anlageberatung der ING-DiBa*

Die folgende Frage untersuchte, wie stark verschiedene Informationsquellen die Trading-Entscheidungen der Teilnehmer:innen beeinflussen. Bewertet wurden Social Media, Nachrichten, Empfehlungen von Freunden oder Familie sowie die eigene Analyse. Je nach Einflussfaktor lagen zwischen 1.000 und 1.006 gültige Antworten vor.

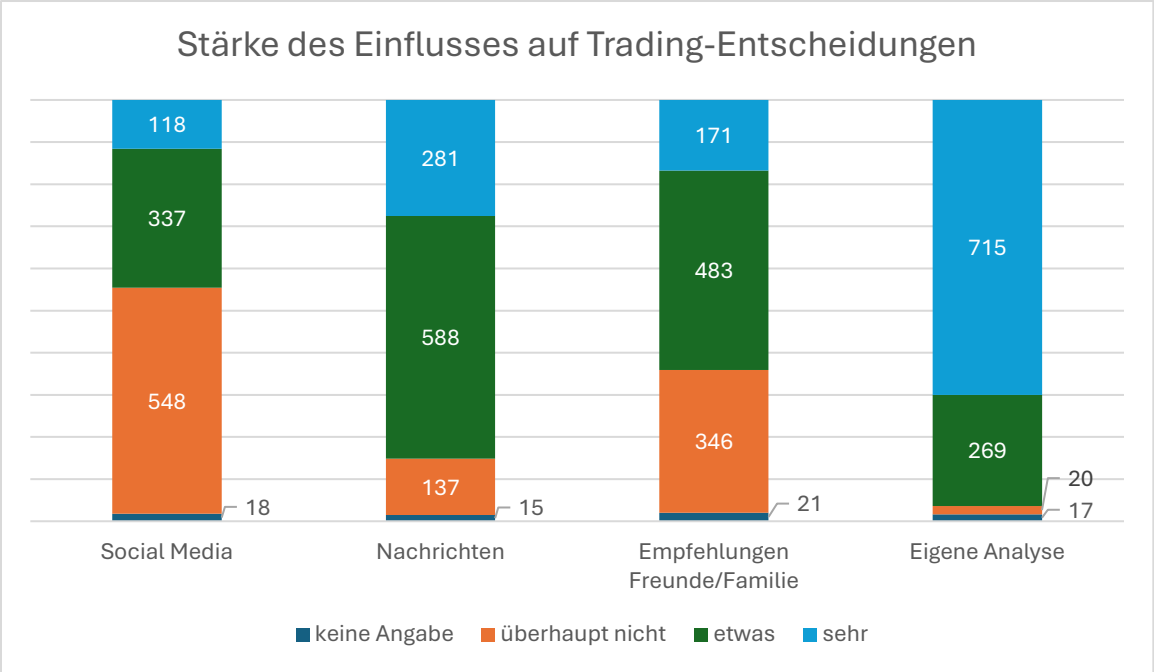


Abbildung 40: Stärke von Einflusskategorien auf Investmententscheidungen

Die eigene Analyse besitzt mit Abstand den stärksten Einfluss. 71,2 % gaben an, dass sie ihre Entscheidungen sehr stark beeinflusst. Weitere 26,8 % sehen einen gewissen Einfluss, während sich nur 2,0 % überhaupt nicht von der eigenen Analyse beeinflusst fühlen.

Nachrichten beeinflussen 27,9 % der gültig Antwortenden sehr und 58,4 % zumindest etwas. Lediglich 13,6 % schreiben Nachrichten überhaupt keinen Einfluss auf ihre Anlageentscheidungen zu.

Empfehlungen aus dem Freundes- oder Familienkreis wirken sich bei 17,1 % sehr stark und bei 48,3 % zumindest etwas auf die Entscheidungen aus. 34,6 % fühlen sich davon überhaupt nicht beeinflusst.

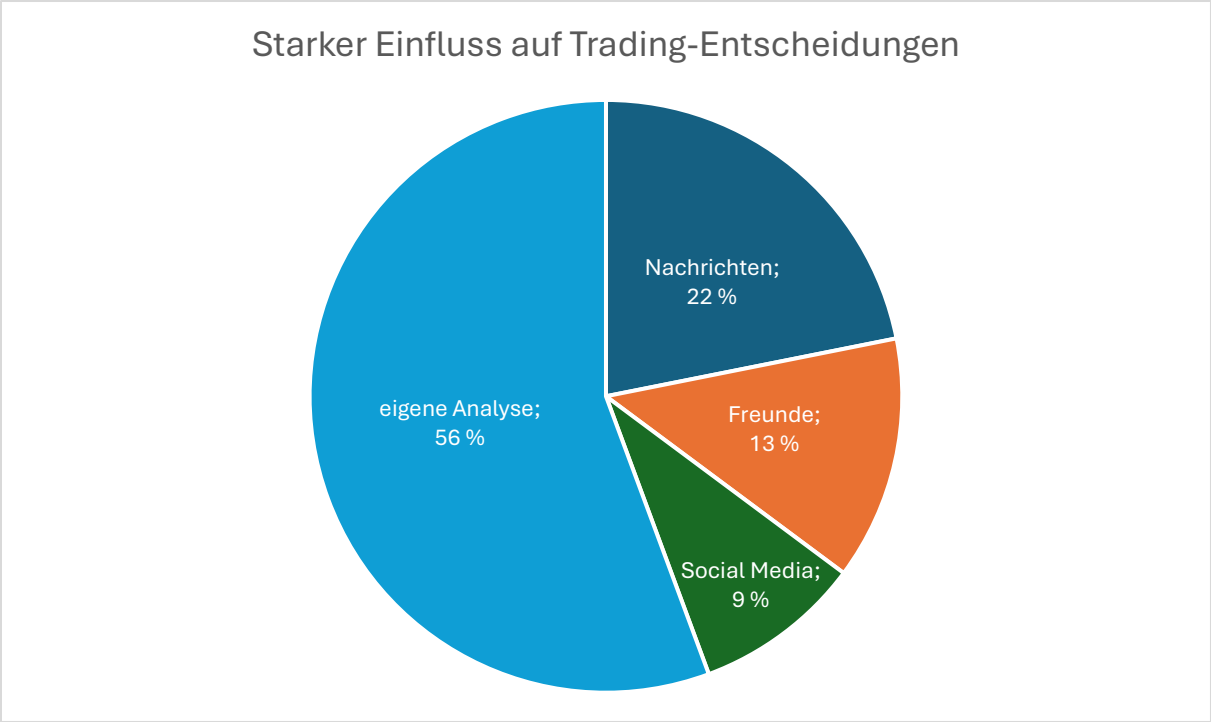


Abbildung 41: Prozentuale Aufteilung des stärksten Einflusses

Social Media besitzt im Vergleich den geringsten Einfluss. 11,8 % bewerten den Einfluss als sehr stark und 33,6 % als zumindest etwas vorhanden. Mit 54,6 % gibt mehr als die Hälfte an, dass Social Media ihre Trading-Entscheidungen überhaupt nicht beeinflusst.

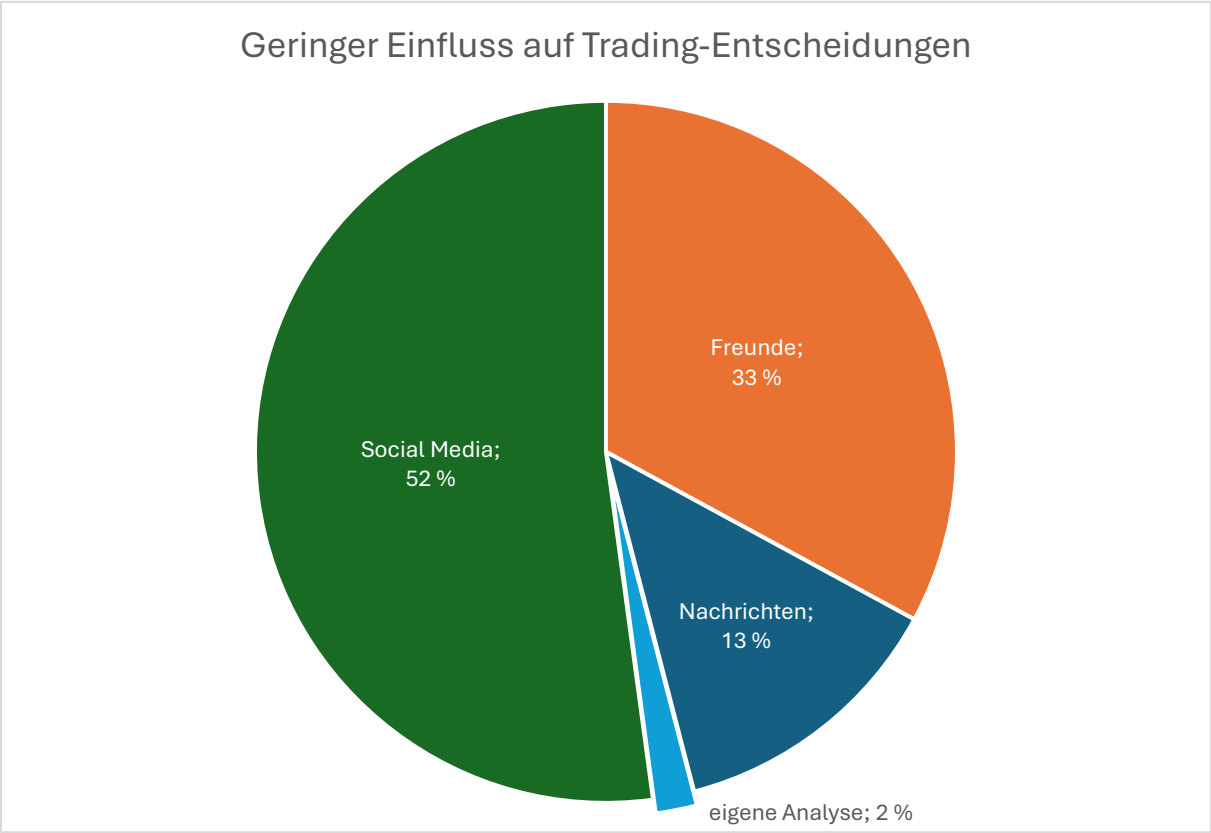


Abbildung 42: Prozentuale Aufteilung des geringsten Einflusses

Etwas beeinflusst werden die Teilnehmer:innen am meisten durch Nachrichten (35 %), gefolgt von Empfehlungen (29 %), Social Media (20 %) und schließlich der eigenen Analyse (16 %).

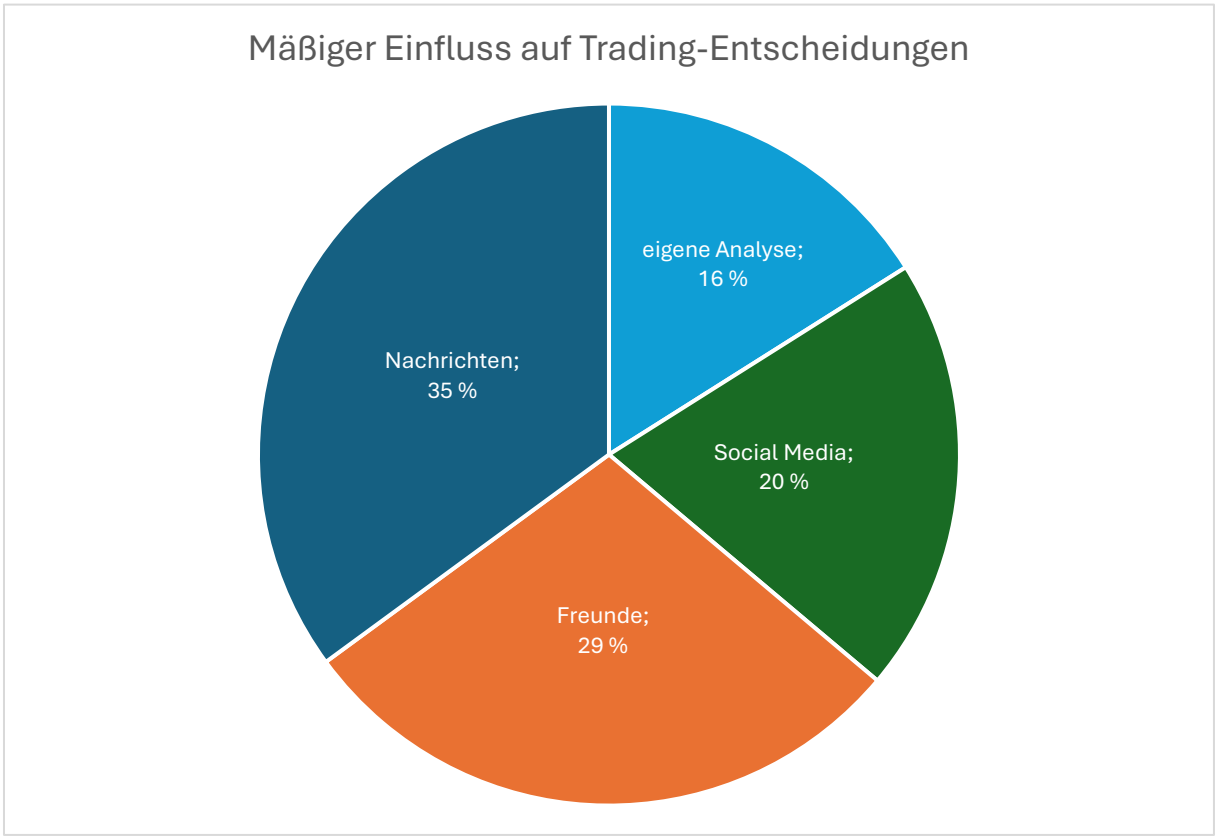


Abbildung 43: Prozentuale Aufteilung des mäßigen Einflusses

Frage 27 bat die Teilnehmer:innen anschließend um eine Einschätzung der Aussage „Meine Neobroker- beziehungsweise Trading-App verleitet mich zum Traden oder Investieren“. 41 Personen machten hierzu keine auswertbare Angabe, sodass 980 gültige Antworten vorlagen.

Von den gültig Antwortenden stimmten 40,8 % der Aussage eher und 15,7 % voll und ganz zu. Dagegen stimmten 29,1 % eher nicht und 14,4 % überhaupt nicht zu.

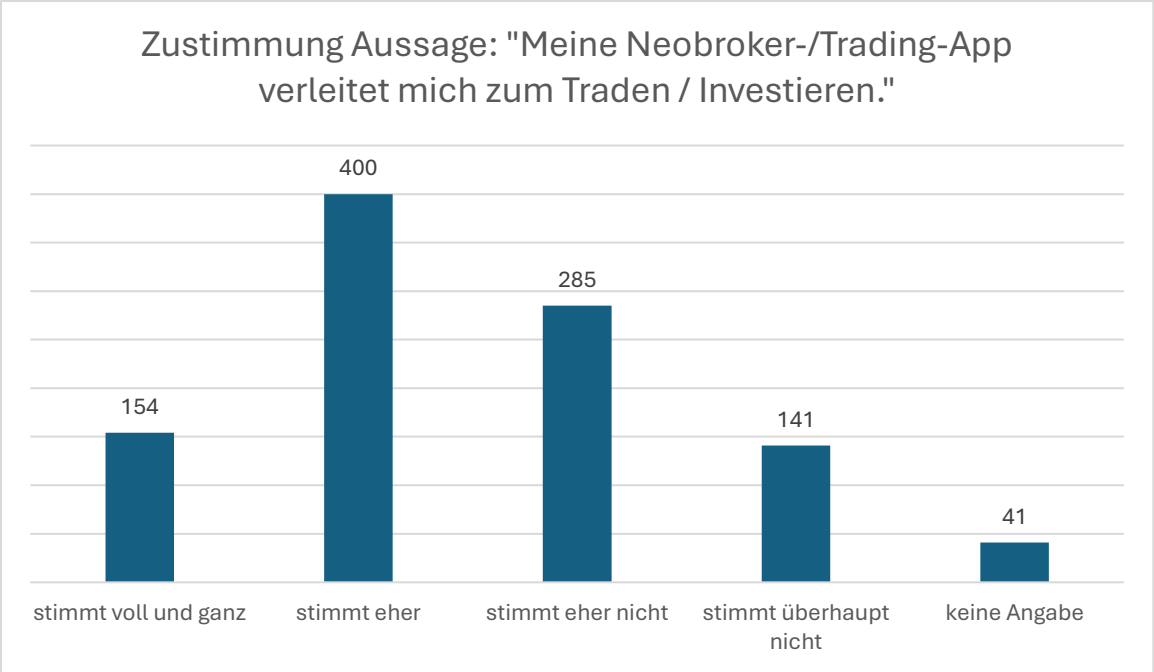


Abbildung 44: Zustimmung der Aussage „Neobroker verleitet zum Traden“

Zusammengenommen fühlen sich damit 56,5 % durch ihre Trading-App zumindest teilweise zum Handeln oder Investieren verleitet. 43,5 % verneinen einen solchen Einfluss. Die Zustimmung überwiegt somit, auch wenn die Einschätzungen vergleichsweise nah beieinanderliegen.

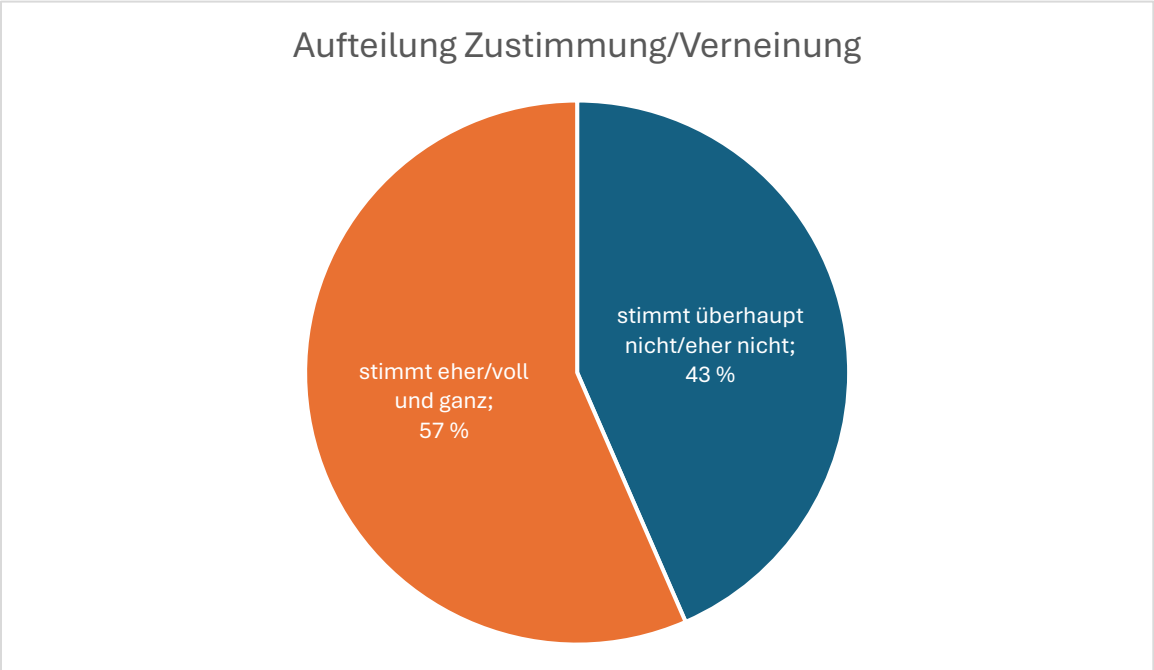


Abbildung 45: Prozentuale Aufteilung Zustimmung/Verneinung „Neobroker verleitet zum Traden“

Anschließend wurde erfragt, ob die Teilnehmer:innen bereits einmal ein Depot bei einem Neobroker vollständig oder weitgehend aufgelöst hatten. 19 Personen machten hierzu keine auswertbare Angabe, sodass 1.002 gültige Antworten vorlagen.

Bei 68,6 % ist das Depot weiterhin aktiv. Weitere 7,4 % haben es bislang nicht aufgelöst, nutzen es jedoch nur selten. 12,5 % haben ein Depot bereits nahezu geleert, während 11,6 % schon einmal ein Depot vollständig aufgelöst haben.

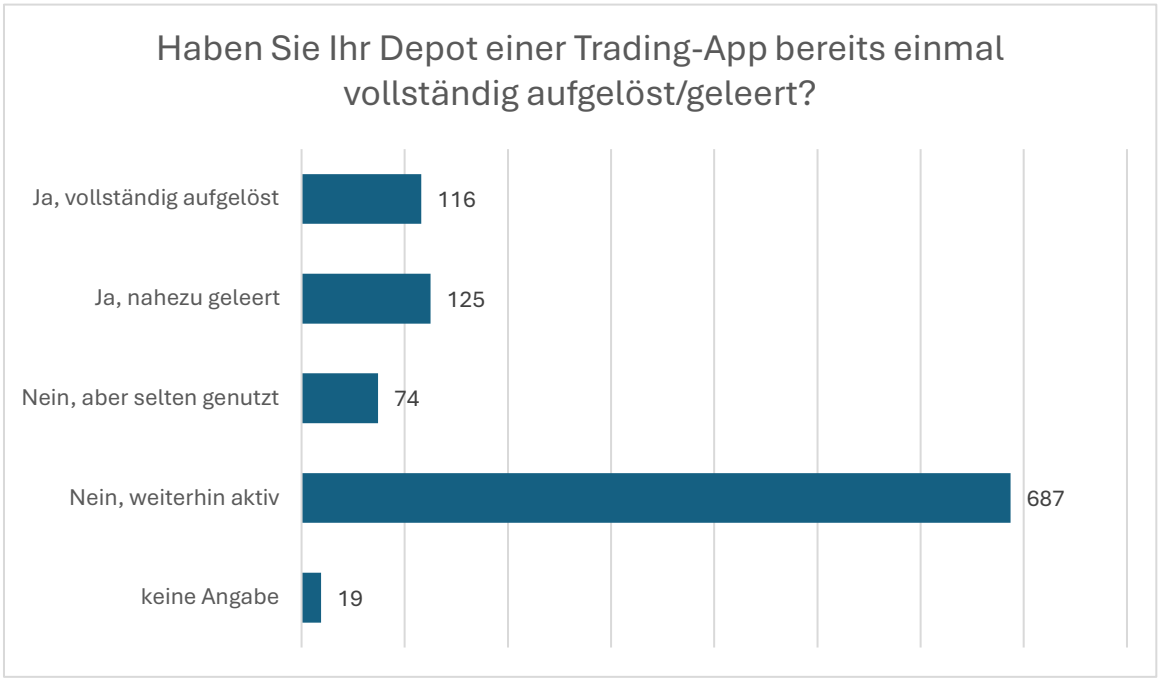


Abbildung 46: Auflösung von Neobroker-Depots

Die 241 Personen, die ihr Depot nahezu geleert oder vollständig aufgelöst hatten, wurden anschließend nach den Gründen für diese Entscheidung gefragt. Drei Personen machten hierzu keine auswertbare Angabe. Da mehrere Gründe genannt werden konnten, summieren sich die Prozentwerte auf mehr als 100 %.

Am häufigsten wurde mit 42,4 % der Wechsel zu einem anderen Neobroker genannt. Weitere 31,5 % benötigten das angelegte Geld, während 27,7 % zu einer anderen Anlageform wechselten. Mangelndes Vertrauen in die App spielte bei 22,7 % eine Rolle. Verluste beim Trading nannten 19,7 %, einen zu hohen Zeitaufwand oder Stress 18,1 % und ein fehlendes Interesse am Trading 16,0 %.

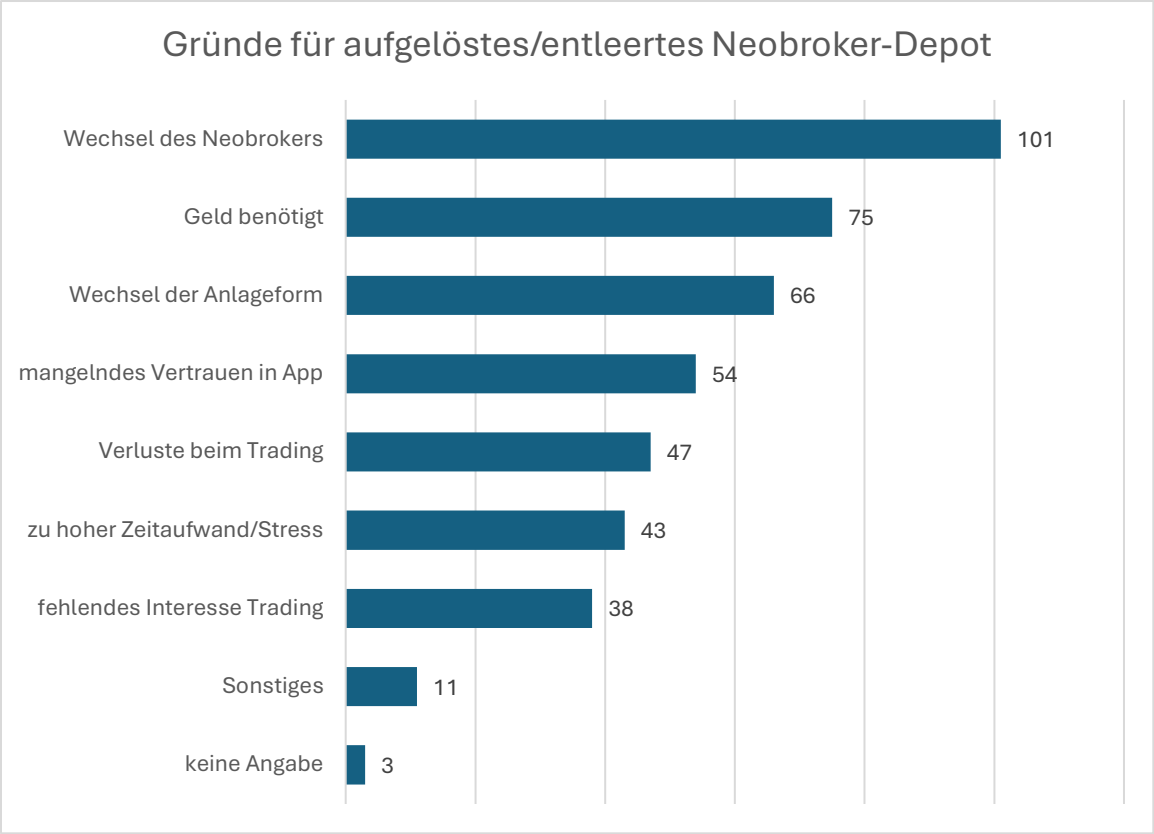


Abbildung 47: Gründe für aufgelöstes Neobroker-Depot

Elf Personen wählten die Kategorie „Sonstiges“. Zehn davon erläuterten ihre Entscheidung in einer eigenen Textantwort. Mehrere dieser Angaben ließen sich bestehenden Kategorien zuordnen und wurden in der Auswertung entsprechend berücksichtigt. Dazu gehörten:

Geld benötigt (3 Nennungen ergänzt)

- *Sondertilgung Hypothek*
- *Gewinnmitnahme (2x genannt)*

zu hoher Zeitaufwand/Stress (1 Nennung ergänzt)

- *Mangelhafte Selbstkontrolle beim Traden*

Die Antworten wurden der Auswertung und dem Diagramm bereits hinzugefügt. Aus den restlichen Antworten können diese neuen Kategorien gebildet werden:

Unpassender Anbieter (3 Nennungen)

- *Diese Bank war zu kompliziert für mich - aber sehr gut für Profis*
- *Hohe Kosten des Anbieters*
- *Anbieter ändert sein Angebot/AGBs*

Unzufriedenheit mit Performance & Marktlage (2 Nennungen)

- *zu wenig Rendite*
- *Marktgeschehen*

Externe / Irreführende Beratung (1 Nennung)

- *Irreführende Beratung*

Auf die Frage nach der geplanten Haltedauer ihrer Investments über den Neobroker machten 116 Personen keine auswertbare Angabe. Unter den gültig Antwortenden plant mit 60,4 % die Mehrheit, die Anlagen länger als fünf Jahre zu halten. Weitere 16,6 % sehen eine Haltedauer von ein bis zwei Jahren vor, während 16,0 % ihre Investments drei bis fünf Jahre halten möchten. Nur 7,0 % planen einen Verkauf innerhalb des ersten Jahres.

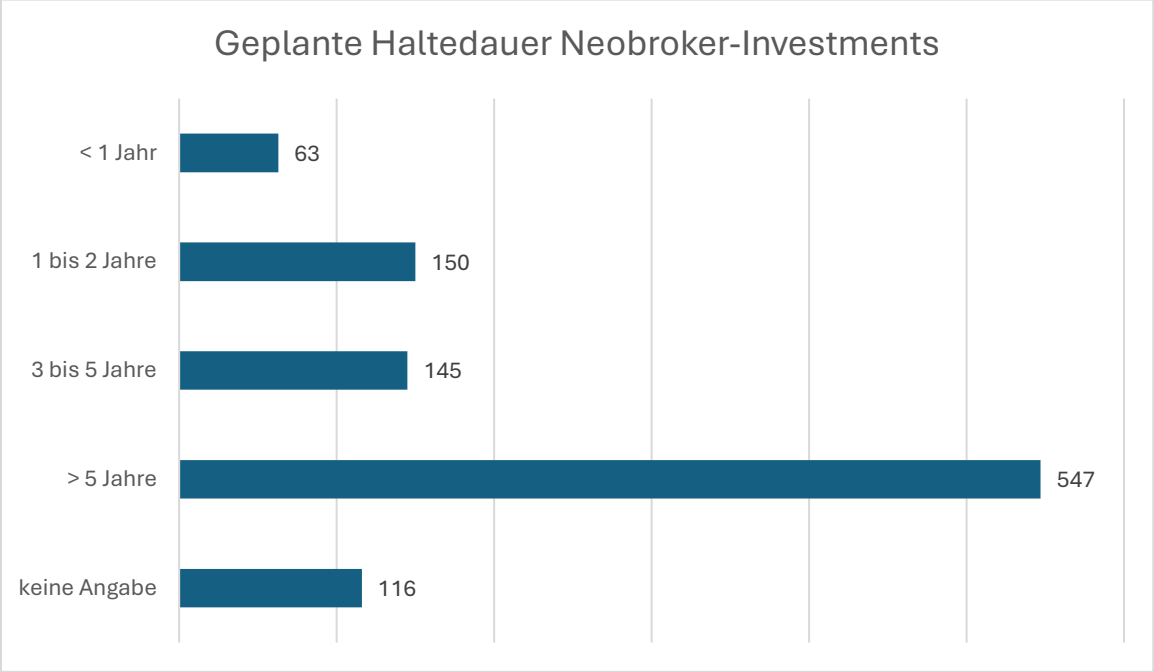


Abbildung 48: Geplante Haltedauer Neobroker-Investments

In Frage 31 sollten die Teilnehmer:innen einschätzen, wie stark verschiedene App-Funktionen und Informationsquellen ihre Investitionsentscheidungen beeinflussen. Bewertet wurden E-Mail-Werbung des Neobrokers, In-App-Empfehlungen, Social-Media-Trends, einfache Swipe-Käufe, Kursalarme und Push-Benachrichtigungen. Da sich die Zahl der fehlenden Angaben je nach Kategorie unterscheidet, wurden die Prozentwerte jeweils anhand der gültigen Antworten berechnet.

Bei allen sechs Einflussfaktoren war „überhaupt nicht“ die häufigste und „sehr“ die seltenste Antwort. Die geringste Wirkung wurde Social-Media-Trends zugeschrieben: 69,0 % fühlen sich hiervon überhaupt nicht beeinflusst, 21,6 % etwas und 9,4 % sehr.

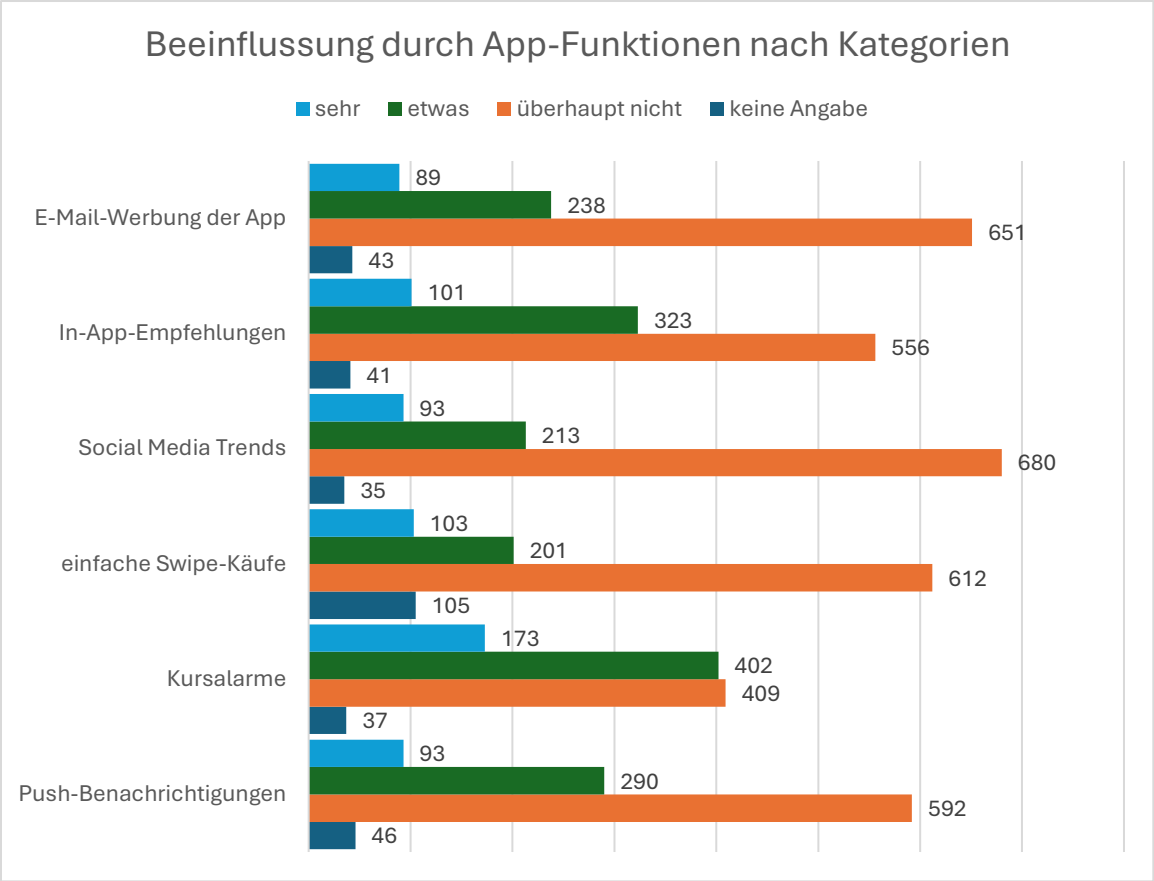


Abbildung 49: Stärke von Einfluss durch App-Funktionen

Auch einfache Swipe-Käufe besitzen für die Mehrheit keinen Einfluss. 66,8 % wählten „überhaupt nicht“, 21,9 % „etwas“ und 11,2 % „sehr“. Bei der E-Mail-Werbung des Neobrokers liegen die Anteile bei 66,6 %, 24,3 % und 9,1 %.

Push-Benachrichtigungen beeinflussen 60,7 % überhaupt nicht, 29,7 % etwas und 9,5 % sehr. Bei In-App-Empfehlungen fällt der Anteil ohne wahrgenommenen Einfluss mit 56,7 % geringer aus. Hier fühlen sich 33,0 % etwas und 10,3 % sehr beeinflusst.

Den stärksten Einfluss besitzen Kursalarme. Zwar wählten auch hier mit 41,6 % die meisten Teilnehmer:innen „überhaupt nicht“, der Abstand zur Antwort „etwas“ ist mit 40,9 % jedoch gering. Weitere 17,6 % fühlen sich durch Kursalarme sehr beeinflusst.

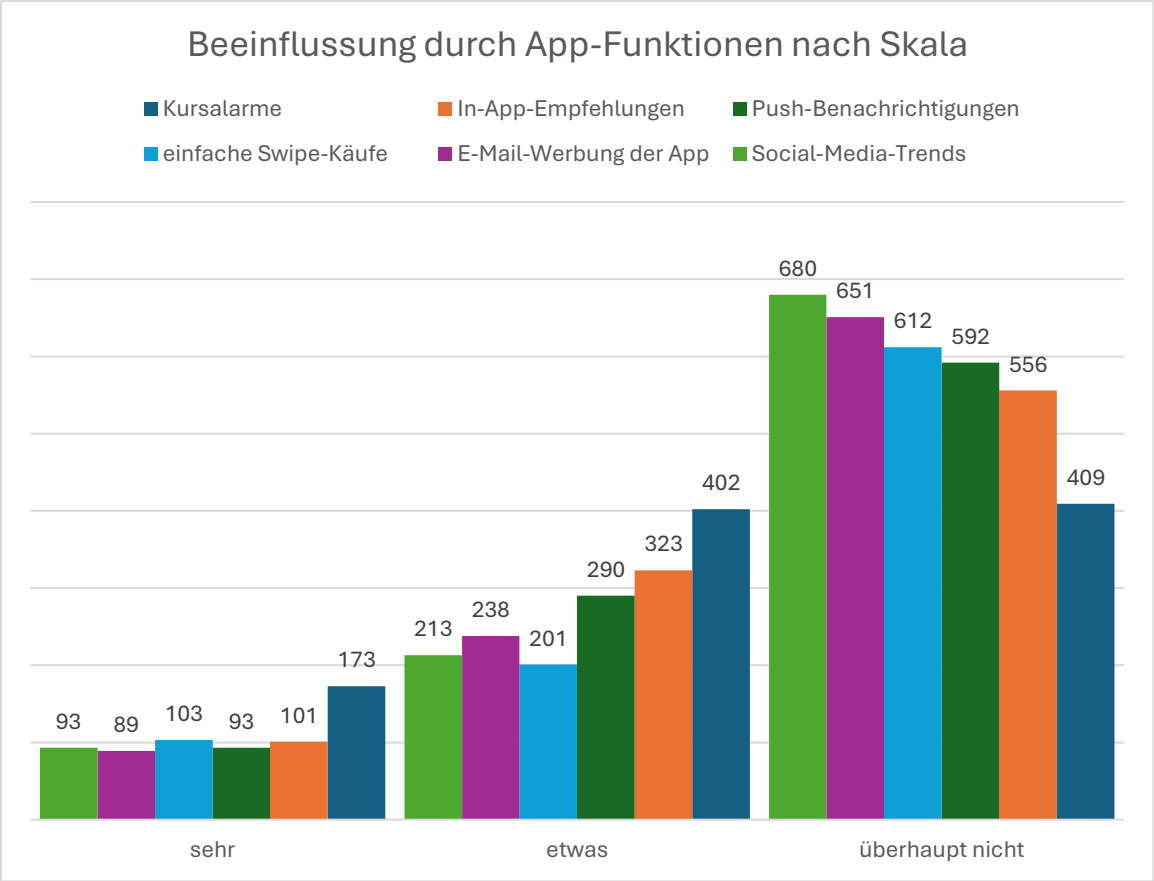


Abbildung 50: Einfluss von App-Funktionen nach Skala „sehr“ bis „überhaupt nicht“

Anschließend wurde konkreter gefragt, wie häufig die Teilnehmer:innen bereits aufgrund einer Push-Benachrichtigung investiert hatten. 67 Personen machten hierzu keine auswertbare Angabe. Von den gültig Antwortenden hatten 63,3 % noch nie aufgrund einer solchen Nachricht investiert. Die übrigen 36,7 % hatten mindestens einmal auf eine Push-Benachrichtigung mit einem Investment reagiert.

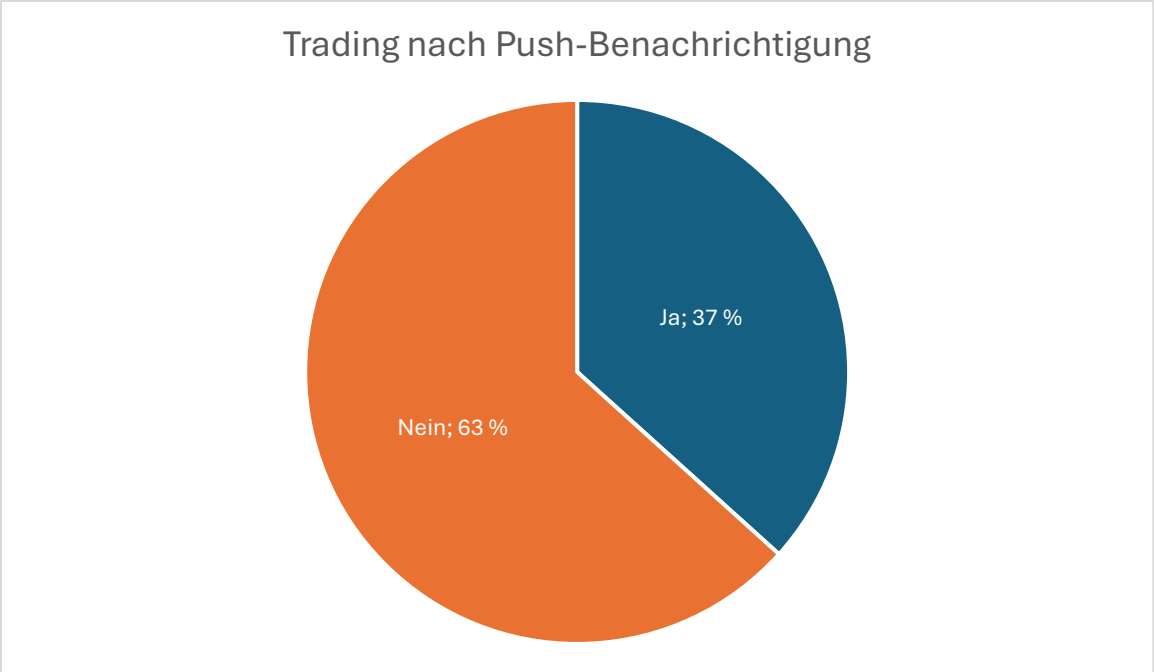


Abbildung 51: Trading nach Push-Benachrichtigung Ja/Nein

Innerhalb dieser Gruppe handelten 52,9 % ein- bis dreimal nach einer Push-Benachrichtigung. Weitere 35,1 % reagierten vier- bis zehnmal und 7,4 % elf- bis fünfzehnmal. Jeweils 2,3 % investierten sechzehn- bis zwanzigmal beziehungsweise mehr als zwanzigmal aufgrund einer solchen Nachricht.

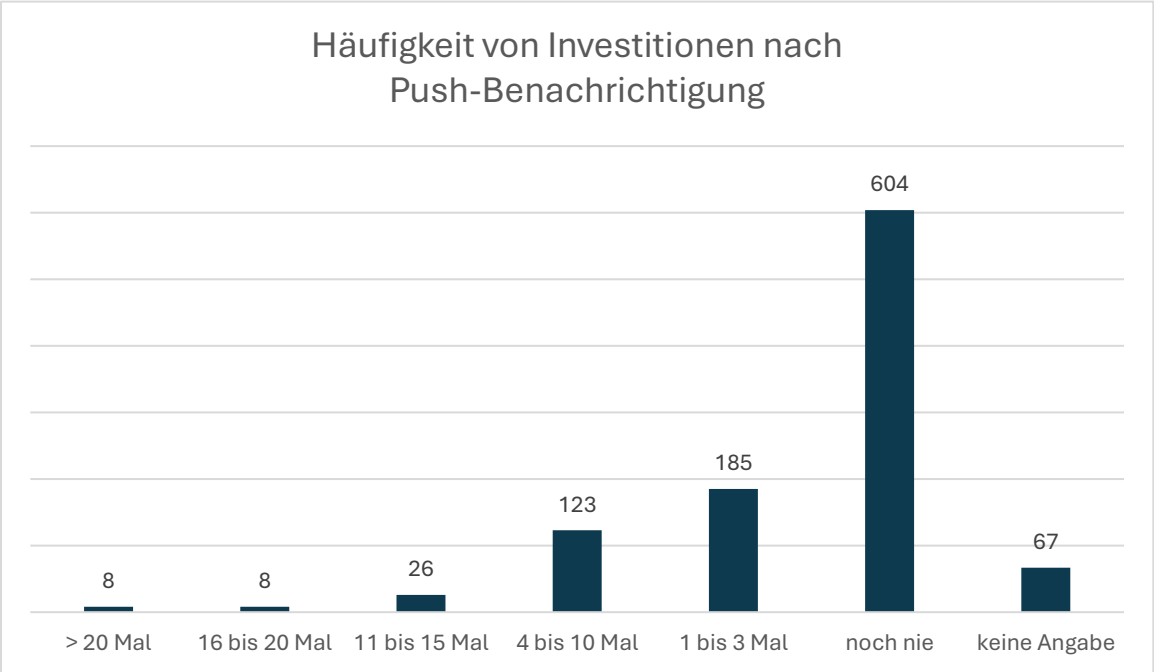


Abbildung 52: Häufigkeit von Trades nach Push-Benachrichtigung

Auf Frage 33 „Hätten Sie gerne einen persönlichen Ansprechpartner oder Berater für Ihre Investmententscheidungen?“ lagen 946 gültige Antworten vor. Von diesen wünschten sich 25,6 % eine persönliche Ansprechperson, während 74,4 % keinen entsprechenden Bedarf sahen.

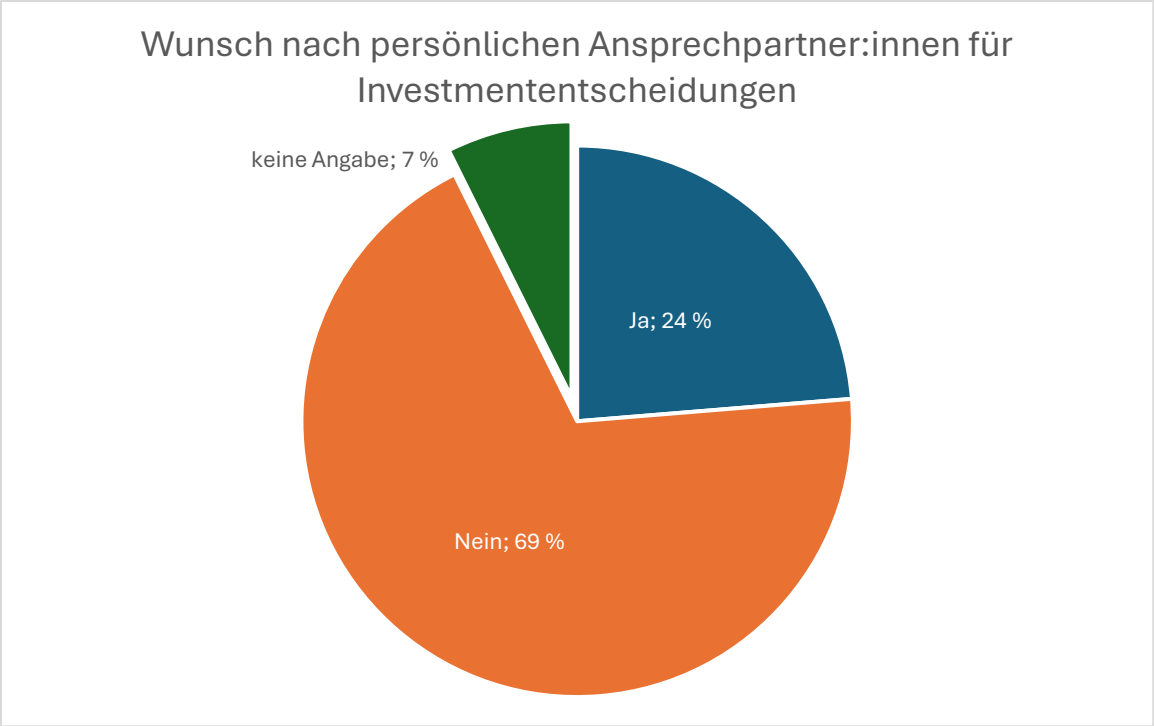


Abbildung 53: Wunsch nach persönlicher Beratung

In der anschließenden Frage wurde untersucht, ob eine Anlageberatung dennoch zu besseren Entscheidungen beitragen könnte. 44 Personen machten hierzu keine auswertbare Angabe. Unter den 977 gültig Antwortenden glaubten 13,0 %, dass eine Beratung ihnen eindeutig helfen würde. Weitere 43,2 % erwarteten zumindest teilweise einen Nutzen. Insgesamt sahen damit 56,2 % in einer Anlageberatung grundsätzlich Unterstützungspotenzial. Dagegen waren 43,8 % der Ansicht, dass eine Beratung ihre Entscheidungen nicht verbessern würde.

Die Ergebnisse zeigen somit einen Unterschied zwischen dem Wunsch nach einer festen persönlichen Ansprechperson und der Einschätzung des möglichen Nutzens einer Beratung. Obwohl sich nur rund ein Viertel ausdrücklich eine persönliche Beratung wünscht, hält mehr als die Hälfte eine solche Unterstützung zumindest teilweise für hilfreich.

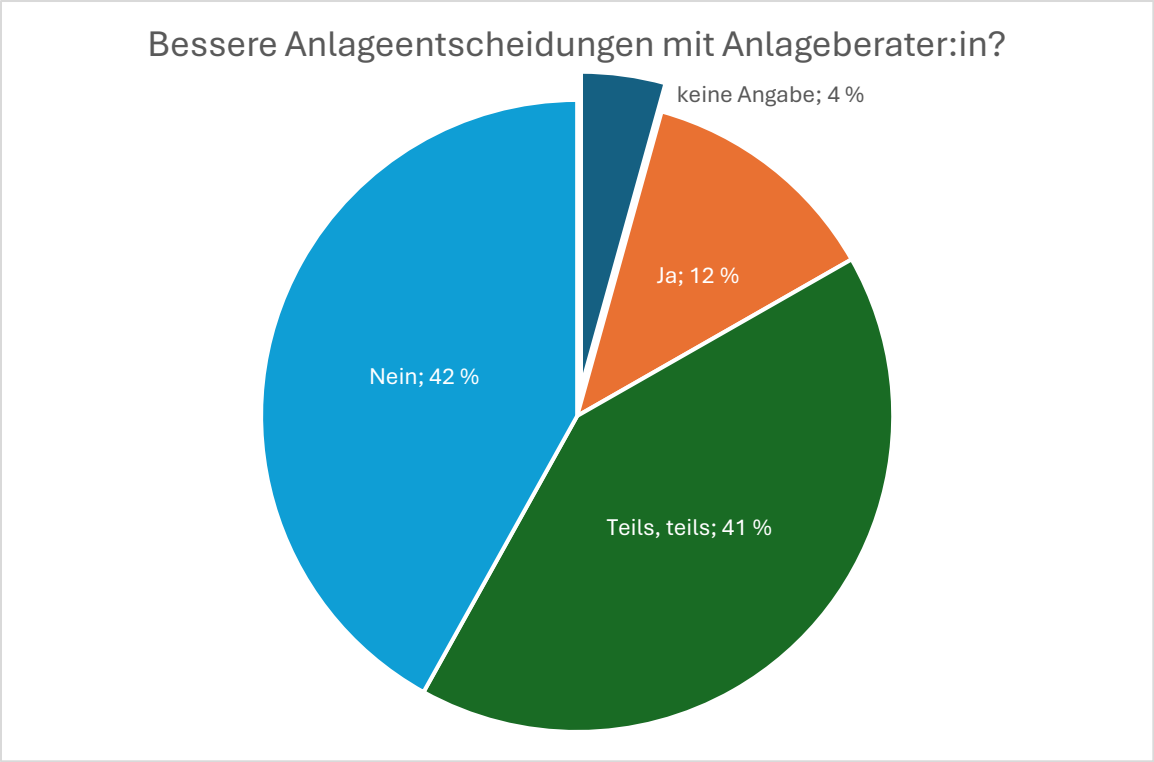


Abbildung 54: Verbesserung Anlageentscheidungen durch Beratung Ja/Nein

Anschließend wurde erfragt, welche weiteren Aspekte den Teilnehmer:innen helfen könnten, erfolgreicher zu investieren. Da mehrere Antworten möglich waren, summieren sich die Prozentwerte auf mehr als 100 %. Nach Ausschluss von 31 nicht auswertbaren Antworten lagen 990 gültige Angaben vor.

Am häufigsten wurde mit 53,0 % ein besseres Finanzwissen zu den Grundlagen des Tradings und zu den Finanzmärkten genannt. Es folgen klarere Strategien für den langfristigen Vermögensaufbau mit 38,5 % sowie eine unabhängige und verständliche Finanzbildung mit 31,6 %. Mehr Transparenz bei Kosten und Produkten wünschen sich 28,4 %, während 27,7 % mehr Zeit für fundierte Entscheidungen als hilfreich ansehen. Ein besseres Verständnis von Risiken nannten 24,7 %.

Persönliche Beratung oder Unterstützung wurde von 17,3 % gewählt. Dieser Anteil liegt unter dem Anteil der Befragten, die in der vorherigen Frage zumindest teilweise einen Nutzen durch Anlageberatung erwarteten. Weitere 13,4 % gaben an, bereits ausreichend informiert zu sein und keine zusätzliche Unterstützung zu benötigen.



Abbildung 55: Notwendige Aspekte für bessere Anlageentscheidungen

Von den ursprünglich 24 Nennungen unter „Sonstiges“ konnten 5 bestehenden Kategorien zugeordnet werden und wurden diesen in der Auswertung und dem Diagramm hinzugerechnet. Dazu zählen:

Klare Strategien für langfristigen Vermögensaufbau (1 Nennung ergänzt)

- „Klare Strategie zum Entsparen“

Unabhängige und verständliche Finanzbildung (1 Nennung ergänzt)

- „Mehr einfach zugängliche Informationen“

Mehr Transparenz bei Kosten und Produkten (1 Nennung ergänzt)

- „mehr detaillierte Produktinfos“

Mehr Zeit für fundierte Entscheidungen (1 Nennung ergänzt)

- „Zeit und Erfahrung“

Nicht zutreffend – ich bin bereits ausreichend informiert (1 Nennung ergänzt)

- Insider wissen, aber ernstahft, wäre ich sehr viel besser aufgestellt, wenn neobroker nicht zu Derivaten verleiten würden. Wie gesagt, seitdem nur noch ETFs und da bin ich ausreichend informiert [sic]

Die restlichen 19 Antworten können in die folgenden, neuen Kategorien zusammengefasst werden:

Mehr verfügbares Kapital & Einkommen (11 Nennungen)

- Mehr Geld [3x]
- mehr Geld zum investieren [2x]
- Mehr Geld haben
- Mehr Netto vom Brutto
- mehr eigenes Vermögen
- Mehr investierbares Geld
- Mehr Gehalt
- Mehr Kapital

Professionelle Daten, Research & Analysetools (5 Nennungen)

- Passende Analysetools
- Fundierte Analysen
- Research Informationen
- bessere Verfügbarkeit historischer Kursdaten
- Einfacher zugänglichere Unternehmensdaten

Erweiterung der Produktauswahl (1 Nennung)

- Mehr Produktauswahl

Ausreißer / Nicht fachbezogen (2 Nennungen)

- Meine Gesundheit
- Glaskugel

Frage 36 lautete: „Wie häufig haben Sie die folgenden Emotionen beim Trading beziehungsweise Investieren?“ Abgefragt wurden die Kategorien „positiv aufgeregt oder gespannt“, „gestresst“, „rational“ und „impulsiv“. Da die Zahl der fehlenden Angaben je nach Emotion unterschiedlich ausfiel, wurden die Prozentwerte jeweils anhand der gültigen Antworten berechnet.

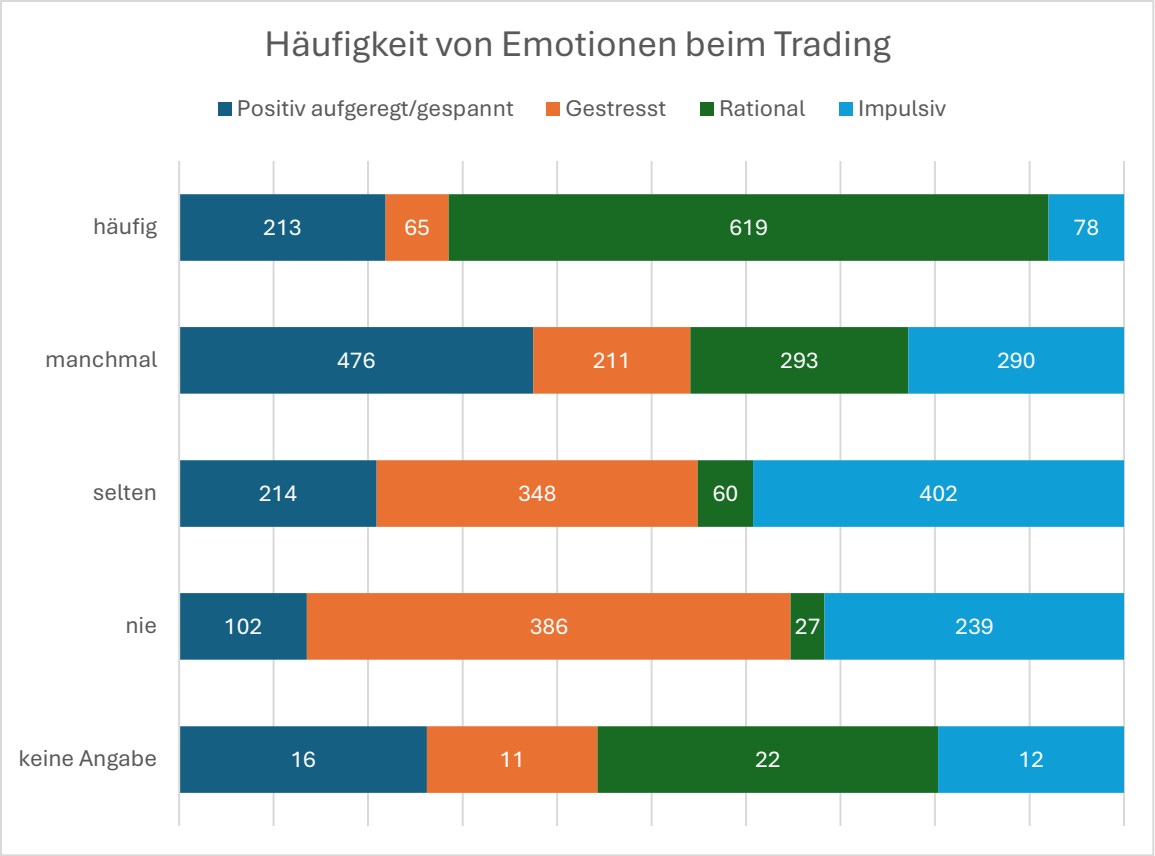


Abbildung 56: Häufigkeit der Emotionen „gespannt“, „gestresst“, „rational“ & „impulsiv“ beim Trading

Beim rationalen Verhalten ist „häufig“ mit 62,0 % die meistgewählte Antwort. Weitere 29,3 % handeln nach eigener Einschätzung manchmal rational, 6,0 % selten und 2,7 % nie.

Positive Aufregung oder Spannung empfinden die Befragten am häufigsten gelegentlich: 47,4 % wählten „manchmal“. Weitere 21,2 % erleben diese Emotion häufig, 21,3 % selten und 10,1 % nie.

Impulsives Verhalten tritt nach eigener Einschätzung überwiegend selten auf. Dies gaben 39,8 % der gültig Antwortenden an. Weitere 28,7 % handeln manchmal impulsiv, 23,7 % nie und 7,7 % häufig.

Auch Stress wird vergleichsweise selten erlebt. 38,2 % fühlen sich beim Trading oder Investieren nie gestresst, weitere 34,5 % selten. Manchmal gestresst sind 20,9 %, während 6,4 % häufig Stress empfinden.

Abschließend wurde erfragt, ob die Teilnehmer:innen ihrem Nachwuchs die Nutzung einer Neobroker-App empfehlen würden. 64 Personen machten hierzu keine auswertbare Angabe.

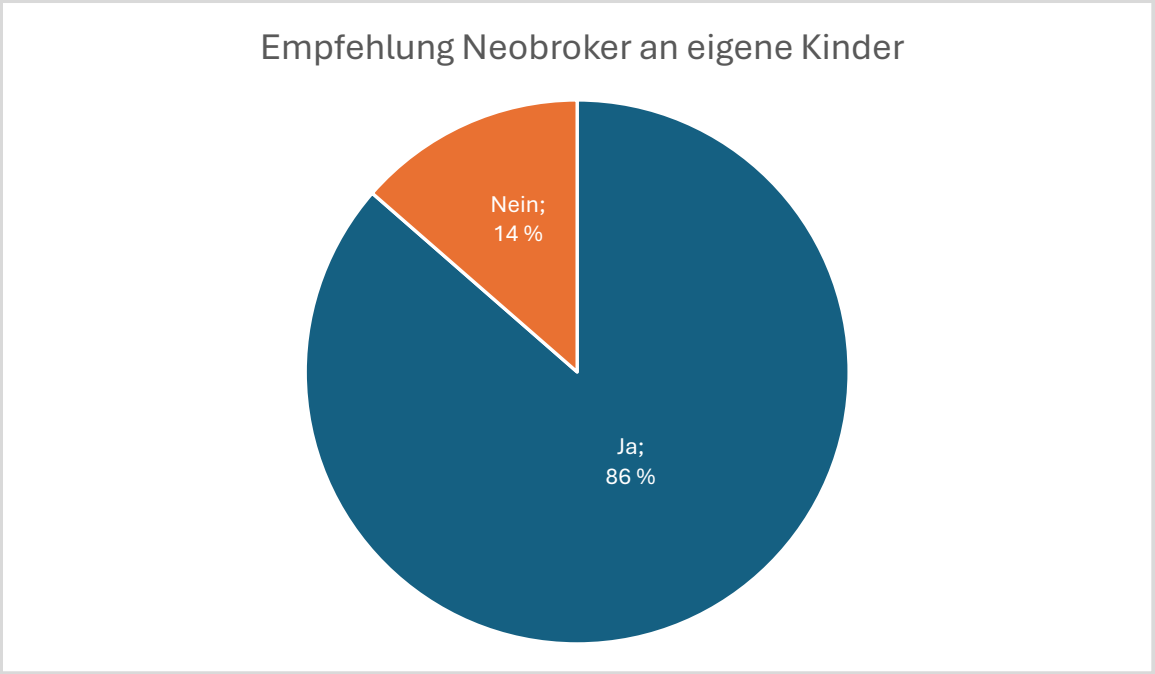


Abbildung 57: Prozentuale Aufteilung Empfehlung Neobroker an Nachwuchs Ja/Nein

Unter den gültig Antwortenden würden 86,4 % eine Neobroker-App grundsätzlich empfehlen. Dabei antworteten 44,3 % mit „Ja, auf jeden Fall“ und 42,1 % mit „eher ja“. Dagegen würden 13,6 % von der Nutzung abraten. Davon wählten 11,2 % „eher nein“ und 2,4 % „Nein, auf keinen Fall“.

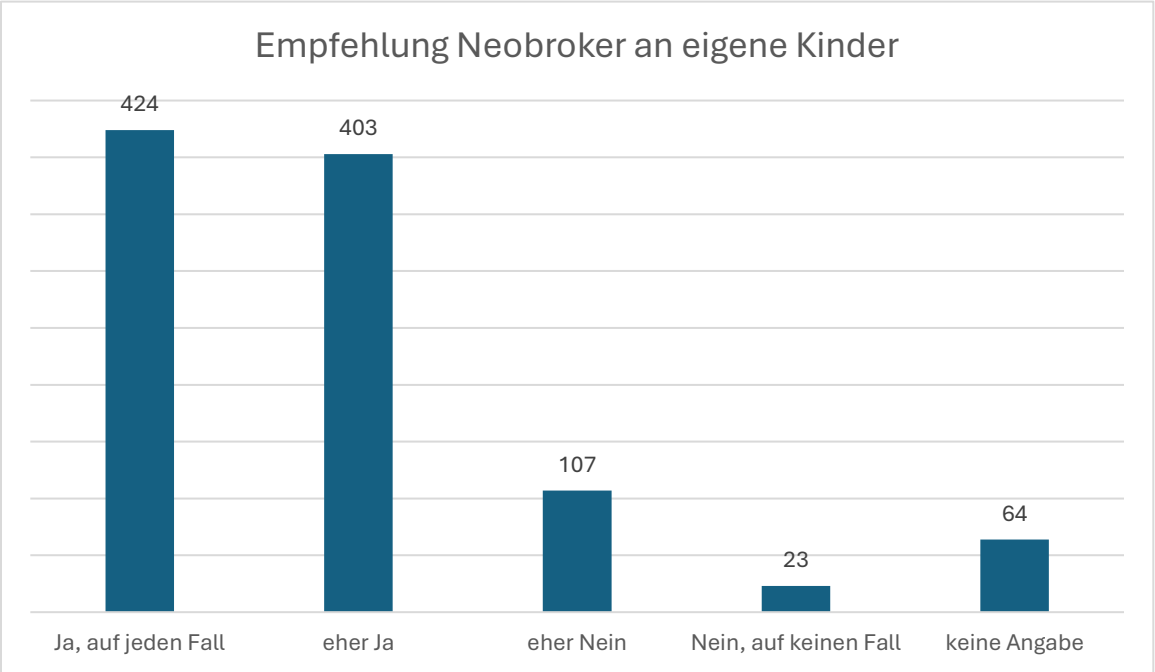


Abbildung 58: Empfehlung Neobroker an Nachwuchs

Analyse der Umfrageergebnisse

Aus den in der Umfrage erfassten Zahlen lassen sich mehrere Erkenntnisse in Bezug auf die Forschungsfragen dieser Studie ableiten. Diese werden in den folgenden Unterkapiteln thematisch geordnet zusammengefasst.

Rolle von Neobrokern innerhalb der Anlagestrategie

Aufgrund der Zielgruppe von Neobroker-Nutzer:innen ist es naheliegend, dass dieser Anlageweg eine hohe Bedeutung unter den Teilnehmer:innen der Umfrage einnimmt. Für 72,0 % sind die Neobroker-Apps der hauptsächlich genutzte Anlageweg. 35,6 % der 1.021 Befragten nutzen sogar ausschließlich diesen Weg. Über die Hälfte der Personen (53,4 %) haben zudem ihre erste Investmenterfahrung über Neobroker gemacht.

Für die Mehrheit der Teilnehmer:innen nimmt der Neobroker damit nicht nur die Rolle eines ergänzenden Depots ein, sondern ist ein/der zentrale Zugang zum Kapitalmarkt.

Der Einstiegseffekt ist bei jüngeren Nutzer:innen dabei etwas stärker: Rund 60 % der 18- bis 24-Jährigen, aber nur 47 % der mindestens 55-Jährigen, machten ihre erste Investmenterfahrung über einen Neobroker.

Dieser Unterschied lässt sich primär durch einen natürlichen Kohorteneffekt und die noch vergleichsweise junge Markthistorie der Trading-Apps erklären. Während Personen ab 55 Jahren in ihrer typischen Phase des Vermögensaufbaus – mangels digitaler Alternativen – auf traditionelle Banken oder frühe Online-Broker angewiesen waren, stellen die Smartphone-Apps für die digital affine Gen Z heute den standardmäßigen Zugang zum Kapitalmarkt dar.

Bemerkenswert ist in diesem Kontext jedoch insbesondere der Wert der über 55-Jährigen: Dass fast die Hälfte dieser älteren Kohorte ihre allererste Investmenterfahrung über eine App gemacht hat, bedeutet im Umkehrschluss, dass diese Anleger:innen in den Jahrzehnten zuvor nie an der Börse aktiv waren und erst im fortgeschrittenen Alter durch das niedrigschwellige Angebot aktiviert wurden.

Die Ergebnisse bestätigen damit insgesamt die im Theorieteil beschriebene Funktion von Neobrokern als wirksames Instrument zur Senkung von Zugangshürden zu Investitionen über alle Altersgruppen hinweg.

Veränderte Handelsfrequenz

Auf eigene Aussage hin handeln 31,0 % täglich oder mindestens einmal wöchentlich über die Trading-App. 48,4 % handeln ungefähr einmal monatlich. 20,6 % handeln seltener als einmal monatlich.

Dabei geben 38,1 % an, dass sich ihr Investmentverhalten seit der Neobroker-Nutzung gesteigert habe. In der konkreteren Folgefrage erklären jedoch 28,5 %, häufiger als zuvor zu handeln.

Die Differenz zwischen den beiden Fragen zeigt, dass die Befragten „mehr Investmentverhalten“ nicht ausschließlich als mehr Trades verstehen. Dazu können auch Sparpläne, Informationssuche oder höhere Anlagebeträge gehören.

Verluste von Geld über Neobroker-Apps

Nach Ausschluss der Angaben von „Weiß nicht/keine Angabe“ haben von den übrigen 989 Personen mit gültiger Antwort 56,6 % bereits mindestens einen endgültig realisierten Verlust über eine Trading-App erlitten.

Gleichzeitig berichten von den 946 Personen, die ihre gesamte Portfolioentwicklung einschätzen konnten, 83,4 % einen Gewinn, 7,4 % eine ungefähr gleichbleibende Entwicklung, und 9,2 % einen Gesamtverlust.

Diese Ergebnisse widersprechen sich nicht: 55,5 % der Personen mit insgesamt positiver Portfolioentwicklung hatten trotzdem bereits mindestens einen einzelnen endgültigen Verlust. Die Umfrage zeigt somit eine hohe Verbreitung einzelner Verluste, aber keine überwiegend negative Gesamtperformance.

Bezogen auf die 552 gültigen Antworten der 560 Personen mit Verlusterfahrung konnten die folgenden Hauptgründe für den Verlust ermittelt werden:

- Einzelaktien bzw. mangelnde Diversifikation: **43,3 %**
- Weltgeschehen und allgemeine Marktentwicklungen: **37,0 %**
- impulsive Entscheidungen: **31,0 %**
- Kryptowährungen: **19,7 %**
- Derivate beziehungsweise Hebelprodukte: **19,0 %**
- zu häufiges Trading: **11,6 %**

Damit ist übermäßiges Trading nach Meinung der Teilnehmer:innen nicht die am häufigsten genannte unmittelbare Verlustursache. Stärker wirken nach eigener Einschätzung Konzentrationsrisiken, Marktbewegungen und impulsive Entscheidungen.

Faktoren mit starker Verlust-Verbindung

Eine explorative logistische Regressionsanalyse berücksichtigt gleichzeitig Alter, Geschlecht, Einkommen, selbst eingeschätztes Finanzwissen, Handelsfrequenz, Produktwahl, wahrgenommene App-Einflüsse und Produktverständnis. Dabei zeigen sich mehrere Faktoren, die eigenständig mit einer höheren Chance verbunden sind, bereits einen endgültigen Verlust über eine Trading-App erlitten zu haben:

- Tägliches oder wöchentliches Trading geht mit **1,91-mal so hohen Odds** einer Verlusterfahrung einher wie monatliches oder selteneres Trading.
- Bei Nutzer:innen von Derivaten beziehungsweise Hebelprodukten sind die Odds einer Verlusterfahrung **2,91-mal so hoch**.

- Bei Kryptowährungsnutzer:innen sind sie **1,64-mal so hoch**.
- Wer bereits ohne vollständiges Produktverständnis investiert hat, weist **2,56-mal so hohe Odds** einer Verlusterfahrung auf.
- Männer berichten unter Berücksichtigung der übrigen Faktoren häufiger Verluste als Frauen.

Die Ergebnisse ergänzen die vorherige Selbsteinschätzung der Verlustgründe durch die Befragten um eine wichtige Perspektive: Nur 64 der Personen mit gültiger Antwort unter Verlusterfahrung nannten zu häufiges Trading ausdrücklich als Ursache ihres Verlusts. Im Abgleich der Antworten aus mehreren Fragen zeigt sich jedoch, dass eine hohe Handelsfrequenz unabhängig von weiteren untersuchten Merkmalen mit einer deutlich höheren Verlusterfahrung verbunden ist. Möglicherweise unterschätzen einige Befragte daher die Auswirkung ihrer Handelsfrequenz auf mögliche Verluste.

Auch App-Funktionen stehen mit mehreren risikorelevanten Verhaltensweisen in Zusammenhang. Nutzer:innen, die Push-Benachrichtigungen, Kursalarme, einfache Swipe-Käufe, In-App-Empfehlungen oder Social-Media-Trends als einflussreich wahrnehmen, handeln im Durchschnitt häufiger, treffen öfter spontane Anlageentscheidungen und haben häufiger bereits ohne vollständiges Verständnis eines Produkts investiert.

Die konkreten Prozentwerte, Effektstärken und Unterschiede zwischen den einzelnen App-Funktionen werden im späteren Unterkapitel zu Digital Engagement Practices und ihrem Einfluss auf das Investmentverhalten anhand der Kreuztabellen ausführlicher dargestellt.

In der isolierten Betrachtung berichten Personen, die eine größere Zahl von App-Funktionen als einflussreich wahrnehmen, dabei häufiger Verlusterfahrungen. Dies spricht für einen möglichen Wirkungsweg: App-Funktionen können die Aufmerksamkeit und Handelsaktivität erhöhen, spontane Entscheidungen begünstigen und die Hinwendung zu hervorgehobenen oder riskanteren Produkten fördern. Diese Verhaltensweisen stehen wiederum mit einer höheren Verlusterfahrung in Zusammenhang.

Mehrkanalnutzer:innen vs. ausschließlich Neobroker-Nutzer:innen

Ein überraschender Befund ergibt sich in mehreren Fragen beim Vergleich exklusiver Neobroker-Nutzer:innen mit Personen, die zusätzlich Banken, reguläre Online-Broker oder Robo-Advisor verwenden:

Merkmal	**Nur Neobroker**	**Mehrere Anlagewege**
Tägliches oder wöchentliches Trading	19,6 %	36,6 %
Mindestens eine endgültige Verlusterfahrung	51,7 %	59,3 %
Investment mindestens einmal bereut	60,3 %	69,4 %

Merkmal	Nur Neobroker	Mehrere Anlagewege
Häufig oder sehr häufig spontane Entscheidungen	10,8 %	17,6 %
Nach eigener Aussage höhere Risiken eingegangen	9,4 %	18,2 %

Ausschließliche Neobroker-Nutzer:innen erscheinen in den Daten damit weniger aktiv und weniger risikoorientiert als Mehrkanalnutzer:innen. Die ausschließliche Nutzung eines Neobrokers ist daher kein geeigneter alleiniger Indikator für spekulatives Verhalten.

Vermutlich gehören zu den Mehrkanalnutzer:innen überdurchschnittlich aktive und erfahrene Anleger:innen mit mehreren Depots. Diese Erklärung bleibt jedoch eine Interpretation.

Umfrageergebnisse zum Einfluss der DEPs auf Investmentverhalten

Der Anteil der Nutzer:innen, die wenigstens einen gewissen Einfluss der jeweiligen Funktion angeben, beträgt:

- Kursalarme: 58,4 %
- In-App-Empfehlungen: 43,3 %
- Push-Benachrichtigungen: 39,3 %
- E-Mail-Werbung: 33,4 %
- einfache Swipe-Käufe: 33,2 %
- Social-Media-Trends innerhalb oder im Umfeld der App: 31,0 %

Zwar ist „beeinflusst mich überhaupt nicht“ bei den meisten einzelnen Funktionen die häufigste Antwortkategorie. Zugleich erkennt jedoch jeweils ein Drittel bis mehr als die Hälfte der Befragten zumindest einen gewissen Einfluss. Die Aussage, diese Funktionen seien für die Teilnehmenden weitgehend unbedeutend, wäre daher zu pauschal.

Die wahrgenommene Beeinflussung zeigt sich auch in den Angaben zum Investmentverhalten. Bei Befragten, die Swipe-Käufe als einflussreich bewerten, ergeben sich beispielsweise folgende Unterschiede:

- tägliches oder wöchentliches Trading: 52,2 % gegenüber 22,4 %
- häufige oder sehr häufige spontane Entscheidungen: 33,2 % gegenüber 7,9 %
- mindestens einmal ein Investment bereut: 79,1 % gegenüber 59,4 %
- mindestens einmal einen endgültigen Verlust erlitten: 64,2 % gegenüber 53,1 %

- Zustimmung, von der App zum Trading verleitet zu werden: 80,4 % gegenüber 42,9 %

Vergleichbare, wenn auch unterschiedlich starke Unterschiede zeigen sich auch bei den übrigen App-Funktionen. Insgesamt steht eine höhere Anzahl als einflussreich wahrgenommener Funktionen unter anderem mit häufigeren spontanen Entscheidungen, bereuten Investments, einer ungünstigeren Portfolioentwicklung und der Wahrnehmung in Zusammenhang, durch die App zum Trading verleitet zu werden.

Bei riskanteren Anlageprodukten ist das Bild weniger einheitlich. Die Zusammenhänge unterscheiden sich je nach App-Funktion und Produktart.

Besonders deutlich fallen die Unterschiede zwischen den Altersgruppen aus. Von den 18- bis 24-Jährigen geben 76,5 % an, die App verleite sie zum Trading; bei den Befragten ab 55 Jahren sind es 41,5 %. Mindestens einmal nach einer Push-Benachrichtigung investiert haben 69,8 % der jüngeren Gruppe, gegenüber 25,3 % der Befragten ab 55 Jahren.

Kreuztabellenanalysen zum Einfluss der DEPs auf das Investmentverhalten

Die Zusammenhänge des wahrgenommenen Einflusses von aktivierenden App-Funktionen und Investmentverhalten konnten durch Kreuztabellenanalysen der Umfrageergebnisse ermittelt werden. Für jede der sechs App-Funktionen wurden zwei Gruppen gebildet:

- **beeinflusst:** „beeinflusst mich etwas“ oder „beeinflusst mich sehr“
- **nicht beeinflusst:** „beeinflusst mich überhaupt nicht“

„Weiß nicht/keine Angabe“ wurde jeweils ausgeschlossen.

Die untersuchten Verhaltensmerkmale wurden folgendermaßen zusammengefasst:

- **häufiges Trading:** täglich oder einmal wöchentlich
- **unvollständiges Produktverständnis:** mindestens selten ohne vollständiges Verständnis investiert
- **häufig spontane Entscheidungen:** häufig oder sehr häufig
- **riskante Produkte:** Derivate/Hebelprodukte beziehungsweise Kryptowährungen

Zusätzlich wurden Chi-Quadrat-Tests, Odds Ratios und Cramérs V berechnet. Die Signifikanzwerte wurden wegen der Vielzahl der Vergleiche mit einer FDR-Korrektur abgesichert.

1. App-Einfluss und Handelsfrequenz

Die erste Kreuztabelle testete, ob der wahrgenommene Einfluss der App-Funktionen eine Auswirkung auf die Häufigkeit von Trades hat.

App-Funktion	Häufiges Trading ohne Einfluss	Häufiges Trading mit Einfluss	Odds Ratio	Cramérs V
Push-Benachrichtigungen	22,4 %	46,3 %	2,99	0,250
Kursalarme	19,6 %	40,0 %	2,74	0,217
einfache Swipe-Käufe	22,4 %	52,2 %	3,79	0,300
Social-Media-Trends	24,9 %	45,7 %	2,54	0,208
In-App-Empfehlungen	24,7 %	40,6 %	2,09	0,170
E-Mail-Werbung	25,2 %	43,9 %	2,33	0,190

Alle sechs Zusammenhänge sind auch nach der Korrektur für Mehrfachtests statistisch signifikant.

Am stärksten ist der Unterschied bei einfachen Swipe-Käufen:

- 52,2 % der beeinflussten Nutzer:innen handeln täglich oder wöchentlich.
- Bei den nicht beeinflussten Nutzer:innen sind es 22,4 %.
- Die Chance häufigen Tradings ist damit in der beeinflussten Gruppe etwa 3,8-mal so hoch.

Auch nach statistischer Berücksichtigung von Alter, Geschlecht, selbst eingeschätztem Finanzwissen und Dauer der App-Nutzung bleiben alle sechs Zusammenhänge bestehen. Die adjustierten Odds Ratios liegen zwischen 1,86 und 2,91.

App-Funktion	Gültiges N	Adjustierte OR	95-%-KI	p
Push-Benachrichtigungen	957	2,512	1,843–3,424	< 0,001
Kursalarme	966	2,514	1,827–3,461	< 0,001
Einfache Swipe-Käufe	900	2,911	2,089–4,052	< 0,001
Social-Media-Trends	969	1,859	1,332–2,594	< 0,001
In-App-Empfehlungen	963	1,939	1,431–2,627	< 0,001
E-Mail-Werbung	960	1,888	1,375–2,595	< 0,001

Erkenntnis: Die Daten sprechen klar gegen die Annahme, dass sich beeinflusst fühlende Personen nicht häufiger handeln würden. Die wahrgenommene Wirkung der App-Funktionen hängt deutlich mit der tatsächlichen Handelsfrequenz zusammen.

2. App-Einfluss und unvollständiges Produktverständnis

Im nächsten Schritt wurde geprüft, ob der wahrgenommene Einfluss einzelner App-Funktionen damit zusammenhängt, dass Nutzer:innen bereits in ein Anlageprodukt investiert haben, obwohl sie dessen Funktionsweise nicht vollständig verstanden hatten. Hierzu wurden für jede App-Funktion separate Kreuztabellen erstellt.

App-Funktion	Ohne Verständnis investiert: kein Einfluss	Ohne Verständnis investiert: Einfluss	Odds Ratio	Cramérs V
Push-Benachrichtigungen	64,2 %	78,5 %	2,04	0,152
Kursalarme	60,3 %	76,9 %	2,19	0,178
einfache Swipe-Käufe	63,5 %	80,7 %	2,40	0,175
Social-Media-Trends	63,1 %	85,0 %	3,33	0,222
In-App-Empfehlungen	63,5 %	78,3 %	2,08	0,160
E-Mail-Werbung	64,7 %	79,6 %	2,13	0,153

Bei allen sechs App-Funktionen zeigt sich ein statistisch signifikanter Zusammenhang mit Investitionen bei unvollständigem Produktverständnis. Die unadjustierten Odds Ratios liegen zwischen 2,04 und 3,33. Damit war die Chance, bereits ohne vollständiges Produktverständnis investiert zu haben, in den beeinflussten Gruppen durchgehend höher als in den jeweils nicht beeinflussten Gruppen.

Zur zusätzlichen Prüfung wurden sechs binär-logistische Regressionen berechnet. Dabei wurden Alter, Geschlecht, das selbst eingeschätzte Finanzwissen und die bisherige Nutzungsdauer der Anlage-App statistisch berücksichtigt.

App-Funktion	Gültiges N	Adjustierte OR	95-%-KI	p
Push-Benachrichtigungen	952	1,838	1,341–2,519	< 0,001
Kursalarme	964	2,062	1,543–2,757	< 0,001
Einfache Swipe-Käufe	898	2,256	1,582–3,217	< 0,001
Social-Media-Trends	964	3,139	2,144–4,597	< 0,001
In-App-Empfehlungen	957	1,891	1,397–2,559	< 0,001
E-Mail-Werbung	954	1,871	1,341–2,611	< 0,001

Auch nach statistischer Kontrolle bleiben alle sechs Zusammenhänge bestehen. Sämtliche adjustierten Odds Ratios liegen über 1, die zugehörigen 95-%-Konfidenzintervalle schließen den Wert 1 aus und alle p-Werte liegen unter 0,001.

Besonders ausgeprägt ist der Zusammenhang bei Social-Media-Trends:

- 85,0 % der beeinflussten Nutzer:innen hatten bereits ohne vollständiges Produktverständnis investiert.
- In der nicht beeinflussten Gruppe lag dieser Anteil bei 63,1 %.
- Unadjustiert waren die entsprechenden Odds in der beeinflussten Gruppe etwa 3,33-mal so hoch.
- Nach Kontrolle von Alter, Geschlecht, Finanzwissen und Nutzungsdauer lag die adjustierte Odds Ratio weiterhin bei 3,139.

Auch bei einfachen Swipe-Käufen zeigt sich ein deutlicher Unterschied: In der beeinflussten Gruppe hatten 80,7 % bereits ohne vollständiges Produktverständnis investiert, verglichen mit 63,5 % in der nicht beeinflussten Gruppe. Nach Kontrolle der vier Merkmale beträgt die adjustierte Odds Ratio 2,256.

Erkenntnis: Wahrgenommener App-Einfluss hängt nicht nur mit einer höheren Handelsaktivität zusammen. Er geht auch mit einer deutlich höheren Verbreitung von Anlageentscheidungen bei unvollständigem Produktverständnis einher. Dieser Zusammenhang bleibt bestehen, wenn Alter, Geschlecht, das selbst eingeschätzte Finanzwissen und die Nutzungsdauer der Anlage-App statistisch berücksichtigt werden.

Aus den Querschnittsdaten lässt sich allerdings keine eindeutige Wirkungsrichtung ableiten. Mindestens zwei Erklärungsmechanismen sind denkbar:

1. App-Funktionen könnten die Reflexionsschwelle senken und Anlageentscheidungen fördern, obwohl das jeweilige Produkt noch nicht vollständig verstanden wurde.
2. Personen mit geringerer Entscheidungssicherheit, höherer Risikoneigung oder einer stärkeren Ansprechbarkeit für digitale Reize könnten entsprechende App-Funktionen intensiver wahrnehmen.

Methodischer Hinweis: In der ursprünglichen fünfstufigen Variable zum selbst eingeschätzten Finanzwissen trat in der niedrigsten Kategorie eine Nullzelle auf: In dieser Gruppe hatte keine Person angegeben, noch nie ohne vollständiges Produktverständnis investiert zu haben. Dadurch entstand in den logistischen Regressionsmodellen eine vollständige Separation mit instabilen Koeffizienten und nicht sinnvoll interpretierbaren Konfidenzintervallen.

Für die Regressionsanalysen wurden deshalb die beiden niedrigsten, inhaltlich benachbarten Finanzwissenskategorien zusammengefasst. Das Finanzwissen wurde somit als vierstufige kategoriale Kontrollvariable berücksichtigt. Zusätzlich wurde die bisherige Nutzungsdauer der Anlage-App in alle sechs Modelle aufgenommen. Die unterschiedlichen gültigen Fallzahlen ergeben sich aus fehlenden Werten in den jeweils einbezogenen Variablen.

3. App-Einfluss und spontane Entscheidungen

Im nächsten Schritt wurde geprüft, ob der wahrgenommene Einfluss einzelner App-Funktionen damit zusammenhängt, dass Nutzer:innen häufig oder sehr häufig spontane Anlageentscheidungen treffen. Dazu wurden zunächst separate Kreuztabellen für die sechs App-Funktionen berechnet.

App-Funktion	Häufig spontan ohne Einfluss	Häufig spontan mit Einfluss	Odds Ratio	Cramérs V
Push-Benachrichtigungen	8,8 %	26,4 %	3,71	0,236
Kursalarme	9,6 %	19,8 %	2,33	0,139
Einfache Swipe-Käufe	7,9 %	33,2 %	5,83	0,323
Social-Media-Trends	9,1 %	29,4 %	4,13	0,259
In-App-Empfehlungen	9,0 %	23,8 %	3,15	0,203
E-Mail-Werbung	9,1 %	28,6 %	4,00	0,253

Bei allen sechs App-Funktionen zeigt sich ein statistisch signifikanter Zusammenhang mit häufigen oder sehr häufigen spontanen Anlageentscheidungen. Die unadjustierten Odds Ratios liegen zwischen 2,33 und 5,83. Damit sind die Odds häufiger spontaner Entscheidungen in den beeinflussten Gruppen durchgehend höher als in den jeweils nicht beeinflussten Gruppen.

Zur zusätzlichen Prüfung wurden sechs binär-logistische Regressionen berechnet. Dabei wurden Alter, Geschlecht, das selbst eingeschätzte Finanzwissen und die bisherige Nutzungsdauer der Anlage-App statistisch berücksichtigt.

App-Funktion	Gültiges N	Unadjustierte OR	Adjustierte OR	95-%-KI der adjustierten OR	p
Push-Benachrichtigungen	962	3,71	2,722	1,826–4,057	< 0,001
Kursalarme	973	2,33	1,811	1,194–2,746	0,005
Einfache Swipe-Käufe	906	5,83	4,302	2,829–6,543	< 0,001
Social-Media-Trends	975	4,13	2,886	1,900–4,383	< 0,001
In-App-Empfehlungen	968	3,15	2,517	1,688–3,752	< 0,001
E-Mail-Werbung	965	4,00	2,923	1,966–4,345	< 0,001

Auch nach statistischer Kontrolle bleiben alle sechs Zusammenhänge bestehen. Sämtliche adjustierten Odds Ratios liegen über 1 und die zugehörigen 95-%-Konfidenzintervalle schließen den Wert 1 aus. Fünf Zusammenhänge weisen einen p-Wert unter 0,001 auf; der Zusammenhang mit Kursalarmen ist mit p = 0,005 ebenfalls statistisch signifikant. Die unterschiedlichen gültigen Fallzahlen ergeben sich aus fehlenden Werten in den jeweils einbezogenen Variablen.

Der stärkste Zusammenhang tritt erneut bei einfachen Swipe-Käufen auf:

- 33,2 % der beeinflussten Personen treffen häufig oder sehr häufig spontane Anlageentscheidungen.
- Ohne wahrgenommenen Einfluss liegt dieser Anteil bei lediglich 7,9 %.
- Die unadjustierten Odds häufiger spontaner Entscheidungen sind in der beeinflussten Gruppe etwa 5,83-mal so hoch.
- Nach Kontrolle von Alter, Geschlecht, Finanzwissen und Nutzungsdauer beträgt die adjustierte Odds Ratio weiterhin 4,302.

Damit gehört der Zusammenhang zwischen einfachen Swipe-Käufen und spontanen Anlageentscheidungen zu den stärksten Effekten der gesamten Kreuztabellenanalyse.

Erkenntnis: Die Ergebnisse stehen im Einklang mit der theoretischen Annahme der *Removal of Friction*. Personen, die sich durch stark vereinfachte Kaufprozesse wie Swipe-Käufe beeinflusst fühlen, berichten deutlich häufiger spontane Anlageentscheidungen als Personen ohne wahrgenommenen Einfluss. Dieser Zusammenhang bleibt auch unter statistischer Kontrolle zentraler demografischer Merkmale, des Finanzwissens und der Nutzungsdauer bestehen.

4. App-Einfluss und Derivate beziehungsweise Hebelprodukte

Im nächsten Schritt wurde geprüft, ob der wahrgenommene Einfluss einzelner App-Funktionen damit zusammenhängt, dass Nutzer:innen aktuell Derivate beziehungsweise Hebelprodukte besitzen oder verwenden. Hierzu wurden zunächst für jede App-Funktion separate Kreuztabellen berechnet.

App-Funktion	Derivate ohne Einfluss	Derivate mit Einfluss	Odds Ratio	Cramérs V
Push-Benachrichtigungen	7,9 %	13,8 %	1,86	0,095
Kursalarme	5,9 %	13,2 %	2,44	0,120
Einfache Swipe-Käufe	6,5 %	18,8 %	3,30	0,187
Social-Media-Trends	7,4 %	16,7 %	2,52	0,142
In-App-Empfehlungen	8,1 %	13,0 %	1,69	0,080
E-Mail-Werbung	8,1 %	14,7 %	1,94	0,101

In den einfachen Kreuztabellen zeigen sich bei allen sechs App-Funktionen statistisch signifikante Zusammenhänge mit dem Besitz beziehungsweise der Nutzung von Derivaten und Hebelprodukten. Die unadjustierten Odds Ratios liegen zwischen 1,69 und 3,30. Damit sind die Odds, Derivate oder Hebelprodukte zu besitzen beziehungsweise zu nutzen, in sämtlichen beeinflussten Gruppen höher als in den jeweils nicht beeinflussten Gruppen.

Zur zusätzlichen Prüfung wurden sechs binär-logistische Regressionen berechnet. Dabei wurden Alter, Geschlecht, das selbst eingeschätzte Finanzwissen und die bisherige Nutzungsdauer der Anlage-App statistisch berücksichtigt.

App-Funktion	Gültiges N	Adjustierte OR	95-%-KI	p
Push-Benachrichtigungen	968	1,208	0,745–1,958	0,443
Kursalarme	978	1,914	1,142–3,209	0,014
Einfache Swipe-Käufe	911	2,178	1,325–3,580	0,002
Social-Media-Trends	980	1,552	0,935–2,577	0,089
In-App-Empfehlungen	974	1,371	0,853–2,203	0,193
E-Mail-Werbung	971	1,213	0,740–1,989	0,443

Nach der statistischen Kontrolle bleiben nur zwei Zusammenhänge signifikant:

- **Kursalarme:** adjustierte Odds Ratio 1,914, 95-%-KI 1,142–3,209, p = 0,014
- **Einfache Swipe-Käufe:** adjustierte Odds Ratio 2,178, 95-%-KI 1,325–3,580, p = 0,002

Die Zusammenhänge bei Push-Benachrichtigungen, Social-Media-Trends, In-App-Empfehlungen und E-Mail-Werbung fallen nach der Kontrolle schwächer aus. Ihre 95-%-Konfidenzintervalle schließen jeweils den Wert 1 ein, sodass sie nicht mehr statistisch signifikant sind.

Der stärkste Unterschied zeigt sich erneut bei einfachen Swipe-Käufen:

- 18,8 % der beeinflussten Nutzer:innen besitzen oder verwenden Derivate beziehungsweise Hebelprodukte.
- Ohne wahrgenommenen Einfluss liegt dieser Anteil bei 6,5 %.
- Unadjustiert sind die entsprechenden Odds in der beeinflussten Gruppe etwa 3,30-mal so hoch.

- Nach Kontrolle von Alter, Geschlecht, Finanzwissen und Nutzungsdauer beträgt die adjustierte Odds Ratio weiterhin 2,178.

Auch bei Kursalarmen bleibt ein adjustierter Zusammenhang im Einzelmodell bestehen. Nach der statistischen Kontrolle sind die Odds, Derivate oder Hebelprodukte zu besitzen beziehungsweise zu nutzen, in der beeinflussten Gruppe etwa 1,91-mal so hoch wie in der nicht beeinflussten Gruppe.

Erkenntnis: Die Rohdaten zeigen bei allen sechs App-Funktionen einen Zusammenhang mit dem Besitz beziehungsweise der Nutzung von Derivaten und Hebelprodukten. Ein Teil dieser Zusammenhänge lässt sich jedoch durch Unterschiede in Alter, Geschlecht, Finanzwissen und Nutzungsdauer erklären. Besonders robust bleiben die Zusammenhänge mit Kursalarmen und einfachen Swipe-Käufen.

5. App-Einfluss und Kryptowährungen

Im nächsten Schritt wurde geprüft, ob der wahrgenommene Einfluss einzelner App-Funktionen mit dem Besitz beziehungsweise der Nutzung von Kryptowährungen zusammenhängt. Hierzu wurden zunächst für jede App-Funktion separate Kreuztabellen berechnet.

App-Funktion	Kryptowährungen ohne Einfluss	Kryptowährungen mit Einfluss	Odds Ratio	Cramérs V
Push-Benachrichtigungen	36,1 %	40,2 %	1,19	0,041
Kursalarme	30,6 %	43,0 %	1,71	0,126
Einfache Swipe-Käufe	35,6 %	42,8 %	1,35	0,069
Social-Media-Trends	35,1 %	44,4 %	1,48	0,089
In-App-Empfehlungen	36,2 %	40,1 %	1,18	0,040
E-Mail-Werbung	37,8 %	38,2 %	1,02	0,004

Die Ergebnisse fallen uneinheitlicher aus als bei den zuvor untersuchten Verhaltensmerkmalen. Die unadjustierten Odds Ratios liegen zwischen 1,02 und 1,71, die Werte für Cramérs V zwischen 0,004 und 0,126. Insgesamt handelt es sich damit überwiegend um schwache Zusammenhänge.

Bei Betrachtung der unkorrigierten p-Werte zeigen sich signifikante Zusammenhänge für Kursalarme, einfache Swipe-Käufe und Social-Media-Trends. Push-Benachrichtigungen, In-App-Empfehlungen und E-Mail-Werbung stehen dagegen nicht in einem statistisch signifikanten Zusammenhang mit der Kryptowährungsnutzung.

Wird die im methodischen Vorgehen vorgesehene FDR-Korrektur für die sechs parallelen Kreuztabellentests berücksichtigt, bleiben die Zusammenhänge mit Kursalarmen und Social-Media-Trends signifikant. Der zunächst signifikante Zusammenhang mit

einfachen Swipe-Käufen erreicht nach dieser Korrektur das Signifikanzniveau nicht mehr.

Zur zusätzlichen Prüfung wurden sechs binär-logistische Regressionen berechnet. Dabei wurden Alter, Geschlecht, das selbst eingeschätzte Finanzwissen und die bisherige Nutzungsdauer der Anlage-App statistisch berücksichtigt.

App-Funktion	Gültiges N	Adjustierte OR	95-%-KI	p
Push-Benachrichtigungen	968	1,042	0,783–1,387	0,779
Kursalarme	978	1,659	1,252–2,197	< 0,001
Einfache Swipe-Käufe	911	1,121	0,822–1,528	0,471
Social-Media-Trends	980	1,219	0,894–1,661	0,210
In-App-Empfehlungen	974	1,154	0,875–1,522	0,310
E-Mail-Werbung	971	0,864	0,640–1,165	0,337

Nach der statistischen Kontrolle bleibt ausschließlich der Zusammenhang mit Kursalarmen signifikant. Bei Personen, die einen Einfluss von Kursalarmen wahrnehmen, sind die Odds, Kryptowährungen zu besitzen oder zu nutzen, etwa 1,66-mal so hoch wie bei Personen ohne wahrgenommenen Einfluss. Das zugehörige 95-%-Konfidenzintervall schließt den Wert 1 nicht ein.

Die Zusammenhänge mit einfachen Swipe-Käufen und Social-Media-Trends werden nach der Kontrolle deutlich schwächer und sind nicht mehr statistisch signifikant. Gleiches gilt für Push-Benachrichtigungen, In-App-Empfehlungen und E-Mail-Werbung. Ihre Konfidenzintervalle schließen jeweils den Wert 1 ein.

Erkenntnis: Der Besitz beziehungsweise die Nutzung von Kryptowährungen ist nicht generell mit jeder Form wahrgenommenen App-Einflusses verbunden. Der deutlichste und robusteste Zusammenhang besteht mit Kursalarmen. Die zunächst beobachteten Unterschiede bei Swipe-Käufen und Social-Media-Trends lassen sich zumindest teilweise durch Unterschiede in Alter, Geschlecht, Finanzwissen und Nutzungsdauer erklären.

Aus den Querschnittsdaten lässt sich keine eindeutige Wirkungsrichtung ableiten. Die Ergebnisse zeigen einen eigenständigen Zusammenhang zwischen dem wahrgenommenen Einfluss von Kursalarmen und der Kryptowährungsnutzung. Sie belegen jedoch nicht, dass Kursalarme die Entscheidung für Kryptowährungen unmittelbar verursachen.

6. Gesamtzahl einflussreicher App-Funktionen

Ergänzend wurde untersucht, ob sich das Anlageverhalten danach unterscheidet, wie viele der sechs betrachteten App-Funktionen eine Person als zumindest etwas

einflussreich bewertet. Dazu wurde für jede Person die Zahl der als einflussreich wahrgenommenen Funktionen bestimmt und in vier Gruppen zusammengefasst.

Funktionen mit Einfluss	Fälle insgesamt	Häufiges Trading	Ohne Verständnis investiert	Derivate	Krypto	Spontane Trades
0	246	18,9 %	52,9 %	6,5 %	32,1 %	9,8 %
1–2	277	26,6 %	68,6 %	8,3 %	40,1 %	5,8 %
3–4	156	34,6 %	75,6 %	9,0 %	35,9 %	16,7 %
5–6	195	57,1 %	83,9 %	21,5 %	47,2 %	40,1 %

Die Prozentwerte beziehen sich jeweils auf die gültigen Antworten innerhalb der betreffenden Einflussgruppe. Da bei den einzelnen Verhaltensmerkmalen unterschiedlich viele Angaben fehlen, weicht die zugrunde liegende Zahl gültiger Fälle teilweise geringfügig von der ausgewiesenen Gruppengröße ab. Die Analysen basieren je nach Merkmal auf 861 bis 874 gültigen Fällen.

Für alle fünf untersuchten Merkmale zeigt sich ein statistisch signifikanter Zusammenhang mit der Zahl einflussreicher App-Funktionen:

Verhaltensmerkmal	χ^2	p	Cramérs V
Häufiges Trading	77,38	< 0,001	0,300
Ohne vollständiges Produktverständnis investiert	52,26	< 0,001	0,246
Derivate beziehungsweise Hebelprodukte	30,21	< 0,001	0,186
Kryptowährungen	11,15	0,011	0,113
Häufig spontane Entscheidungen	109,00	< 0,001	0,354

Der stärkste Zusammenhang zeigt sich bei häufigen spontanen Entscheidungen, gefolgt von häufigem Trading und Investitionen ohne vollständiges Produktverständnis. Der Zusammenhang mit Kryptowährungen fällt dagegen vergleichsweise schwach aus.

Der Verlauf ist nicht bei jedem Merkmal und zwischen allen aufeinanderfolgenden Gruppen vollständig linear. Bei Kryptowährungen liegt der Anteil in der Gruppe mit drei bis vier einflussreichen Funktionen beispielsweise unter dem Anteil in der Gruppe mit ein bis zwei Funktionen. Bei spontanen Entscheidungen fällt der Anteil in der Gruppe mit ein bis zwei Funktionen zunächst niedriger aus als bei Personen ohne wahrgenommenen Einfluss.

Besonders deutlich hebt sich jedoch die Gruppe ab, die fünf oder sechs App-Funktionen als einflussreich wahrnimmt. Im Vergleich zu Personen, die keine der Funktionen als einflussreich bewerten, zeigen sich folgende Unterschiede:

- häufiges Trading: **57,1 %** gegenüber **18,9 %**
- Investitionen ohne vollständiges Produktverständnis: **83,9 %** gegenüber **52,9 %**
- Nutzung von Derivaten beziehungsweise Hebelprodukten: **21,5 %** gegenüber **6,5 %**
- Nutzung von Kryptowährungen: **47,2 %** gegenüber **32,1 %**
- häufige oder sehr häufige spontane Entscheidungen: **40,1 %** gegenüber **9,8 %**

Erkenntnis: Die Ergebnisse sprechen für einen kumulativen Zusammenhang zwischen der Zahl wahrgenommener App-Einflüsse und mehreren Formen aktiven beziehungsweise risikorelevanten Anlageverhaltens. Personen, die besonders viele App-Mechanismen als einflussreich bewerten, handeln häufiger, investieren öfter ohne vollständiges Produktverständnis, nutzen häufiger Derivate und treffen häufiger spontane Anlageentscheidungen.

Der Verlauf ist jedoch nicht bei allen Merkmalen durchgehend abgestuft. Zudem handelt es sich um Querschnittsdaten. Aus den Ergebnissen lässt sich daher weder eine eindeutige Dosis-Wirkungs-Beziehung noch ein kausaler Einfluss der App-Funktionen ableiten. Ebenso ist denkbar, dass besonders aktive oder risikobereite Anleger:innen App-Mechanismen stärker wahrnehmen oder häufiger nutzen.

7. Direkt genannte Auswirkungen der App

Die Befragten konnten unmittelbar angeben, welche Veränderungen sie seit der Nutzung ihrer Trading-App bei sich wahrnehmen. Dabei zeigt sich ein differenziertes Bild.

Die Verbindung zwischen den App-Funktionen und der Aussage **„Ich trade häufiger als vorher“** fällt insgesamt schwach aus. Nach der Korrektur für Mehrfachtests bleibt nur der Zusammenhang mit Kursalarmen statistisch signifikant. Personen, die Kursalarme als zumindest etwas einflussreich bewerten, wählten die Aussage häufiger aus als Personen ohne wahrgenommenen Einfluss dieser Funktion: 32,0 % gegenüber 23,5 %. Die Effektstärke ist mit Cramérs V = 0,093 jedoch gering.

Deutlicher sind die Zusammenhänge mit der Aussage **„Ich treffe Entscheidungen schneller oder spontaner“**. Nach der Korrektur für Mehrfachtests bleiben fünf der sechs untersuchten Funktionen signifikant. Dies betrifft Push-Benachrichtigungen, Kursalarme, einfache Swipe-Käufe, In-App-Empfehlungen und E-Mail-Werbung. Lediglich bei Social-Media-Trends ist der Zusammenhang nicht statistisch signifikant. Die stärksten Zusammenhänge zeigen sich bei Kursalarmen und In-App-Empfehlungen: Bei Kursalarmen wählten 33,6 % der beeinflussten gegenüber 22,0 % der nicht beeinflussten Nutzer:innen die Aussage aus; bei In-App-Empfehlungen waren es 35,6 % gegenüber 24,1 %. Beide Effektstärken bleiben mit Cramérs V = 0,126 im kleinen Bereich.

Am konsistentesten fällt der Zusammenhang bei der Aussage **„Ich gehe höhere Risiken ein“** aus. Sie wird bei allen sechs App-Funktionen deutlich häufiger von Personen ausgewählt, die die jeweilige Funktion als einflussreich bewerten. Sämtliche

Zusammenhänge bleiben auch nach der Korrektur für Mehrfachtests statistisch signifikant.

App-Funktion	Höhere Risiken ohne Einfluss	Höhere Risiken mit Einfluss
Push-Benachrichtigungen	10,6 %	23,2 %
Kursalarme	8,8 %	20,2 %
einfache Swipe-Käufe	10,0 %	26,0 %
Social-Media-Trends	10,1 %	25,8 %
In-App-Empfehlungen	9,7 %	22,6 %
E-Mail-Werbung	10,4 %	25,1 %

Die stärksten Zusammenhänge zeigen sich bei einfachen Swipe-Käufen und Social-Media-Trends. Bei diesen Funktionen sind die Odds für die Auswahl der Risikoaussage etwa dreimal so hoch wie bei Personen ohne wahrgenommenen Einfluss.

Damit zeigt sich eine interessante Differenz zwischen gegenwärtigem Verhalten und subjektiv wahrgenommenen Veränderungen:

- Bei der tatsächlichen gegenwärtigen Handelsfrequenz bestehen für alle sechs App-Funktionen deutliche Zusammenhänge.
- Bei der rückblickenden Aussage, seit Beginn der App-Nutzung häufiger zu handeln, sind die Zusammenhänge wesentlich schwächer; nach der Mehrfachtestkorrektur bleibt nur der Kursalarm signifikant.
- Schnellere oder spontanere Entscheidungen werden dagegen bei fünf der sechs Funktionen häufiger genannt.
- Die subjektiv berichtete Zunahme der Risikobereitschaft weist bei allen sechs Funktionen konsistente Zusammenhänge auf.

Eine mögliche Erklärung ist, dass Nutzer:innen ihren heutigen Aktivitätsgrad nicht immer als Veränderung gegenüber der Zeit vor der App-Nutzung wahrnehmen oder sich an ihr früheres Verhalten nur ungenau erinnern.

8. App-Einfluss auf Verluste & Reue

Ergänzend wurde geprüft, ob der wahrgenommene Einfluss der App-Funktionen mit bereuten Investments, endgültigen Verlusten und der allgemeinen Portfolioentwicklung zusammenhängt. Dabei wurden zunächst für jede der sechs App-Funktionen separate Kreuztabellen berechnet. Anschließend wurde untersucht, ob auch die Gesamtzahl der als einflussreich wahrgenommenen Funktionen mit diesen Ergebnissen verbunden ist. Wie in den vorherigen Analysen wurden „Weiß nicht“ und fehlende Angaben ausgeschlossen.

Bereute Investments

Als bereutes Investment wurde gewertet, wenn eine Person angab, mindestens einmal eine Anlageentscheidung im Nachhinein bereut zu haben. Bei allen sechs App-Funktionen liegt der Anteil bereuter Investments in der jeweils beeinflussten Gruppe höher.

App-Funktion	Investment bereut: kein Einfluss	Investment bereut: Einfluss	Odds Ratio	Cramérs V
Push-Benachrichtigungen	59,3 %	78,0 %	2,43	0,194
Kursalarme	54,8 %	75,1 %	2,49	0,213
einfache Swipe-Käufe	59,4 %	79,1 %	2,59	0,196
Social-Media-Trends	60,8 %	77,8 %	2,26	0,166
In-App-Empfehlungen	60,4 %	75,1 %	1,98	0,154
E-Mail-Werbung	62,0 %	75,3 %	1,87	0,133

Alle sechs Zusammenhänge bleiben auch nach der Korrektur für Mehrfachtests statistisch signifikant. Die unadjustierten Odds Ratios liegen zwischen 1,87 und 2,59. Damit sind die Odds, mindestens einmal ein Investment bereut zu haben, in sämtlichen beeinflussten Gruppen höher als in den jeweils nicht beeinflussten Gruppen.

Besonders deutlich ist der Unterschied bei einfachen Swipe-Käufen:

- 79,1 % der beeinflussten Befragten haben bereits mindestens einmal ein Investment bereut.
- Ohne wahrgenommenen Einfluss liegt dieser Anteil bei 59,4 %.
- Die entsprechenden Odds sind in der beeinflussten Gruppe etwa 2,59-mal so hoch.

Auch bei der Gesamtzahl der einflussreichen Funktionen zeigt sich ein klarer Verlauf:

Zahl einflussreicher App-Funktionen	Mindestens ein Investment bereut
0	50,8 %
1–2	65,5 %
3–4	72,1 %
5–6	82,5 %

Der Zusammenhang ist statistisch signifikant, $\chi^2(3) = 51{,}29$, $p < 0{,}001$, Cramérs V = 0,243. Anders als bei einigen zuvor untersuchten Verhaltensmerkmalen steigt der Anteil hier über alle vier Gruppen hinweg kontinuierlich an.

Zur zusätzlichen Prüfung wurde eine binär-logistische Regression berechnet. Dabei wurden Alter, Geschlecht, das selbst eingeschätzte Finanzwissen und die bisherige Nutzungsdauer der Anlage-App statistisch berücksichtigt. Pro zusätzlich als einflussreich wahrgenommener App-Funktion stiegen die adjustierten Odds, mindestens einmal ein Investment bereut zu haben, um rund 25,8 %:

- gültiges N: 862
- adjustierte OR: 1,258
- 95-%-KI: 1,164–1,359
- $p < 0{,}001$

Der Zusammenhang bleibt somit auch nach Berücksichtigung der Kontrollvariablen bestehen.

Endgültige Verlusterfahrungen

Im nächsten Schritt wurde geprüft, ob die Befragten bereits mindestens einmal einen endgültigen Verlust realisiert hatten. Die Ergebnisse fallen weniger einheitlich aus als bei bereuten Investments.

App-Funktion	Endgültiger Verlust: kein Einfluss	Endgültiger Verlust: Einfluss	Odds Ratio	Cramérs V
Push-Benachrichtigungen	53,8 %	62,0 %	1,40	0,081
Kursalarme	50,1 %	62,0 %	1,62	0,118
einfache Swipe-Käufe	53,1 %	64,2 %	1,58	0,106
Social-Media-Trends	52,5 %	65,7 %	1,73	0,123
In-App-Empfehlungen	56,7 %	57,8 %	1,05	0,011
E-Mail-Werbung	56,4 %	58,5 %	1,09	0,020

Nach der Korrektur für Mehrfachtests bleiben die Zusammenhänge mit Push-Benachrichtigungen, Kursalarmen, einfachen Swipe-Käufen und Social-Media-Trends statistisch signifikant. Für In-App-Empfehlungen und E-Mail-Werbung ergeben sich dagegen keine signifikanten Zusammenhänge. Auch die Effektstärken fallen insgesamt geringer aus als bei bereuten Investments.

Der größte Unterschied zeigt sich bei Social-Media-Trends:

- 65,7 % der beeinflussten Befragten berichten mindestens einen endgültigen Verlust.
- In der nicht beeinflussten Gruppe liegt der Anteil bei 52,5 %.
- Die entsprechenden Odds sind in der beeinflussten Gruppe etwa 1,73-mal so hoch.

Bei der Gesamtzahl der einflussreichen Funktionen ergibt sich folgendes Bild:

Zahl einflussreicher App-Funktionen	**Mindestens ein endgültiger Verlust**
0	52,5 %
1–2	56,1 %
3–4	54,3 %
5–6	65,8 %

Der Gruppenunterschied ist zwar statistisch signifikant, $\chi^2(3) = 8{,}62$, $p = 0{,}035$, die Effektstärke fällt mit Cramérs $V = 0{,}100$ jedoch gering aus. Zudem verläuft der Anteil nicht kontinuierlich: In der Gruppe mit drei bis vier einflussreichen Funktionen liegt er etwas niedriger als in der Gruppe mit ein bis zwei Funktionen.

Auch die adjustierte logistische Regression liefert keinen statistisch eindeutig abgesicherten linearen Zusammenhang:

- gültiges N: 851
- adjustierte OR: 1,067
- 95-%-KI: 0,995–1,143
- $p = 0{,}069$

Damit lässt sich auf Grundlage dieses Modells nicht bestätigen, dass jede zusätzlich als einflussreich wahrgenommene App-Funktion unabhängig von den Kontrollvariablen mit höheren Odds verbunden ist, überhaupt einen endgültigen Verlust erlebt zu haben. Das Konfidenzintervall schließt den Wert 1 ein.

Portfolioentwicklung

Die Frage nach endgültigen Verlusten bildet nur ab, ob mindestens einmal eine Anlage mit Verlust beendet wurde. Sie sagt noch nicht aus, wie sich das gesamte Portfolio entwickelt hat. Deshalb wurde zusätzlich die selbst berichtete Portfolioentwicklung untersucht.

Für die binäre Analyse wurden die Antworten folgendermaßen zusammengefasst:

- negative Portfolioentwicklung: Verlust von bis zu 10 %, Verlust von 11 bis 30 % oder Verlust von mehr als 30 %
- keine negative Portfolioentwicklung: Gewinn oder ungefähr unveränderter Portfoliowert

„Weiß ich nicht“ und „Keine Angabe“ wurden ausgeschlossen.

In der adjustierten binär-logistischen Regression war die Anzahl einflussreicher Funktionen signifikant mit einer negativen Portfolioentwicklung verbunden:

- gültiges N: 817
- adjustierte OR: 1,182
- 95-%-KI: 1,049–1,331
- p = 0,006

Pro zusätzlich als einflussreich wahrgenommener Funktion stiegen die adjustierten Odds einer negativen Portfolioentwicklung damit um rund 18,2 %. Das Gesamtmodell war ebenfalls statistisch signifikant, $\Delta\chi^2(8) = 27{,}60$, $p < 0{,}001$.

Zusätzlich wurde die Portfolioentwicklung als siebenstufige ordinale Variable ausgewertet. Die Reihenfolge reicht von einem Gewinn von mehr als 30 % bis zu einem Verlust von mehr als 30 %. Auch in diesem Modell zeigte sich ein signifikanter Zusammenhang. Pro zusätzlicher einflussreicher Funktion stiegen die adjustierten Odds, einer ungünstigeren Kategorie der Portfolioentwicklung anzugehören, um rund 19 %:

- OR für eine ungünstigere Kategorie: etwa 1,19
- 95-%-KI: etwa 1,11–1,26
- p < 0,001

Das Ergebnis der ordinalen Analyse bestätigt damit, dass sich der Zusammenhang nicht nur an der Grenze zwischen Gewinn und Verlust zeigt. Eine höhere Zahl wahrgenommener App-Einflüsse geht insgesamt mit einer Verschiebung zu ungünstigeren Portfolioentwicklungen einher.

Höhe des größten endgültigen Verlusts

Unter den Personen, die bereits einen endgültigen Verlust angegeben hatten, wurde außerdem untersucht, ob die Zahl einflussreicher App-Funktionen mit der Höhe des größten berichteten Verlusts zusammenhängt. Die Verlusthöhe wurde in vier geordneten Kategorien erfasst:

1. bis 500 Euro
2. 501 bis 2.000 Euro
3. 2.001 bis 10.000 Euro
4. mehr als 10.000 Euro

Die ordinale logistische Regression berücksichtigte erneut Alter, Geschlecht, Finanzwissen und Nutzungsdauer. Pro zusätzlich als einflussreich wahrgenommener App-Funktion stiegen die adjustierten Odds, einer höheren Verlustkategorie anzugehören, um rund 29 %:

- OR für eine höhere Verlustkategorie: 1,29
- 95-%-KI: 1,18–1,40
- $p < 0{,}001$

Dieses Ergebnis bezieht sich ausschließlich auf Befragte, die bereits einen endgültigen Verlust berichtet und dessen Höhe angegeben haben. Es bedeutet daher nicht, dass jede zusätzliche App-Funktion bei allen Befragten zwangsläufig zu einem Verlust führt. Innerhalb der Gruppe mit Verlusterfahrung besteht jedoch ein deutlicher Zusammenhang zwischen der Zahl wahrgenommener App-Einflüsse und der Höhe des größten berichteten Verlusts.

Erkenntnis: Der wahrgenommene Einfluss der App-Funktionen steht besonders konsistent mit bereuten Investments in Zusammenhang. Bei allen sechs Funktionen berichten beeinflusste Personen häufiger von mindestens einer bereuten Anlageentscheidung. Auch die Gesamtzahl einflussreicher Funktionen zeigt einen klaren, abgestuften Zusammenhang mit Investmentreue.

Für endgültige Verlusterfahrungen fällt das Bild differenzierter aus. In den einzelnen Kreuztabellen bestehen Zusammenhänge vor allem bei Push-Benachrichtigungen, Kursalarmen, Swipe-Käufen und Social-Media-Trends. Ein eigenständiger linearer Zusammenhang zwischen der Zahl einflussreicher Funktionen und dem bloßen Auftreten eines endgültigen Verlusts lässt sich nach statistischer Kontrolle jedoch nicht eindeutig bestätigen.

Gleichzeitig zeigen die weiterführenden Analysen, dass eine höhere Zahl einflussreicher Funktionen mit einer ungünstigeren gesamten Portfolioentwicklung und – unter den Personen mit Verlusterfahrung – mit einer höheren Kategorie des größten berichteten Verlusts verbunden ist. Die Ergebnisse sprechen somit nicht für einen einfachen Zusammenhang, nach dem jede zusätzliche Funktion zwangsläufig einen Verlust verursacht. Sie zeigen jedoch, dass eine stärkere wahrgenommene Einbindung verschiedener App-Mechanismen mit mehreren nachteiligen finanziellen und subjektiven Ergebnissen einhergeht.

Schlussfolgerung der Kreuztabellenanalyse zum Einfluss der DEPs

Die Ergebnisse zeigen nicht nur, dass sich ein Teil der Nutzer:innen subjektiv durch App-Funktionen beeinflusst fühlt. Die wahrgenommene Beeinflussung steht statistisch mit einer höheren Handelsfrequenz, häufigerem spontanen Entscheiden und einer höheren Verbreitung von Investitionen bei unvollständigem Produktverständnis in Zusammenhang. Diese Zusammenhänge bleiben bei allen sechs App-Funktionen auch nach statistischer Berücksichtigung von Alter, Geschlecht, selbst eingeschätztem Finanzwissen und Nutzungsdauer bestehen.

Für riskantere Anlageprodukte ergibt sich ein differenzierteres Bild:

- Derivate beziehungsweise Hebelprodukte sind in den unadjustierten Analysen bei allen sechs beeinflussten Gruppen häufiger verbreitet.
- Nach Kontrolle von Alter, Geschlecht, Finanzwissen und Nutzungsdauer bleiben nur die Zusammenhänge mit Kursalarmen und einfachen Swipe-Käufen statistisch signifikant.
- Bei Kryptowährungen zeigen sich unadjustiert Zusammenhänge mit Kursalarmen, einfachen Swipe-Käufen und Social-Media-Trends. Nach der FDR-Korrektur bleiben Kursalarme und Social-Media-Trends signifikant; nach statistischer Kontrolle besteht ausschließlich für Kursalarme ein adjustierter Zusammenhang im Einzelmodell.
- Die einzelnen App-Funktionen stehen somit nicht mit jeder Form riskanter Produktwahl gleichermaßen in Zusammenhang.

Die Gesamtzahl der als einflussreich wahrgenommenen Funktionen ist relevant. Personen, die fünf oder sechs Funktionen als einflussreich bewerten, handeln häufiger, treffen häufiger spontane Entscheidungen, investieren öfter ohne vollständiges Produktverständnis und nutzen häufiger Derivate als Personen, die keine der Funktionen als einflussreich wahrnehmen. Der Verlauf ist jedoch nicht bei allen Merkmalen durchgehend linear.

Die direkten Selbstauskünfte über Veränderungen seit der App-Nutzung ergänzen dieses Bild. Bei der Aussage „Ich trade häufiger als vorher“ bleibt nach der Mehrfachtestkorrektur nur der Zusammenhang mit Kursalarmen signifikant. Schnellere oder spontanere Entscheidungen werden dagegen bei fünf der sechs Funktionen häufiger genannt. Die Aussage, höhere Risiken einzugehen, steht mit allen sechs App-Funktionen in einem signifikanten Zusammenhang.

Die Ergebnisse stützen somit die theoretische Annahme einer verhaltensaktivierenden App-Gestaltung. Sie beweisen aber kausal nicht vollständig, dass nur die Funktionen der App das Verhalten verursachen: Besonders aktive Nutzer:innen könnten solche Funktionen zugleich häufiger verwenden und stärker wahrnehmen.

Unterschiede im Investmentverhalten unter den Altersgruppen

Wie bereits erwähnt konnten an mehreren Stellen der Umfrageergebnisse Unterschiede zwischen Altersgruppen ermittelt werden. Dies lässt sich deutlich an den Antworten der jüngsten gegenüber der ältesten Teilnehmergruppe erkennen.

Merkmal	**18–24 Jahre**	**55 Jahre und älter**
Tägliches oder wöchentliches Trading	54,8 %	25,7 %
Mindestens eine endgültige Verlusterfahrung	70,7 %	50,0 %
Investment mindestens einmal bereut	85,3 %	61,7 %
Ohne vollständiges Produktverständnis investiert	87,0 %	66,7 %
Häufig oder sehr häufig spontane Entscheidungen	37,6 %	11,0 %
Zustimmung, dass die App zum Trading verleitet	76,5 %	41,5 %
Mindestens einmal nach einer Push-Benachrichtigung investiert	69,8 %	25,3 %
Derivate beziehungsweise Hebelprodukte genutzt	21,2 %	8,2 %
Persönliche Beratung gewünscht	53,6 %	16,3 %

Das Alter ist damit einer der wichtigsten Differenzierungsfaktoren, insbesondere bei der Stärke von digitalen Impulsen auf jüngere App-Nutzer:innen. Dies entspricht der theoretischen Annahme, dass junge und weniger erfahrene Anleger:innen für niedrigschwellige und aufmerksamkeitsorientierte Trading-Mechanismen besonders empfänglich sein können. Aufgrund der kleinen Gruppe von 104 Befragten zwischen 18 und 24 Jahren ist dies aber eher ein möglicher Trend und nicht vollständig repräsentativ für die Gesamtgruppe an jungen Neobroker-Nutzer:innen belegt.

Bedeutung von Social Media und Finfluencer:innen

Social Media ist laut eigenen Aussagen für die Gesamtstichprobe eine wenig dominierende Informationsquelle.

- 13,7 % nennen Social Media als Auswahlgrund für das erste Neobroker-Investment.
- 11,3 % nennen Social Media oder Influencer:innen als Grund für die Wahl der Trading-App.
- Eigene Recherche, Nachrichten und Empfehlungen aus dem persönlichen Umfeld spielen insgesamt eine größere Rolle.

Auch hier fällt die Bedeutung innerhalb der jungen Zielgruppe erheblich höher aus:

- 27,9 % der 18- bis 24-Jährigen entschieden sich auch aufgrund von Social Media oder Influencer:innen für ihre App; bei den mindestens 55-Jährigen sind es 2,4 %.
- 79,0 % der jüngsten Gruppe geben an, dass Social Media ihre Tradingentscheidungen zumindest etwas beeinflusst; bei den mindestens 55-Jährigen sind es 25,3 %.
- Social-Media-Trends als App- oder Umfeldfunktion beeinflussen 75,0 % der 18- bis 24-Jährigen zumindest etwas, aber nur 15,2 % der ältesten Gruppe.

Die theoretische Bedeutung von Finfluencer:innen wird damit nicht durch einen starken Gesamteffekt, sondern vor allem durch einen deutlich konzentrierten Effekt bei jüngeren Nutzer:innen bestätigt.

Finanzwissen und Verständnis für Risiken

Die Befragten bewerten ihre finanzielle Kompetenz überwiegend positiv. 64,7 % der Antwortenden schätzen ihr allgemeines Finanzwissen als gut oder sehr gut ein. Weitere 30,5 % bezeichnen es als mittelmäßig, während nur 4,8 % ihr Wissen als schlecht oder sehr schlecht bewerten.

Ein ähnliches Bild ergibt sich bei der Frage, wie gut sie sich aktuell aufgestellt fühlen, um fundierte Investmententscheidungen zu treffen. Hier sehen sich 63,6 % als gut oder sehr gut vorbereitet. 30,2 % fühlen sich mittelmäßig und 6,2 % schlecht oder sehr schlecht aufgestellt.

Die Einschätzung der praktischen Entscheidungsfähigkeit fällt damit geringfügig zurückhaltender aus als die Bewertung des allgemeinen Finanzwissens. Insbesondere die Zahl der Antworten „sehr gut“ sinkt von 190 auf 171, während sich mehr Personen als „schlecht“ vorbereitet einschätzen als ihr allgemeines Finanzwissen als schlecht bewerten.

Insgesamt besteht somit eine weitgehende Übereinstimmung zwischen dem subjektiv wahrgenommenen Finanzwissen und dem Vertrauen in die eigene Entscheidungsfähigkeit. Die Nutzer:innen unterscheiden offenbar nur begrenzt zwischen allgemeinem Wissen über Finanzmärkte und der konkreten Fähigkeit, einzelne Anlageentscheidungen fundiert zu beurteilen.

Der Vergleich mit den weiteren Umfrageergebnissen zeigt jedoch, dass diese positive Selbsteinschätzung nicht immer mit einem vollständigen Verständnis der gehandelten Produkte einhergeht:

- 70,0 % der Antwortenden haben mindestens einmal investiert, ohne das Produkt vollständig zu verstehen.
- Gleichzeitig schätzen 64,7 % ihr Finanzwissen als gut oder sehr gut ein.
- Selbst unter den Befragten mit gut oder sehr gut eingeschätztem Finanzwissen haben 66,4 % bereits ohne vollständiges Produktverständnis investiert.

Die Ergebnisse belegen daher eine deutliche Diskrepanz zwischen:

- subjektivem Finanzwissen,
- konkretem Verständnis einzelner Anlageprodukte.

Ein gutes allgemeines Kompetenzgefühl schützt also offenbar nicht zuverlässig vor Entscheidungen bei unvollständigem Produktwissen.

Personen mit hohem selbst eingeschätztem Wissen berichten sogar häufiger mindestens einen Verlust. Das bedeutet nicht, dass Wissen Verluste verursacht. Wahrscheinlicher ist, dass diese Personen aktiver handeln, mehr Kapital einsetzen oder mehr Produkte ausprobieren.

Unterschiede bei Nutzer:innen von Derivaten und Kryptowährungen

Starke Unterschiede in mehreren Aspekten der Umfrage zeigen sich neben dem Alter auch bei dem Investmentverhalten von Personen, die Derivate als Investment nutzen, und solchen, die sie meiden.

Merkmal	**Derivate**	**Keine Derivate**
Tägliches oder wöchentliches Trading	76,5 %	25,5 %
Mindestens eine endgültige Verlusterfahrung	84,2 %	53,5 %
Investment mindestens einmal bereut	86,3 %	63,9 %
Häufig oder sehr häufig spontane Entscheidungen	42,2 %	12,2 %
Geplante Haltedauer von höchstens zwei Jahren	37,1 %	21,9 %
Nach eigener Aussage höhere Risiken eingegangen	35,3 %	12,8 %

Derivative Produkte bilden damit die deutlichste empirisch erkennbare Risikogruppe innerhalb der Befragung.

Auch bei Kryptowährungen zeigen sich erhöhte Werte:

- endgültige Verlusterfahrung bei Kryptonutzer:innen: 67,5 %,
- bei Personen ohne Kryptowährungen: 49,9 %.

Kurzfristige vs. langfristige Strategien

In der Selbstdarstellung der Teilnehmer:innen sind langfristige Investments ein starker Bestandteil der Investmentstrategie:

- Unter den Personen mit gültiger Antwort planen 60,4 %, ihre Investments länger als fünf Jahre zu halten.

- 16,0 % planen eine Haltedauer von drei bis fünf Jahren.
- 16,6 % planen ein bis zwei Jahre.
- 7,0 % planen weniger als ein Jahr.

Das Gesamtbild ist damit stärker langfristig ausgerichtet, als es die theoretische Darstellung von Neobroker-Nutzer:innen als überwiegend kurzfristige Trader:innen erwarten lässt.

Allerdings hängt die angegebene Haltedauer deutlich mit der Handelsfrequenz zusammen:

- Bei einer geplanten Haltedauer von weniger als einem Jahr handeln 41,9 % täglich oder wöchentlich.
- Bei einer Haltedauer von ein bis zwei Jahren sind es 55,8 %.
- Bei einer Haltedauer von mehr als fünf Jahren sind es noch 22,5 %.

Langfristige Anlageziele schließen regelmäßiges Trading somit nicht aus. Ein Teil der monatlichen Aktivitäten kann zudem aus Sparplänen bestehen und sollte nicht automatisch als spekulatives Trading interpretiert werden.

Reue über Anlageentscheidungen über einen Neobroker

66,2 % der gültig Antwortenden haben mindestens selten eine Investmententscheidung über die App bereut.

Bezogen auf die 655 gültigen Antworten der 666 Betroffenen werden als Gründe genannt:

- zu spät gekauft oder verkauft: 47,2 %,
- zu impulsiv entschieden: 43,7 %,
- zu hohes Risiko eingegangen: 35,9 %,
- zu wenig Wissen oder Verständnis: 28,7 %,
- falschen Informationen oder Trends gefolgt: 25,2 %.

Unvollständiges Produktverständnis ist in der gemeinsamen statistischen Analyse der stärkste untersuchte Faktor für bereute Entscheidungen. Die Ergebnisse stützen die Annahme, dass nicht nur berichtete realisierte Verluste, sondern auch Timingfehler, emotionale Entscheidungen und nachträgliche Unsicherheit wichtige Folgen der App-Nutzung darstellen.

Gewünschte Unterstützung

Nur 25,6 % der Teilnehmer:innen wünschen ausdrücklich persönliche Ansprechpartner:innen. Diese hohe Zahl an Personen, die Hilfe theoretisch ablehnen,

passt zu dem Nutzerprofil von Neobrokern als Anleger:innen, die selbst Kontrolle über ihre Investitionen haben möchten. Gleichzeitig glauben 56,2 %, dass eine Beratung zumindest teilweise zu besseren Entscheidungen beitragen könnte. Unter Personen, die ihr Finanzwissen nicht als gut oder sehr gut einschätzen, halten 70,6 % eine Beratung zumindest teilweise für hilfreich; bei Personen mit hoher Selbsteinschätzung sind es 48,9 %.

Die Gründe für die hohe Ablehnung liegen also nicht zwangsläufig darin, dass eine persönliche Beratung als wenig hilfreich angesehen wird. Möglicherweise lehnen die Teilnehmer:innen diese aufgrund des erwarteten damit verbundenen Aufwands und möglicher Mehrkosten ab. Eine vorherige Rücksprache mit Berater:innen steht in einem direkten Kontrast zu einem der stärksten Beweggründe für die Nutzung von Neobrokern als Hauptanlageform: der schnellen und einfachen Bedienung mit möglichst wenigen Schritten als Reibungspunkten, bevor ein Trade durchgeführt werden kann.

Dennoch geben die meisten Befragten mehrere Faktoren an, die ihre Investmententscheidungen unterstützen können. Nur 13,4 % glauben, dass sie keine weitere Unterstützung benötigen.

Gewünscht sind unter den 990 gültigen Antworten der Frage nach Dingen, die die eigenen Investments verbessern würden:

- mehr Finanzwissen zu Grundlagen und Märkten: 53,0 %
- klare Strategien für langfristigen Vermögensaufbau: 38,5 %
- unabhängige und verständliche Finanzbildung: 31,6 %
- mehr Transparenz bei Kosten und Produkten: 28,4 %
- mehr Zeit für fundierte Entscheidungen: 27,7 %
- besseres Risikoverständnis: 24,7 %
- persönliche Beratung: 17,3 %

Der Bedarf richtet sich damit stärker auf Wissen, Strategien, Transparenz und Entscheidungsunterstützung als auf eine klassische dauerhafte Anlageberatung.

Übergreifende Schlussfolgerung der Umfrageanalyse

Neobroker erfüllen eindeutig eine Zugangs- und Aktivierungsfunktion: Sie sind für die Mehrheit (72,0 %) der zentrale Anlageweg und für mehr als die Hälfte (53,4 %) der erste Kontakt mit dem Kapitalmarkt.

Die Nutzung führt dabei nicht pauschal zu einer negativen Gesamtperformance. Dennoch sind einzelne endgültige Verluste, bereute Entscheidungen und Investments ohne vollständiges Produktverständnis sehr weit verbreitet.

Risiken konzentrieren sich insbesondere bei:

- jungen Nutzer:innen,
- täglichem oder wöchentlichem Trading,
- Derivaten und Kryptowährungen,
- unvollständigem Produktverständnis,
- einer starken wahrgenommenen Beeinflussung durch App-Funktionen.

Die Daten bestätigen zudem einen Zusammenhang zwischen digitalen Handelsimpulsen und häufigeren beziehungsweise spontaneren Entscheidungen.

Dennoch verfolgen nicht alle Neobroker-Nutzer:innen kurzfristige oder spekulative Strategien. Die Mehrheit plant langfristige Haltedauern, und exklusive Neobroker-Nutzer:innen handeln sogar weniger häufig und riskant als Mehrkanalnutzer:innen.

Die zentrale empirische Antwort lautet daher: Neobroker werden in hohem Maße für langfristig orientierten Vermögensaufbau genutzt und gehen in der untersuchten Stichprobe überwiegend mit einer positiv berichteten Portfolioentwicklung einher. Zugleich schaffen sie ein Umfeld, in dem besonders junge, aktive und produktunerfahrene Anleger leichter in riskantes oder impulsives Verhalten geraten können.

Beantwortung der Leitfragen

Die Einleitung formuliert als übergeordnete Forschungsfrage, ob Neobroker und Trading-Apps vor allem den Zugang zum Kapitalmarkt erleichtern oder zugleich Verhaltensweisen begünstigen, die mit häufigeren Transaktionen, höheren Risiken, impulsiven Entscheidungen und finanziellen Verlusten verbunden sind. Daraus ergeben sich drei zentrale Leitfragen: Erstens ist zu klären, wie verbreitet Verlusterfahrungen unter den Nutzer:innen sind und welche Faktoren mit ihnen zusammenhängen. Zweitens wird untersucht, welche Rolle App-Design, Gamification, Push-Benachrichtigungen, Kursalarme und vereinfachte Kaufprozesse für das Anlageverhalten spielen. Drittens ist zu bestimmen, welche Strategien die Nutzer:innen verfolgen und bei welchen Gruppen sich risikorelevante Verhaltensweisen besonders konzentrieren.

Die Ergebnisse erlauben kein eindeutiges positives oder negatives Gesamturteil. Sie zeigen vielmehr, dass Neobroker gleichzeitig eine Zugangs- und Aktivierungsfunktion erfüllen und ein Umfeld schaffen, in dem bestimmte Verhaltensrisiken verstärkt auftreten können. Für die Beantwortung der Leitfragen müssen deshalb Kapitalmarktzugang, finanzielle Ergebnisse, digitale Einflussmechanismen sowie unterschiedliche Nutzerstrategien gemeinsam betrachtet werden.

Kapitalmarktzugang und finanzielle Teilhabe

Die Annahme, dass Neobroker den Zugang zum Kapitalmarkt erleichtern, wird durch die Befragung deutlich bestätigt. Für 72,0 Prozent der Teilnehmer:innen ist der Neobroker der hauptsächlich genutzte Anlageweg, während 35,6 Prozent ausschließlich über einen solchen Anbieter investieren. Besonders aussagekräftig ist, dass 53,4 Prozent ihre erste Investmenterfahrung über einen Neobroker gemacht haben. Trading-Apps sind damit für einen erheblichen Teil der Nutzer:innen nicht lediglich ein ergänzender Vertriebskanal, sondern der eigentliche Einstieg in den Wertpapierhandel.

Diese Aktivierungswirkung beschränkt sich nicht auf junge und besonders digital affine Personen. Auch unter den mindestens 55-Jährigen gab ein erheblicher Anteil an, erstmals über eine App investiert zu haben. Neobroker können somit über verschiedene Altersgruppen hinweg Menschen erreichen, die zuvor nicht am Kapitalmarkt beteiligt waren. Niedrige Gebühren, geringe Mindestbeträge, mobile Verfügbarkeit und vereinfachte Prozesse tragen dazu bei, bestehende Zugangshürden zu reduzieren.

Auch die konkrete Nutzung lässt sich nicht pauschal als kurzfristige Spekulation beschreiben. ETFs sind mit 80,8 Prozent das am häufigsten genutzte Anlageprodukt. Von den Befragten mit gültiger Antwort planen 60,4 Prozent, ihre Investments länger als fünf Jahre zu halten. Zudem berichten 44,2 Prozent, seit der Nutzung regelmäßiger zu investieren, beispielsweise über Sparpläne, und 40,5 Prozent geben an, sich stärker mit Finanzthemen zu beschäftigen.

Diese Ergebnisse stützen die Annahme, dass Neobroker finanzielle Teilhabe fördern und von vielen Nutzer für einen langfristig orientierten Vermögensaufbau eingesetzt werden.

Zugleich verdeutlichen sie, dass der technisch einfache Zugang nicht automatisch mit fundierten Anlageentscheidungen gleichzusetzen ist. Die Ergebnisse zeigen vielmehr, dass langfristig orientierter Vermögensaufbau eng mit dem Produktverständnis, der Handelsfrequenz und der gewählten Anlagestrategie zusammenhängt.

Verluste und Performance

Die Frage, ob Anleger:innen durch Neobroker häufiger Geld verlieren, kann auf Grundlage der Untersuchung nur differenziert beantwortet werden. Von den Befragten mit gültiger Antwort haben 56,6 Prozent bereits mindestens einen endgültigen Verlust über einen Neobroker realisiert. Gleichzeitig berichten jedoch nur 9,2 Prozent insgesamt von einer negativen Portfolioentwicklung. Unter den Personen, die ihre Portfolioentwicklung einschätzen konnten, geben 83,4 Prozent eine positive Entwicklung an.

Diese Ergebnisse widersprechen sich nicht. Auch 55,5 Prozent der Personen mit insgesamt positiver Portfolioentwicklung hatten bereits mindestens einen einzelnen Verlust realisiert. Ein Verlusttrade ist deshalb nicht mit einem dauerhaft erfolglosen Portfolio gleichzusetzen. Einzelne Verluste gehören grundsätzlich zum Wertpapierhandel und können auch bei insgesamt erfolgreichen Anlagestrategien auftreten.

Dennoch zeigt die Untersuchung, dass Verluste nicht zufällig über alle Nutzergruppen verteilt sind. In der statistischen Analyse ist tägliches oder wöchentliches Trading unter Berücksichtigung weiterer Merkmale mit 1,91-mal so hohen Odds verbunden, bereits einen endgültigen Verlust erlitten zu haben. Bei Nutzer:innen von Derivaten oder Hebelprodukten liegen die Odds 2,91-mal, bei Nutzer:innen von Kryptowährungen 1,64-mal so hoch. Wer bereits ohne vollständiges Produktverständnis investiert hat, weist 2,56-mal so hohe Odds einer Verlusterfahrung auf.

Auch die von den Betroffenen selbst genannten Verlustursachen weisen in diese Richtung. Besonders häufig wurden Einzelaktien beziehungsweise mangelnde Diversifikation, allgemeine Marktentwicklungen, impulsive Entscheidungen, Kryptowährungen und Derivate genannt. Zu häufiges Trading wurde von den Befragten seltener ausdrücklich als Verlustursache angegeben. Der Vergleich mehrerer Antworten zeigt jedoch, dass eine hohe Handelsfrequenz unabhängig von weiteren untersuchten Merkmalen deutlich mit Verlusterfahrungen verbunden ist. Einige Anleger:innen könnten die Bedeutung ihrer Handelsaktivität für finanzielle Verluste daher unterschätzen.

Neben realisierten Verlusten sind auch subjektiv problematische Anlageentscheidungen weit verbreitet. 66,2 Prozent haben mindestens einmal eine über den Neobroker getroffene Entscheidung bereut. Besonders häufig wurden ein zu später Kauf oder Verkauf, impulsives Handeln, ein zu hohes Risiko, unzureichendes Wissen und das Folgen falscher Informationen oder Trends genannt. Gleichzeitig haben 70,0 Prozent mindestens einmal in ein Produkt investiert, das sie nach eigener Einschätzung nicht vollständig verstanden hatten.

Dieser Befund steht in einem auffälligen Verhältnis zur Selbsteinschätzung des Finanzwissens. Insgesamt bewerten 64,7 Prozent ihr allgemeines Finanzwissen als gut oder sehr gut. Selbst unter diesen Befragten hatte jedoch die Mehrheit bereits ohne vollständiges Produktverständnis investiert. Ein hohes subjektives Kompetenzgefühl schützt somit nicht zuverlässig vor Entscheidungen, bei denen Funktionsweise, Kosten oder Risiken eines konkreten Produkts nicht vollständig verstanden werden.

Die erste Leitfrage lässt sich damit folgendermaßen beantworten: Verlusterfahrungen sind unter Neobroker-Nutzer:innen weit verbreitet, die Gesamtperformance wird jedoch mehrheitlich positiv eingeschätzt. Die Untersuchung belegt daher nicht, dass die Neobroker-Nutzung grundsätzlich zu negativen Portfolios führt. Sie zeigt aber deutlich, dass hohe Handelsfrequenz, spekulative Produkte und unvollständiges Produktverständnis häufiger mit bereits erlebten realisierten Verlusten verbunden sind. Da keine vergleichbare Kontrollgruppe ohne Neobroker-Nutzung untersucht wurde, lässt sich zudem nicht feststellen, ob dieselben Personen über eine klassische Bank oder einen anderen Anlageweg bessere Ergebnisse erzielt hätten.

App-Design und digitale Impulse

Die zweite Leitfrage betrifft den Einfluss digitaler Aktivierungsmechanismen auf das Anlageverhalten. Mehr als die Hälfte der Befragten mit gültiger Antwort stimmt zumindest eher der Aussage zu, ihre App verleite sie zum Traden oder Investieren. Kursalarme werden von 58,4 Prozent als zumindest etwas einflussreich wahrgenommen, In-App-Empfehlungen von 43,3 Prozent und Push-Benachrichtigungen von 39,3 Prozent. Insgesamt haben 36,7 Prozent mindestens einmal aufgrund einer Push-Benachrichtigung investiert.

Der Einfluss dieser Funktionen ist damit nicht bei allen Nutzer:innen gleich stark, kann jedoch auch nicht als Randphänomen betrachtet werden. Besonders relevant sind die statistischen Zusammenhänge mit der Handelsfrequenz, spontanen Entscheidungen und Investitionen ohne vollständiges Produktverständnis. Bei allen sechs untersuchten App-Funktionen handeln Personen, die sich durch die jeweilige Funktion beeinflusst fühlen, häufiger und treffen öfter spontane Anlageentscheidungen als Personen ohne wahrgenommenen Einfluss. Ebenso haben sie häufiger bereits in ein Produkt investiert, dessen Funktionsweise sie nicht vollständig verstanden.

Besonders ausgeprägt sind die Unterschiede bei stark vereinfachten Kaufprozessen. Von den Personen, die sich durch einfache Swipe-Käufe beeinflusst fühlen, handeln 52,2 Prozent täglich oder wöchentlich. In der Gruppe ohne wahrgenommenen Einfluss liegt dieser Anteil bei 22,4 Prozent. Häufige oder sehr häufige spontane Entscheidungen berichten 33,2 Prozent der beeinflussten gegenüber 7,9 Prozent der nicht beeinflussten Nutzer:innen. Auch nach statistischer Berücksichtigung von Alter, Geschlecht, selbst eingeschätztem Finanzwissen und Dauer der App-Nutzung bleiben diese Zusammenhänge bestehen.

Die Ergebnisse entsprechen damit dem theoretischen Prinzip der „Removal of Friction“. Werden administrative und technische Hürden reduziert, erleichtert dies zunächst den

Zugang zum Investieren. Werden jedoch auch Bestätigungs- und Reflexionsschritte vor komplexen oder riskanten Transaktionen weitgehend entfernt, kann zugleich die Schwelle zur inhaltlichen Prüfung sinken. Ein vereinfachter Kaufprozess reduziert dann nicht nur unnötigen Aufwand, sondern möglicherweise auch den Zeitraum, in dem Anleger:innen eine Entscheidung überdenken.

Darüber hinaus zeigen sich kumulative Zusammenhänge. Unter Personen, die fünf oder sechs App-Funktionen als einflussreich bewerten, handeln 57,1 Prozent häufig, während dieser Anteil bei Personen ohne wahrgenommenen App-Einfluss bei 18,9 Prozent liegt. Häufige spontane Entscheidungen berichten 40,1 Prozent gegenüber 9,8 Prozent. Ohne vollständiges Produktverständnis haben 83,9 Prozent der stark beeinflussten gegenüber 52,9 Prozent der nicht beeinflussten Nutzer:innen investiert.

Auch bereute Entscheidungen nehmen mit der Zahl der wahrgenommenen App-Einflüsse kontinuierlich zu. Während 50,8 Prozent der Personen ohne entsprechenden Einfluss mindestens eine Anlageentscheidung bereut haben, liegt der Anteil bei Personen, die fünf oder sechs Funktionen als einflussreich bewerten, bei 82,5 Prozent. Die Zahl einflussreicher Funktionen steht außerdem mit einer ungünstigeren selbst berichteten Portfolioentwicklung und innerhalb der Gruppe mit Verlusterfahrung mit einer höheren Kategorie des größten Verlusts in Zusammenhang.

Diese Ergebnisse sprechen dafür, Trading-Apps nicht als vollständig neutrale Ausführungswerkzeuge zu betrachten. Ihre Benutzeroberflächen strukturieren Aufmerksamkeit, bestimmen die Sichtbarkeit bestimmter Produkte und reduzieren die Zahl der notwendigen Handlungsschritte. Die Gestaltung beeinflusst damit den Kontext, in dem Entscheidungen getroffen werden.

Aus den Querschnittsdaten lässt sich jedoch keine eindeutige Kausalrichtung ableiten. App-Funktionen können impulsives und häufiges Handeln begünstigen. Ebenso ist denkbar, dass besonders aktive, risikobereite oder impulsive Personen diese Funktionen häufiger nutzen und ihren Einfluss deshalb stärker wahrnehmen. Die zweite Leitfrage kann daher dahingehend beantwortet werden, dass zwischen digitalen Aktivierungsmechanismen und mehreren risikorelevanten Verhaltensweisen deutliche und statistisch robuste Zusammenhänge bestehen. Ein unmittelbarer kausaler Nachweis, dass einzelne Funktionen diese Verhaltensweisen oder finanzielle Verluste verursachen, ist mit dem gewählten Untersuchungsdesign jedoch nicht möglich.

Strategien, Zielgruppen und soziale Medien

Die dritte Leitfrage zeigt, dass Neobroker-Nutzer:innen keine einheitliche Anlagestrategie verfolgen. Ein großer Teil investiert langfristig, nutzt ETFs oder Sparpläne und berichtet eine positive Portfolioentwicklung. Daneben besteht eine kleinere, aber deutlich erkennbare Gruppe, bei der hohe Handelsfrequenz, kurze Entscheidungshorizonte, spekulative Produkte, starke digitale Beeinflussung und unvollständiges Produktverständnis zusammentreffen.

Besonders klare Unterschiede zeigen sich beim Alter. Die 18- bis 24-Jährigen handeln häufiger, berichten häufiger Verluste und bereute Entscheidungen und haben öfter ohne vollständiges Produktverständnis investiert als Befragte ab 55 Jahren. Sie stimmen zudem wesentlich häufiger der Aussage zu, ihre App verleite sie zum Trading, und reagieren häufiger mit einer Transaktion auf Push-Benachrichtigungen. Auch Derivate und Hebelprodukte sind in der jüngsten Gruppe stärker verbreitet.

Die Bedeutung sozialer Medien fällt für die Gesamtstichprobe weniger dominant aus, als es die theoretische Diskussion zunächst vermuten lassen könnte. Eigene Analysen, klassische Nachrichten und Empfehlungen aus dem persönlichen Umfeld werden insgesamt häufiger als einflussreich bezeichnet al.s Social Media. Finfluencer:innen und Social-Media-Trends stellen daher nicht für alle Neobroker-Nutzer:innen die zentrale Entscheidungsgrundlage dar.

Innerhalb der jüngsten Altersgruppe zeigt sich jedoch ein deutlich anderes Bild. Unter den 18- bis 24-Jährigen geben 79,0 Prozent an, dass Social Media ihre Tradingentscheidungen zumindest etwas beeinflusst. Bei den mindestens 55-Jährigen liegt dieser Anteil bei 25,3 Prozent. Auch Social-Media-Trends innerhalb oder im Umfeld der App beeinflussen 75,0 Prozent der jüngsten, aber nur 15,2 Prozent der ältesten Gruppe zumindest etwas. Die im Theorieteil beschriebene Verbindung zwischen Trading-Apps, digitaler Aufmerksamkeit und Social-Media-Mechanismen wird damit vor allem für jüngere Nutzer:innen bestätigt.

Gleichzeitig darf junges Alter nicht automatisch mit problematischem Verhalten gleichgesetzt werden. Auch die ausschließliche Nutzung eines Neobrokers ist kein hinreichender Risikoindikator. Ausschließliche Neobroker-Nutzer:innen handeln in der Stichprobe seltener, berichten weniger spontane Entscheidungen und weisen geringere Verlustraten auf als Personen, die mehrere Anlagewege parallel verwenden. Vermutlich gehören Mehrkanalnutzer:innen häufiger zu den besonders aktiven Anleger:innen mit mehreren Depots, einer größeren Produktauswahl und einer höheren Handelsintensität. Diese Erklärung bleibt jedoch eine Interpretation.

Die dritte Leitfrage lässt sich somit dahingehend beantworten, dass die Mehrheit der Nutzer:innen nicht einheitlich kurzfristig oder spekulativ handelt. Die empirisch am deutlichsten abgrenzbare Risikogruppe besteht auch nicht pauschal aus allen jungen oder allen ausschließlichen Neobroker-Nutzer:innen. Risiken verdichten sich insbesondere dort, wo mehrere Faktoren zusammentreffen: häufiges Trading, Derivate oder Kryptowährungen, unvollständiges Produktverständnis, kurze Entscheidungshorizonte und eine starke Reaktion auf digitale Impulse.

Insgesamt bestätigen die Ergebnisse damit das in der Einleitung formulierte Spannungsfeld. Neobroker erleichtern den Zugang zum Kapitalmarkt und können langfristiges Investieren fördern. Dieselben Eigenschaften, die diesen Zugang ermöglichen, können jedoch bei bestimmten Nutzer:innen spontane, häufige oder riskante Entscheidungen begünstigen.

Implikationen für Finanzbildung, Beratung und Anlegerschutz

Aus den Ergebnissen folgt nicht, dass einfache und kostengünstige Anlageangebote grundsätzlich eingeschränkt werden sollten. Ein solcher Ansatz könnte die deutlich erkennbare Zugangs- und Teilhabefunktion von Neobrokern schwächen. Langfristiges und breit diversifiziertes Investieren sollte weiterhin auch mit geringen Beträgen und ohne unnötige administrative Hürden möglich bleiben.

Bei komplexen, gehebelten oder besonders volatilen Produkten erscheinen dagegen zusätzliche Schutzmechanismen sinnvoll. Dazu gehören verständliche Produkt- und Kosteninformationen, sichtbar dargestellte Verlust- und Risikoszenarien, angemessene Wissensprüfungen sowie kurze Bestätigungs- oder Reflexionsschritte vor besonders riskanten Transaktionen. Kursalarme, Push-Nachrichten und Produktempfehlungen sollten zudem nicht ausschließlich Handelsaktivität erzeugen, sondern Risiken und längerfristige Auswirkungen in vergleichbarer Deutlichkeit darstellen.

Grundlegende Veränderungen der auf schnelle und reibungsarme Nutzung ausgerichteten Geschäfts- und Plattformmodelle können kurzfristig jedoch nicht vorausgesetzt werden. Der Anlegerschutz sollte deshalb nicht allein davon abhängig gemacht werden, dass Anbieter ihre Apps freiwillig umfassend umgestalten. Neben regulatorischen und gestalterischen Maßnahmen muss vor allem die Fähigkeit der Nutzer:innen gestärkt werden, digitale Impulse, Produkte und Risiken selbstständig einzuordnen.

Eine zentrale Bedeutung kommt daher der Finanzbildung zu. Anleger:innen benötigen nicht nur allgemeines Wissen über Finanzmärkte, sondern insbesondere ein konkretes Verständnis für Diversifikation, Kosten, Verlustwahrscheinlichkeiten, Hebelwirkungen, Haltedauern und den Unterschied zwischen langfristigem Investieren und kurzfristigem Trading. Ebenso wichtig ist die Fähigkeit, Werbeimpulse, Kursalarme, Social-Media-Trends und Produktempfehlungen kritisch zu bewerten.

Finanzbildung sollte möglichst früh einsetzen und nicht auf eine einmalige Vermittlung abstrakter Grundlagen beschränkt bleiben. Sinnvoll ist eine kontinuierliche und an konkreten Entscheidungssituationen orientierte Unterstützung. Anleger:innen sollten beispielsweise prüfen können, ob ein Produkt zu ihren Zielen und ihrer Risikobereitschaft passt, welche Verluste realistisch möglich sind und ob sie die Funktionsweise auch unabhängig von einer vereinfachten App-Darstellung erklären können.

Der entsprechende Unterstützungsbedarf wird durch die Befragung deutlich. 53,0 Prozent nennen mehr Finanzwissen zu Grundlagen und Märkten als hilfreiche Maßnahme. Weitere 38,5 Prozent wünschen sich klarere Strategien für den langfristigen Vermögensaufbau, 31,6 Prozent eine unabhängige und verständliche Finanzbildung und 28,4 Prozent mehr Transparenz bei Kosten und Produkten. Nur 13,4 Prozent geben an,

bereits ausreichend informiert zu sein und keine zusätzliche Unterstützung zu benötigen.

Persönliche Anlageberatung ist in diesem Zusammenhang nicht als überholt oder unnötig zu bewerten. Zwar wünschen sich nur 25,6 Prozent ausdrücklich eine feste persönliche Ansprechperson. Gleichzeitig gehen jedoch 56,2 Prozent davon aus, dass eine Beratung zumindest teilweise zu besseren Anlageentscheidungen beitragen könnte. Der Unterschied zwischen diesen Werten deutet darauf hin, dass viele Nutzer:innen ihre Investments grundsätzlich selbst steuern möchten, professionelle Unterstützung in bestimmten Situationen aber dennoch als sinnvoll einschätzen.

Persönliche Beratung kann insbesondere bei komplexen Produkten, größeren Anlagebeträgen, unklaren Risikoprofilen oder langfristigen Vorsorgezielen einen Mehrwert bieten. Sie steht nicht im Gegensatz zur selbstständigen Nutzung eines Neobrokers, sondern kann diese ergänzen. Eine Beratung kann individuelle finanzielle Voraussetzungen berücksichtigen, Zielkonflikte sichtbar machen und dabei helfen, eine übergreifende Strategie zu entwickeln, die über einzelne Kaufentscheidungen hinausgeht.

Neben einer dauerhaften persönlichen Betreuung kommen auch niedrigschwellige und anlassbezogene Formate infrage. Dazu gehören digitale Beratungsgespräche, eine einmalige Überprüfung der Anlagestrategie, unabhängige Erstgespräche oder eine fachliche Einordnung komplexer Produkte. Entscheidend ist, dass Anleger:innen erkennen können, wann eigenständiges Handeln ausreicht und wann externe Expertise sinnvoll ist.

Finanzbildung und persönliche Beratung erfüllen dabei unterschiedliche, aber komplementäre Aufgaben. Finanzbildung stärkt die allgemeine Fähigkeit zu eigenständigen und reflektierten Entscheidungen. Persönliche Beratung kann individuelle Ziele, finanzielle Voraussetzungen und konkrete Risiken einordnen. Beide Ansätze können dazu beitragen, dass der erleichterte Kapitalmarktzugang nicht nur technisch genutzt wird, sondern auch zu langfristig tragfähigen Entscheidungen führt.

Methodische Einordnung und weiterer Forschungsbedarf

Das gewählte Studiendesign schafft eine breite empirische Grundlage, um das Anlageverhalten und die Erfahrungen von Neobroker-Nutzer:innen in Deutschland zu untersuchen. Mit 1.021 volljährigen Teilnehmer:innen aus dem YouGov-Panel umfasst die Befragung eine große Stichprobe und ermöglicht sowohl die deskriptive Darstellung zentraler Nutzungsmuster als auch differenzierte Gruppenvergleiche und statistische Zusammenhangsanalysen.

Die Zusammensetzung der Stichprobe ist bei der Interpretation der Ergebnisse zu berücksichtigen. Mit einem Männeranteil von 76 Prozent und einer vergleichsweise starken Besetzung älterer Altersgruppen bildet sie bestimmte Nutzergruppen stärker ab als andere. Da keine Gewichtungsvariable vorliegt, sind insbesondere die ermittelten Häufigkeits- und Verbreitungswerte in erster Linie als Ergebnisse für die untersuchte

Stichprobe zu verstehen. Für die Analyse von Unterschieden zwischen Nutzergruppen und von Zusammenhängen zwischen App-Einfluss, Handelsverhalten, Produktwahl und Verlusterfahrungen bietet der Datensatz dennoch eine umfangreiche und aussagekräftige Grundlage.

Wie bei Querschnittsuntersuchungen üblich, lassen sich aus Zusammenhängen keine eindeutigen Aussagen über die zeitliche Abfolge und die Wirkungsrichtung ableiten. So können Push-Benachrichtigungen oder stark vereinfachte Kaufprozesse impulsive Entscheidungen begünstigen. Gleichzeitig ist denkbar, dass besonders aktive oder risikobereite Anleger:innen solche Funktionen häufiger nutzen und ihren Einfluss bewusster wahrnehmen. Die Studie beantwortet daher vor allem die Frage, welche Verhaltensweisen und App-Einflüsse miteinander verbunden sind. Die genaue Richtung dieser Beziehungen kann in der weiteren Forschung in darauf aufbauenden Untersuchungen weiter vertieft werden.

Bei Angaben zur Portfolioentwicklung, Verlusthöhe, Handelsfrequenz und zum Finanzwissen ist zu berücksichtigen, dass sie nicht anhand tatsächlicher Depotdaten oder standardisierter Wissenstests überprüft wurden. Unterschiedliche Einstiegszeitpunkte, Marktphasen und persönliche Berechnungsweisen können die Einschätzung der eigenen Performance beeinflussen.

Ohne eine Vergleichsgruppe zeigt die Studie zudem nur, bei welchen Nutzer:innen und unter welchen Bedingungen sich risikorelevante Merkmale konzentrieren. Sie kann hingegen nicht unmittelbar bestimmen, ob vergleichbare Anleger:innen über traditionelle Banken oder klassische Online-Broker seltener Verluste erlitten oder andere Entscheidungen getroffen hätten. Für einen solchen Vergleich wäre ein erweitertes Untersuchungsdesign mit möglichst ähnlichen Anlegergruppen erforderlich.

Für die weitere Forschung wären insbesondere Längsschnittstudien geeignet, die das Verhalten derselben Anleger:innen über einen längeren Zeitraum beobachten. Experimentelle Untersuchungen könnten prüfen, wie unterschiedliche App-Oberflächen, Risikohinweise und Bestätigungsschritte konkrete Entscheidungen verändern. Ergänzend wären anonymisierte Transaktionsdaten hilfreich, um Selbstauskünfte mit tatsächlicher Handelsfrequenz, Haltedauer und Performance abzugleichen. Repräsentativ gewichtete Stichproben und standardisierte Tests des Finanz- und Produktwissens könnten außerdem zeigen, wie stark die beobachteten Zusammenhänge auf die Gesamtgruppe deutscher Neobroker-Nutzer:innen übertragbar sind.

Fazit

Die vorliegende Studie zeigt, dass Neobroker und Trading-Apps den privaten Wertpapierhandel nicht nur technisch vereinfachen, sondern den Zugang zum Kapitalmarkt und den Prozess finanzieller Entscheidungen grundlegend verändern. Die in der Einleitung formulierte Ausgangsfrage lässt sich nicht mit einem eindeutigen Entweder/Oder beantworten. Neobroker erfüllen eine wichtige Zugangs- und Aktivierungsfunktion, schaffen jedoch gleichzeitig ein Entscheidungsumfeld, in dem bestimmte Nutzer:innen leichter zu häufigem, spontanem oder risikoreichem Handeln übergehen.

Die positive Zugangswirkung ist deutlich erkennbar. Für viele Befragte stellt der Neobroker den wichtigsten oder sogar ersten Zugang zum Kapitalmarkt dar. Ein erheblicher Teil nutzt ETFs, Sparpläne und langfristige Haltedauern. Die Nutzung führt deshalb nicht pauschal zu spekulativem Verhalten oder einer negativen Gesamtperformance. Neobroker können regelmäßiges Investieren, langfristigen Vermögensaufbau und eine stärkere Beschäftigung mit Finanzthemen unterstützen.

Gleichzeitig zeigt die Untersuchung, dass technische Zugänglichkeit nicht mit finanzieller Befähigung gleichgesetzt werden darf. Verlusterfahrungen, bereute Entscheidungen und Investitionen ohne vollständiges Produktverständnis sind weit verbreitet. Besonders deutlich verdichten sich Risiken bei hoher Handelsfrequenz, Derivaten und Kryptowährungen, unvollständigem Produktverständnis und einer starken Reaktion auf digitale Aktivierungsmechanismen. Junge Nutzer:innen sind für Push-Benachrichtigungen und Social-Media-Einflüsse besonders empfänglich, bilden jedoch nicht pauschal eine homogene Risikogruppe.

Die zentrale Antwort auf die Forschungsfrage lautet daher: Neobroker befähigen Anleger:innen nicht automatisch zu vorteilhaften Entscheidungen, führen aber ebenso wenig zwangsläufig zu Verlusten. Sie erweitern zunächst die Möglichkeiten, selbstständig am Kapitalmarkt teilzunehmen. Die Ergebnisse zeigen, dass langfristig orientierter Vermögensaufbau ebenso wie risikorelevantes Verhalten eng mit Finanz- und Produktwissen, Handelsfrequenz, Produktauswahl, Anlagestrategie und der Reaktion auf digitale Impulse zusammenhängen

Trading-Apps sind damit weder ausschließlich Instrumente einer Demokratisierung der Geldanlage noch ausschließlich digitale Spekulationsplattformen. Sie stellen eine leistungsfähige Infrastruktur finanzieller Teilhabe dar, deren Chancen und Risiken eng mit der konkreten Nutzung zusammenhängen. Da kurzfristig nicht allein auf eine umfassende Umgestaltung der Plattformen vertraut werden kann, kommt unabhängiger, praxisbezogener Finanzbildung eine zentrale Bedeutung zu. Persönliche Anlageberatung bleibt zugleich ein wichtiges ergänzendes Instrument, wenn individuelle Ziele, komplexe Produkte oder erhöhte finanzielle Risiken eine professionelle Einordnung erfordern.

Neobroker haben den Kapitalmarktzugang erfolgreich vereinfacht. Zugang allein bedeutet jedoch noch keine Befähigung. Erst wenn technische Zugänglichkeit mit Produktverständnis, reflektierter Entscheidungsfähigkeit und bei Bedarf professioneller

Beratung verbunden wird, kann aus der Demokratisierung des Wertpapierhandels eine tatsächliche Demokratisierung fundierter Anlageentscheidungen entstehen.

Quellenverzeichnis

Alexander Eschment: Wie seriös ist das Angebot von Neobrokern? 01.04.2025. URL: https://www.zdfheute.de/ratgeber/neobroker-aktien-trading-app-geld-anlegen-anfaenger-100.html.

Andreas Greiner: Das Ende von PFOF 2026: Wie Neobroker das Verbot umgehen und was Anleger jetzt wissen sollten, 07.04.2026. URL: https://www.broker-test.at/news/das-ende-von-pfof-2026-wie-neobroker-das-verbot-umgehen-und-was-anleger-jetzt-wissen-muessen/.

Ankit Kalda et al.: Smart(Phone) Investing? A Within Investor-Time Analysis of New Technologies and Trading Behavior, in: NBER Working Paper No. 28363, Januar 2021. URL: https://www.nber.org/system/files/working_papers/w28363/w28363.pdf.

Artemisa Dores et al.: The Effects of Social Feedback Through the “Like” Feature on Brain Activity: A Systematic Review, in: Healthcare 13, No. 1, 2025, S. 89. URL: https://doi.org/10.3390/healthcare13010089.

Cary Stothart, Ainsley Mitchum, Courtney Yehnert: The Attentional Cost of Receiving a Cell Phone Notification, in: Journal of Experimental Psychology: Human Perception and Performance, August 2015. URL: https://www.researchgate.net/publication/279457726_The_Attentional_Cost_of_Receiving_a_Cell_Phone_Notification

Delia Cristina Balaban, Julia Szambolics, Mihai Chiricǎ: Parasocial relations and social media influencers' persuasive power. Exploring the moderating role of product involvement, in: Acta Psychologica, Vol. 230, Oktober 2022. URL: https://www.sciencedirect.com/science/article/pii/S0001691822002463?via%3Dihub.

ESMA Discussion Paper: On MiFID II investor protection topics linked to digitalisation, 14.12.2023. URL: https://www.esma.europa.eu/sites/default/files/2023-12/ESMA35-43-3682_Discussion_Paper_on_MiFID_II_investor_protection_topics_linked_to_digitalisation.pdf.

Europäische Wertpapier- und Marktaufsichtsbehörde: Article 39a – Prohibition of receiving payment for order flow. URL: https://www.esma.europa.eu/publications-and-data/interactive-single-rulebook/mifir/article-39a-prohibition-receiving-payment.

Faz.net: EU-Finanzaufsicht nimmt Neobroker unter die Lupe, 14.07.2021. URL: https://www.faz.net/aktuell/finanzen/eu-finanzaufsicht-nimmt-neobroker-unter-die-lupe-17436925.html.

Haibo Wu, Chongfeng Wu: Mobile device use and the ranking effect on trading behavior: Evidence from natural experiments, in: Pacific-Basin Finance Journal, Vol. 85, 2024. URL: https://www.sciencedirect.com/science/article/abs/pii/S0927538X24000684.

Harry Brignull: Dark Patterns: dirty tricks designers use to make people do stuff, 08.07.2010. Archiviert durch web.archive.org. URL: https://web.archive.org/web/20250620081436/https:/90percentofeverything.com/2010/07/08/dark-patterns-dirty-tricks-designers-use-to-make-people-do-stuff/.

Hoyun Kim: Social media engagement and retail investors' short-termism, in: Finance Research Letters, Vol. 85, Part E, 2025. URL: https://www.sciencedirect.com/science/article/pii/S154461232501503X.

IOSCO: Digital Engagement Practices (DEPs): Final Report, Mai 2025. URL: https://www.iosco.org/library/pubdocs/pdf/IOSCOPD794.pdf.

Jonas Freibauer: Effects of Trading Apps on Investment Behavior, Dissertation Uni Trier, 06.12.2024. URL: https://ubt.opus.hbz-nrw.de/frontdoor/deliver/index/docId/2418/file/PhD_thesis_Freibauer.pdf.

Jonas Freibauer, Marc Oliver Rieger, Silja Grawert: The effects of trading apps on investment behavior over time, in: European Journal of Finance, 12.09.2024, S. 1–25, URL: https://www.researchgate.net/publication/383986187_The_effects_of_trading_apps_on_investment_behavior_over_time.

Jonas Freibauer, Marc Oliver Rieger, Silja Grawert: The Role of Trading Apps in Shaping Investment Behavior, in: Swiss Journal of Business Vol. 79, no. 2, Juni 2025, S. 147–176. URL: https://www.researchgate.net/publication/392557711_The_Role_of_Trading_Apps_in_Shaping_Investment_Behavior.

Jonas Freibauer, Silja Grawert: Prolonged Neobroker usage: Analyzing investment behavior and its impact on trading specific financial products, in: Global Finance Journal, Volume 69, 2026, URL: https://www.researchgate.net/publication/397916270_Prolonged_Neobroker_usage_Analyzing_investment_behavior_and_its_impact_on_trading_specific_financial_products.

Jürgen Kühling, Cornelius Sauerborn: Rechtsgutachten über die rechtlichen Rahmenbedingungen sogenannter „Dark Patterns", 14.02.2022. URL: https://bevh.org/fileadmin/content/04_politik/Europa/Kuehling-Gutachten-BEVH-Dark-pattern-22-02-16-final.pdf.

Kevin Chen: Impacts of Short-Form Media Use on Sustained Attention and Memory: A Behavioral Study of TikTok Consumption in Young Adults. Undergrad Honors Thesis Version 1, 2025, in: Stanford Digital Repository. URL: https://purl.stanford.edu/zb094wm9033.

Lauren Sherman et al..: The Power of the Like in Adolescence: Effects of Peer Influence on Neural and Behavioral Responses to Social Media, in: Psychological science, Vol. 27 (7), 2016, S. 1027–1035. URL: https://pubmed.ncbi.nlm.nih.gov/27247125/.

Matteo Cinelli et al.: The echo chamber effect on social media, in: PNAS Vol. 118, No. 9, 2021. URL: https://www.pnas.org/doi/pdf/10.1073/pnas.2023301118.

Matthew Salganik, Peter Sheridan Dodds, Duncan Watts: Experimental Study of Inequality and Unpredictability in an Artificial Cultural Market, in: Science, Vol. 311, 10.02.2006. URL: https://www.princeton.edu/~mjs3/salganik_dodds_watts06_full.pdf.

Maximilian Janussek: Blessing or Curse? The Influence of Neobrokers on the Investment Behavior of Young Investors, in: Junior Management Science 7, 2022, S. 1375-1399. URL: https://jums.academy/wp-content/uploads/2022/12/MA_Janussek.pdf.

Miranda Reiter, Di Qing, Morgen Nations: Who Uses Social Media for Investment Advice?, in: Journal of Financial Planning, September 2023. URL: https://www.financialplanningassociation.org/learning/publications/journal/SEP23-who-uses-social-media-investment-advice-OPEN.

Philipp Frohn: Verbraucherschützer kritisieren neue Tagesgeld-Offerte von Scalable, 20.03.2026. URL: https://www.wiwo.de/finanzen/geldanlage/scalable-capital-verbraucherschuetzer-kritisieren-neue-tagesgeld-offerte/100209533.html.

Philipp Masur et al.: Behavioral contagion on social media: Effects of social norms, design interventions, and critical media literacy on self-disclosure, in: PloS one Vol. 16 (7), 19.07.2021. URL: https://pmc.ncbi.nlm.nih.gov/articles/PMC8289004.

Richard Thaler, Cass Sunstein: Nudge: The Final Edition, Penguin Books 2021.

Scalable Capital: Scalable Capital expands derivatives offering and introduces best execution on public exchanges, 08.07.2026. URL: https://de.scalable.capital/en/newsroom/derivatives.

Scalable Capital: Scalable Preismodelle und Guthabenverteilung. URL: https://de.scalable.capital/trading-gebuehren.

Steffen Preißler: Zocken an der Börse: Wenn der Aktienkauf fast nichts kostet. 01.02.2021. URL: https://www.abendblatt.de/wirtschaft/article231449407/Zocken-an-der-Boerse-Wenn-der-Aktienkauf-fast-nichts-kostet.html.

Trade Republic: Best Price, Informationen zur Bestpreis- und Direktpreis-Ausführung. URL: https://support.traderepublic.com/en-de/3372dc64-59cb-4521-a424-1ee812f264a4.

Verbraucherzentrale: Klage gegen Trade Republic, Verfahren I, Stand 06.07.2026. URL: https://www.verbraucherzentrale.de/verbandsklagen/klage-gegen-trade-republic-verfahren-i-101735.

Verbraucherzentrale: Klage gegen Trade Republic, Verfahren II, Stand 06.07.2026. URL: https://www.verbraucherzentrale.de/verbandsklagen/klage-gegen-trade-republic-verfahren-ii-104013.

Verbraucherzentrale: Neobroker: Kosten und Risiken des schnellen Wertpapier-Handels per App, 03.03.2026. URL: https://www.verbraucherzentrale.de/wissen/geld-versicherungen/sparen-und-anlegen/neobroker-kosten-und-risiken-des-schnellen-wertpapierhandels-per-app-62408.

Abbildungsverzeichnis

Abbildung 1: Geschlecht der Teilnehmer:innen 24
Abbildung 2: Alter der Teilnehmer:innen 25
Abbildung 3: Bundesland der Teilnehmer:innen 25
Abbildung 4: Erwerbssituation der Teilnehmer:innen 26
Abbildung 5: Nettoeinkommen der Teilnehmer:innen-Haushalte 26
Abbildung 6: Genutzte Investitionswege 27
Abbildung 7: Genutzte Geldanlagen 28
Abbildung 8: Meistgenutzte Investmentwege 29
Abbildung 9: Bevorzugter Investmentrhythmus 30
Abbildung 10: Häufigkeit genutzter Investmentwege 30
Abbildung 11: Selbsteinschätzung Finanzwissen allgemein 31
Abbildung 12: Prozentuale Aufteilung Stärke des Finanzwissens 31
Abbildung 13: Prozentuale Aufteilung Vertrauen in Investmententscheidungen 32
Abbildung 14: Selbsteinschätzung Vertrauen in Investmententscheidungen 33
Abbildung 15: Methode erster Investments 33
Abbildung 16: Seit wann investieren Teilnehmer:innen über Neobroker 34
Abbildung 17: Trade-Intervalle über Trading-Apps 35
Abbildung 18: Durchschnittliche Höhe von Investments 35
Abbildung 19: Höhe des für Trades genutzten Einkommens 36
Abbildung 20: Beweggründe für Neobroker-Nutzung 37
Abbildung 21: Änderungen im Investmentverhalten seit Neobroker-Nutzung 38
Abbildung 22: Prozentuale Aufteilung von Änderungen im Investmentverhalten 39
Abbildung 23: Zeitspanne Neobroker-Nutzung vor eingetretenen Änderungen 39

Abbildung 24: Auswirkungen Neobroker-Nutzung auf Investmentverhalten 40

Abbildung 25: Änderungen bei Personen, die diese zuvor verneint haben 42

Abbildung 26: Reue über Investmententscheidungen über Neobroker 43

Abbildung 27: Prozentuale Aufteilung der Reue über Investmententscheidungen 43

Abbildung 28: Gründe für bereute Investmententscheidungen 44

Abbildung 29: Prozentuale Aufteilung Gewinne/Verluste seit Neobroker-Nutzung 45

Abbildung 30: Portfolio-Entwicklung seit Neobroker-Nutzung 45

Abbildung 31: Prozentuale Aufteilung der Häufigkeit von Investitionen ohne Verständnis des Produkts 46

Abbildung 32: Häufigkeit von Investitionen ohne Verständnis des Produkts 47

Abbildung 33: Wurde Geld über Neobroker-Investments verloren 47

Abbildung 34: Höhe von Verlusten über Neobroker-Investments 48

Abbildung 35: Gründe für Verluste über Neobroker 49

Abbildung 36: Häufigkeit spontaner Anlageentscheidungen 50

Abbildung 37: Passgenauigkeit ETF-Auswahl zu Anlagezielen 51

Abbildung 38: Prozentuale Aufteilung Passgenauigkeit ETF-Auswahl 51

Abbildung 39: Auswahlgründe für erstes Neobroker-Investment 52

Abbildung 40: Stärke von Einflusskategorien auf Investmententscheidungen 54

Abbildung 41: Prozentuale Aufteilung des stärksten Einflusses 55

Abbildung 42: Prozentuale Aufteilung des geringsten Einflusses 55

Abbildung 43: Prozentuale Aufteilung des mäßigen Einflusses 56

Abbildung 44: Zustimmung der Aussage „Neobroker verleitet zum Traden“ 57

Abbildung 45: Prozentuale Aufteilung Zustimmung/Verneinung „Neobroker verleitet zum Traden“ 57

Abbildung 46: Auflösung von Neobroker-Depots 58

Abbildung 47: Gründe für aufgelöstes Neobroker-Depot 59

Abbildung 48: Geplante Haltedauer Neobroker-Investments 60

Abbildung 49: Stärke von Einfluss durch App-Funktionen 61

Abbildung 50: Einfluss von App-Funktionen nach Skala „sehr“ bis „überhaupt nicht“ .. 62

Abbildung 51: Trading nach Push-Benachrichtigung Ja/Nein 63

Abbildung 52: Häufigkeit von Trades nach Push-Benachrichtigung 63

Abbildung 53: Wunsch nach persönlicher Beratung 64

Abbildung 54: Verbesserung Anlageentscheidungen durch Beratung Ja/Nein 65

Abbildung 55: Notwendige Aspekte für bessere Anlageentscheidungen 66

Abbildung 56: Häufigkeit der Emotionen „gespannt“, „gestresst“, „rational“ & „impulsiv“ beim Trading 68

Abbildung 57: Prozentuale Aufteilung Empfehlung Neobroker an Nachwuchs Ja/Nein . 69

Abbildung 58: Empfehlung Neobroker an Nachwuchs 69

Anhang

Contingency Tables Häufiges Trading

Contingency Tables

Einfluss_Push		Trading_haeufig 0	Trading_haeufig 1	Total
0	Count	454.0	131.0	585.0
	Expected count	399.3	185.7	585.0
	% within row	77.61 %	22.39 %	100.00 %
1	Count	202.0	174.0	376.0
	Expected count	256.7	119.3	376.0
	% within row	53.72 %	46.28 %	100.00 %
Total	Count	656.0	305.0	961.0
	Expected count	656.0	305.0	961.0
	% within row	68.26 %	31.74 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	60.26	1	< .001
N	961		

Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Odds Ratio	2.985	2.254	3.953	
Fisher's exact test	2.982	2.232	3.993	< .001

Note. Odds ratio indicates the following:
(Ratio > 1): Group *0* is more likely in group *0*
(Ratio < 1): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2504
Cramer's V	0.2504

Contingency Tables

Einfluss_Kursalarm		Trading_haeufig 0	1	Total
0	Count	325.0	79.00	404.0
	Expected count	276.8	127.2	404.0
	% within row	80.45 %	19.55 %	100.00 %
1	Count	339.0	226.0	565.0
	Expected count	387.2	177.8	565.0
	% within row	60.00 %	40.00 %	100.00 %
Total	Count	664.0	305.0	969.0
	Expected count	664.0	305.0	969.0
	% within row	68.52 %	31.48 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	45.65	1	< .001
N	969		

Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Odds Ratio	2.743	2.036	3.695	
Fisher's exact test	2.740	2.018	3.745	< .001

Note. Odds ratio indicates the following:
(Ratio > 1): Group *0* is more likely in group *0*
(Ratio < 1): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2171
Cramer's V	0.2171

Contingency Tables

Einfluss_Swipe		Trading_haeufig		Total
		0	1	
0	Count	469.0	135.0	604.0
	Expected count	409.4	194.6	604.0
	% within row	77.65 %	22.35 %	100.00 %
1	Count	143.0	156.0	299.0
	Expected count	202.6	96.36	299.0
	% within row	47.83 %	52.17 %	100.00 %
Total	Count	612.0	291.0	903.0
	Expected count	612.0	291.0	903.0
	% within row	67.77 %	32.23 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	81.44	1	< .001
N	903		

Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Odds Ratio	3.790	2.816	5.100	
Fisher's exact test	3.784	2.785	5.155	< .001

Note. Odds ratio indicates the following:
(Ratio > 1): Group *0* is more likely in group *0*
(Ratio < 1): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.3003
Cramer's V	0.3003

Contingency Tables

Einfluss_SocialMedia		Trading_haeufig 0	1	Total
0	Count	504.0	167.0	671.0
	Expected count	460.7	210.3	671.0
	% within row	75.11 %	24.89 %	100.00 %
1	Count	164.0	138.0	302.0
	Expected count	207.3	94.67	302.0
	% within row	54.30 %	45.70 %	100.00 %
Total	Count	668.0	305.0	973.0
	Expected count	668.0	305.0	973.0
	% within row	68.65 %	31.35 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	41.90	1	< .001
N	973		

Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Odds Ratio	2.540	1.908	3.381	
Fisher's exact test	2.537	1.887	3.414	< .001

Note. Odds ratio indicates the following:
(Ratio > 1): Group *0* is more likely in group *0*
(Ratio < 1): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2075
Cramer's V	0.2075

Contingency Tables

Einfluss_InApp		Trading_haeufig 0	1	Total
0	Count	415.0	136.0	551.0
	Expected count	377.2	173.8	551.0
	% within row	75.32 %	24.68 %	100.00 %
1	Count	247.0	169.0	416.0
	Expected count	284.8	131.2	416.0
	% within row	59.38 %	40.63 %	100.00 %
Total	Count	662.0	305.0	967.0
	Expected count	662.0	305.0	967.0
	% within row	68.46 %	31.54 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	27.90	1	< .001
N	967		

Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Odds Ratio	2.088	1.585	2.750	
Fisher's exact test	2.086	1.570	2.776	< .001

Note. Odds ratio indicates the following:
(Ratio > 1): Group *0* is more likely in group *0*
(Ratio < 1): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1699
Cramer's V	0.1699

Contingency Tables

Einfluss_Email		Trading_haeufig 0	1	Total
0	Count	481.0	162.0	643.0
	Expected count	440.9	202.1	643.0
	% within row	74.81 %	25.19 %	100.00 %
1	Count	180.0	141.0	321.0
	Expected count	220.1	100.9	321.0
	% within row	56.07 %	43.93 %	100.00 %
Total	Count	661.0	303.0	964.0
	Expected count	661.0	303.0	964.0
	% within row	68.57 %	31.43 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	34.85	1	< .001
N	964		

Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Odds Ratio	2.326	1.752	3.088	
Fisher's exact test	2.324	1.733	3.117	< .001

Note. Odds ratio indicates the following:
(Ratio > 1): Group *0* is more likely in group *0*
(Ratio < 1): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1901
Cramer's V	0.1901

Logistic Regression Tables Häufiges Trading

Logistic Regression

Model Summary - Trading_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1198	1199.951	1204.815	956			0.000		0.000	
M_1	1016	1044.031	1112.125	943	181.920	< .001	0.1519	0.2425	0.1817	0.1731

Note. M_1 includes Einfluss_Push, z_age_omnibus_18, gender, Finanzwissen_clean, App_Dauer_clean

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.760	0.069	0.4678	-10.95	119.9	1	< .001	0.408	0.536
M_1	(Intercept)	1.811	0.806	6.116	2.246	5.045	1	.025	1.259	29.699
	Einfluss_Push (1)	0.921	0.158	2.512	5.827	33.95	1	< .001	1.843	3.424
	z_age_omnibus_18 (2)	-0.650	0.300	0.5220	-2.169	4.704	1	.030	0.290	0.939
	z_age_omnibus_18 (3)	-0.571	0.294	0.5648	-1.942	3.770	1	.052	0.317	1.005
	z_age_omnibus_18 (4)	-0.825	0.309	0.4382	-2.675	7.153	1	.007	0.239	0.802
	z_age_omnibus_18 (5)	-0.568	0.297	0.5667	-1.912	3.656	1	.056	0.317	1.014
	gender (2)	-0.176	0.201	0.8387	-0.8773	0.7696	1	.380	0.566	1.243
	Finanzwissen_clean (2)	-2.844	0.905	0.05818	-3.141	9.869	1	.002	0.010	0.343
	Finanzwissen_clean (3)	-3.505	0.792	0.03005	-4.426	19.59	1	< .001	0.006	0.142
	Finanzwissen_clean (4)	-2.408	0.776	0.08997	-3.105	9.641	1	.002	0.020	0.411
	Finanzwissen_clean (5)	-1.709	0.783	0.1811	-2.183	4.765	1	.029	0.039	0.840
	App_Dauer_clean (2)	-0.136	0.291	0.8727	-0.4678	0.2189	1	.640	0.493	1.544
	App_Dauer_clean (3)	0.598	0.310	1.819	1.930	3.724	1	.054	0.991	3.338
	App_Dauer_clean (4)	0.145	0.334	1.156	0.4342	0.1885	1	.664	0.601	2.224

Note. Trading_haeufig level '1' coded as class 1.

Results

Logistic Regression

Model Summary - Trading_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1198	1199.951	1204.815	956			0.000		0.000	
M_1	1016	1044.031	1112.125	943	181.920	< .001	0.1519	0.2425	0.1817	0.1731

Note. M_1 includes Einfluss_Push, z_age_omnibus_18, gender, Finanzwissen_clean, App_Dauer_clean

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.760	0.069	0.4678	-10.95	119.9	1	< .001	0.408	0.536
M_1	(Intercept)	1.811	0.806	6.116	2.246	5.045	1	.025	1.259	29.699
	Einfluss_Push (1)	0.921	0.158	2.512	5.827	33.95	1	< .001	1.843	3.424
	z_age_omnibus_18 (2)	-0.650	0.300	0.5220	-2.169	4.704	1	.030	0.290	0.939
	z_age_omnibus_18 (3)	-0.571	0.294	0.5648	-1.942	3.770	1	.052	0.317	1.005
	z_age_omnibus_18 (4)	-0.825	0.309	0.4382	-2.675	7.153	1	.007	0.239	0.802
	z_age_omnibus_18 (5)	-0.568	0.297	0.5667	-1.912	3.656	1	.056	0.317	1.014
	gender (2)	-0.176	0.201	0.8387	-0.8773	0.7696	1	.380	0.566	1.243
	Finanzwissen_clean (2)	-2.844	0.905	0.05818	-3.141	9.869	1	.002	0.010	0.343
	Finanzwissen_clean (3)	-3.505	0.792	0.03005	-4.426	19.59	1	< .001	0.006	0.142
	Finanzwissen_clean (4)	-2.408	0.776	0.08997	-3.105	9.641	1	.002	0.020	0.411
	Finanzwissen_clean (5)	-1.709	0.783	0.1811	-2.183	4.765	1	.029	0.039	0.840
	App_Dauer_clean (2)	-0.136	0.291	0.8727	-0.4678	0.2189	1	.640	0.493	1.544
	App_Dauer_clean (3)	0.598	0.310	1.819	1.930	3.724	1	.054	0.991	3.338
	App_Dauer_clean (4)	0.145	0.334	1.156	0.4342	0.1885	1	.664	0.601	2.224

Note. Trading_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Trading_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1205	1206.820	1211.693	965			0.000		0.000	
M_1	1024	1051.975	1120.199	952	180.845	< .001	0.1501	0.2396	0.1779	0.1707

Note. M_1 includes Einfluss_Kursalarm, gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean

Coefficients

						Wald Test		
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p
M_0	(Intercept)	-0.773	0.069	0.4614	-11.17	124.8	1	< .001
M_1	(Intercept)	1.765	0.804	5.839	2.196	4.820	1	.028
	Einfluss_Kursalarm (1)	0.922	0.163	2.514	5.641	31.82	1	< .001
	gender (2)	-0.199	0.200	0.8199	-0.9905	0.9812	1	.322
	z_age_omnibus_18 (2)	-0.725	0.298	0.4842	-2.431	5.910	1	.015
	z_age_omnibus_18 (3)	-0.642	0.292	0.5265	-2.195	4.816	1	.028
	z_age_omnibus_18 (4)	-0.911	0.302	0.4021	-3.012	9.073	1	.003
	z_age_omnibus_18 (5)	-0.732	0.293	0.4811	-2.494	6.221	1	.013
	Finanzwissen_clean (2)	-2.660	0.902	0.06998	-2.948	8.691	1	.003
	Finanzwissen_clean (3)	-3.513	0.785	0.02981	-4.473	20.01	1	< .001
	Finanzwissen_clean (4)	-2.367	0.770	0.09379	-3.074	9.447	1	.002
	Finanzwissen_clean (5)	-1.647	0.777	0.1926	-2.119	4.490	1	.034
	App_Dauer_clean (2)	-0.217	0.285	0.8051	-0.7599	0.5774	1	.447
	App_Dauer_clean (3)	0.489	0.305	1.630	1.603	2.569	1	.109
	App_Dauer_clean (4)	0.043	0.329	1.044	0.1305	0.01703	1	.896

Note. Trading_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Trading_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1133	1134.842	1139.644	899			0.000		0.000	
M_1	947.0	975.024	1042.257	886	185.818	< .001	0.1640	0.2605	0.1974	0.1865

Note. M_1 includes Einfluss_Swipe, gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean

Coefficients

						Wald Test		
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p
M_0	(Intercept)	-0.738	0.071	0.4778	-10.36	107.4	1	< .001
M_1	(Intercept)	1.860	0.813	6.426	2.288	5.234	1	.022
	Einfluss_Swipe (1)	1.068	0.169	2.911	6.310	39.82	1	< .001
	gender (2)	-0.289	0.213	0.7490	-1.359	1.848	1	.174
	z_age_omnibus_18 (2)	-0.548	0.304	0.5781	-1.804	3.254	1	.071
	z_age_omnibus_18 (3)	-0.376	0.299	0.6866	-1.258	1.584	1	.208
	z_age_omnibus_18 (4)	-0.673	0.313	0.5102	-2.150	4.623	1	.032
	z_age_omnibus_18 (5)	-0.427	0.306	0.6524	-1.398	1.954	1	.162
	Finanzwissen_clean (2)	-2.484	0.905	0.08344	-2.743	7.525	1	.006
	Finanzwissen_clean (3)	-3.519	0.800	0.02962	-4.397	19.33	1	< .001
	Finanzwissen_clean (4)	-2.355	0.781	0.09487	-3.017	9.101	1	.003
	Finanzwissen_clean (5)	-1.718	0.787	0.1795	-2.182	4.759	1	.029
	App_Dauer_clean (2)	-0.385	0.297	0.6806	-1.296	1.680	1	.195
	App_Dauer_clean (3)	0.405	0.315	1.499	1.283	1.647	1	.199
	App_Dauer_clean (4)	-0.065	0.340	0.9373	-0.1905	0.03629	1	.849

Note. Trading_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Trading_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1203	1204.539	1209.409	962			0.000		0.000	
M_1	1038	1065.826	1134.006	949	164.713	< .001	0.1370	0.2205	0.1656	0.1572

Note. M_1 includes Einfluss_InApp, gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean

Coefficients

						Wald Test		
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p
M_0	(Intercept)	-0.769	0.069	0.4635	-11.10	123.2	1	< .001
M_1	(Intercept)	2.164	0.806	8.703	2.685	7.212	1	.007
	Einfluss_InApp (1)	0.662	0.155	1.939	4.268	18.22	1	< .001
	gender (2)	-0.249	0.198	0.7798	-1.253	1.571	1	.210
	z_age_omnibus_18 (2)	-0.713	0.295	0.4900	-2.416	5.839	1	.016
	z_age_omnibus_18 (3)	-0.580	0.287	0.5601	-2.017	4.069	1	.044
	z_age_omnibus_18 (4)	-0.896	0.298	0.4080	-3.011	9.065	1	.003
	z_age_omnibus_18 (5)	-0.717	0.288	0.4884	-2.487	6.185	1	.013
	Finanzwissen_clean (2)	-2.748	0.905	0.06404	-3.038	9.229	1	.002
	Finanzwissen_clean (3)	-3.648	0.791	0.02605	-4.609	21.24	1	< .001
	Finanzwissen_clean (4)	-2.479	0.775	0.08386	-3.199	10.23	1	.001
	Finanzwissen_clean (5)	-1.808	0.782	0.1639	-2.314	5.353	1	.021
	App_Dauer_clean (2)	-0.250	0.285	0.7784	-0.8792	0.7729	1	.379
	App_Dauer_clean (3)	0.478	0.305	1.613	1.569	2.460	1	.117
	App_Dauer_clean (4)	0.063	0.328	1.065	0.1925	0.03708	1	.847

Note. Trading_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Trading_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1207	1209.092	1213.968	968			0.000		0.000	
M_1	1043	1070.593	1138.861	955	164.499	< .001	0.1363	0.2192	0.1628	0.1561

Note. M_1 includes Einfluss_SocialMedia, gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean

Coefficients

						Wald Test		
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p
M_0	(Intercept)	-0.778	0.069	0.4593	-11.25	126.5	1	< .001
M_1	(Intercept)	2.092	0.806	8.097	2.594	6.730	1	.009
	Einfluss_SocialMedia (1)	0.620	0.170	1.859	3.651	13.33	1	< .001
	gender (2)	-0.212	0.199	0.8087	-1.066	1.136	1	.287
	z_age_omnibus_18 (2)	-0.621	0.295	0.5377	-2.100	4.410	1	.036
	z_age_omnibus_18 (3)	-0.521	0.291	0.5942	-1.789	3.202	1	.074
	z_age_omnibus_18 (4)	-0.780	0.305	0.4585	-2.556	6.531	1	.011
	z_age_omnibus_18 (5)	-0.582	0.300	0.5589	-1.938	3.757	1	.053
	Finanzwissen_clean (2)	-2.638	0.887	0.07149	-2.973	8.839	1	.003
	Finanzwissen_clean (3)	-3.550	0.791	0.02872	-4.486	20.13	1	< .001
	Finanzwissen_clean (4)	-2.375	0.774	0.09305	-3.067	9.408	1	.002
	Finanzwissen_clean (5)	-1.713	0.781	0.1803	-2.194	4.812	1	.028
	App_Dauer_clean (2)	-0.303	0.285	0.7387	-1.064	1.133	1	.287
	App_Dauer_clean (3)	0.454	0.303	1.575	1.498	2.243	1	.134
	App_Dauer_clean (4)	0.009	0.326	1.009	0.02668	7.120×10^{-4}	1	.979

Note. Trading_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Trading_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1197	1199.173	1204.040	959			0.000		0.000	
M_1	1035	1062.723	1130.860	946	162.450	< .001	0.1357	0.2184	0.1620	0.1557

Note. M_1 includes Einfluss_Email, gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean

Coefficients

						Wald Test		
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p
M_0	(Intercept)	-0.774	0.069	0.4612	-11.15	124.2	1	< .001
M_1	(Intercept)	2.057	0.806	7.823	2.552	6.512	1	.011
	Einfluss_Email (1)	0.636	0.162	1.888	3.915	15.33	1	< .001
	gender (2)	-0.292	0.200	0.7466	-1.460	2.131	1	.144
	z_age_omnibus_18 (2)	-0.656	0.297	0.5190	-2.210	4.886	1	.027
	z_age_omnibus_18 (3)	-0.614	0.291	0.5413	-2.108	4.442	1	.035
	z_age_omnibus_18 (4)	-0.831	0.303	0.4354	-2.745	7.536	1	.006
	z_age_omnibus_18 (5)	-0.704	0.293	0.4947	-2.398	5.750	1	.016
	Finanzwissen_clean (2)	-2.531	0.889	0.07956	-2.847	8.106	1	.004
	Finanzwissen_clean (3)	-3.498	0.792	0.03027	-4.419	19.53	1	< .001
	Finanzwissen_clean (4)	-2.320	0.776	0.09824	-2.991	8.944	1	.003
	Finanzwissen_clean (5)	-1.681	0.782	0.1862	-2.150	4.622	1	.032
	App_Dauer_clean (2)	-0.237	0.286	0.7890	-0.8293	0.6877	1	.407
	App_Dauer_clean (3)	0.502	0.304	1.653	1.650	2.722	1	.099
	App_Dauer_clean (4)	0.081	0.327	1.084	0.2479	0.06143	1	.804

Note. Trading_haeufig level '1' coded as class 1.

Contingency Tables Trading ohne Verständnis

Contingency Tables

Einfluss_Push		Ohne_Verstaendnis 0	Ohne_Verstaendnis 1	Total
0	Count	208.0	373.0	581.0
	Expected count	175.3	405.7	581.0
	% within row	35.80 %	64.20 %	100.00 %
1	Count	81.00	296.0	377.0
	Expected count	113.7	263.3	377.0
	% within row	21.49 %	78.51 %	100.00 %
Total	Count	289.0	669.0	958.0
	Expected count	289.0	669.0	958.0
	% within row	30.17 %	69.83 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	22.24	1	< .001
N	958		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.7119	0.413	1.010	
Fisher's exact test	0.7112	0.404	1.024	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1524
Cramer's V	0.1524

Contingency Tables

Einfluss_Kursalarm		Ohne_Verstaendnis 0	Ohne_Verstaendnis 1	Total
0	Count	159.0	242.0	401.0
	Expected count	120.0	281.0	401.0
	% within row	39.65 %	60.35 %	100.00 %
1	Count	131.0	437.0	568.0
	Expected count	170.0	398.0	568.0
	% within row	23.06 %	76.94 %	100.00 %
Total	Count	290.0	679.0	969.0
	Expected count	290.0	679.0	969.0
	% within row	29.93 %	70.07 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	30.84	1	< .001
N	969		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.7847	0.505	1.064	
Fisher's exact test	0.7839	0.495	1.074	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1784
Cramer's V	0.1784

Contingency Tables

Einfluss_Swipe		Ohne_Verstaendnis 0	Ohne_Verstaendnis 1	Total
0	Count	220.0	383.0	603.0
	Expected count	185.6	417.4	603.0
	% within row	36.48 %	63.52 %	100.00 %
1	Count	58.00	242.0	300.0
	Expected count	92.36	207.6	300.0
	% within row	19.33 %	80.67 %	100.00 %
Total	Count	278.0	625.0	903.0
	Expected count	278.0	625.0	903.0
	% within row	30.79 %	69.21 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	27.66	1	< .001
N	903		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.8741	0.543	1.205	
Fisher's exact test	0.8732	0.533	1.224	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1750
Cramer's V	0.1750

Contingency Tables

Einfluss_SocialMedia		Ohne_Verstaendnis 0	Ohne_Verstaendnis 1	Total
0	Count	247.0	422.0	669.0
	Expected count	201.4	467.6	669.0
	% within row	36.92 %	63.08 %	100.00 %
1	Count	45.00	256.0	301.0
	Expected count	90.61	210.4	301.0
	% within row	14.95 %	85.05 %	100.00 %
Total	Count	292.0	678.0	970.0
	Expected count	292.0	678.0	970.0
	% within row	30.10 %	69.90 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	47.63	1	< .001
N	970		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.203	0.849	1.556	
Fisher's exact test	1.202	0.840	1.580	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2216
Cramer's V	0.2216

Contingency Tables

Einfluss_InApp		Ohne_Verstaendnis 0	Ohne_Verstaendnis 1	Total
0	Count	200.0	348.0	548.0
	Expected count	165.0	383.0	548.0
	% within row	36.50 %	63.50 %	100.00 %
1	Count	90.00	325.0	415.0
	Expected count	125.0	290.0	415.0
	% within row	21.69 %	78.31 %	100.00 %
Total	Count	290.0	673.0	963.0
	Expected count	290.0	673.0	963.0
	% within row	30.11 %	69.89 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	24.61	1	< .001
N	963		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.7301	0.439	1.021	
Fisher's exact test	0.7294	0.430	1.034	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1599
Cramer's V	0.1599

Contingency Tables

Einfluss_Email		Ohne_Verstaendnis 0	Ohne_Verstaendnis 1	Total
0	Count	226.0	415.0	641.0
	Expected count	194.3	446.7	641.0
	% within row	35.26 %	64.74 %	100.00 %
1	Count	65.00	254.0	319.0
	Expected count	96.70	222.3	319.0
	% within row	20.38 %	79.62 %	100.00 %
Total	Count	291.0	669.0	960.0
	Expected count	291.0	669.0	960.0
	% within row	30.31 %	69.69 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	22.33	1	< .001
N	960		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.7552	0.438	1.072	
Fisher's exact test	0.7545	0.429	1.089	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1525
Cramer's V	0.1525

Logistic Regression Tables Trading ohne Verständnis

Logistic Regression

Model Summary - Ohne_Verstaendnis

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1169	1170.790	1175.648	951			0.000		0.000	
M_1	1095	1121.327	1184.489	939	73.462	< .001	0.06285	0.1050	0.07285	0.07426

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_gruppiert, App_Dauer_clean, Einfluss_Push

Coefficients

									95% Confidence interval (odds ratio scale)	
						Wald Test				
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.830	0.070	2.294	11.78	138.8	1	< .001	1.998	2.634
M_1	(Intercept)	2.287	0.628	9.846	3.641	13.26	1	< .001	2.875	33.719
	gender (2)	0.348	0.192	1.416	1.817	3.301	1	.069	0.973	2.062
	z_age_omnibus_18 (2)	-0.743	0.358	0.4759	-2.073	4.297	1	.038	0.236	0.960
	z_age_omnibus_18 (3)	-0.728	0.353	0.4830	-2.062	4.252	1	.039	0.242	0.965
	z_age_omnibus_18 (4)	-1.295	0.353	0.2740	-3.672	13.49	1	< .001	0.137	0.547
	z_age_omnibus_18 (5)	-1.081	0.350	0.3393	-3.088	9.538	1	.002	0.171	0.674
	Finanzwissen_gruppiert (2)	-0.869	0.553	0.4195	-1.571	2.467	1	.116	0.142	1.240
	Finanzwissen_gruppiert (3)	-1.226	0.548	0.2935	-2.235	4.994	1	.025	0.100	0.860
	Finanzwissen_gruppiert (4)	-1.786	0.561	0.1676	-3.182	10.12	1	.001	0.056	0.504
	App_Dauer_clean (2)	0.360	0.250	1.433	1.441	2.075	1	.150	0.878	2.338
	App_Dauer_clean (3)	0.473	0.280	1.605	1.689	2.853	1	.091	0.927	2.781
	App_Dauer_clean (4)	0.438	0.296	1.549	1.479	2.186	1	.139	0.867	2.767
	Einfluss_Push (1)	0.609	0.161	1.838	3.783	14.31	1	< .001	1.341	2.519

Note. Ohne_Verstaendnis level '1' coded as class 1.

Logistic Regression

Model Summary - Ohne_Verstaendnis

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1179	1181.099	1185.970	963			0.000		0.000	
M_1	1099	1124.816	1188.141	951	80.282	< .001	0.06809	0.1132	0.08034	0.07991

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_gruppiert, App_Dauer_clean, Einfluss_Kursalarm

Coefficients

									95% Confidence interval (odds ratio scale)	
						Wald Test				
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.843	0.070	2.324	12.01	144.2	1	< .001	2.025	2.667
M_1	(Intercept)	2.009	0.583	7.453	3.445	11.87	1	< .001	2.377	23.369
	gender (2)	0.363	0.191	1.437	1.904	3.625	1	.057	0.989	2.088
	z_age_omnibus_18 (2)	-0.782	0.357	0.4574	-2.194	4.813	1	.028	0.227	0.920
	z_age_omnibus_18 (3)	-0.742	0.351	0.4764	-2.112	4.458	1	.035	0.239	0.948
	z_age_omnibus_18 (4)	-1.348	0.348	0.2597	-3.872	14.99	1	< .001	0.131	0.514
	z_age_omnibus_18 (5)	-1.122	0.346	0.3258	-3.237	10.48	1	.001	0.165	0.642
	Finanzwissen_gruppiert (2)	-0.729	0.507	0.4824	-1.438	2.067	1	.151	0.179	1.303
	Finanzwissen_gruppiert (3)	-1.019	0.503	0.3610	-2.026	4.104	1	.043	0.135	0.967
	Finanzwissen_gruppiert (4)	-1.576	0.518	0.2067	-3.044	9.265	1	.002	0.075	0.570
	App_Dauer_clean (2)	0.335	0.249	1.398	1.345	1.809	1	.179	0.858	2.279
	App_Dauer_clean (3)	0.406	0.280	1.501	1.450	2.104	1	.147	0.867	2.599
	App_Dauer_clean (4)	0.369	0.295	1.446	1.250	1.563	1	.211	0.811	2.577
	Einfluss_Kursalarm (1)	0.724	0.148	2.062	4.887	23.88	1	< .001	1.543	2.757

Note. Ohne_Verstaendnis level '1' coded as class 1.

Logistic Regression

Model Summary - Ohne_Verstaendnis

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1111	1113.296	1118.096	897			0.000		0.000	
M_1	1036	1061.791	1124.193	885	75.505	< .001	0.06794	0.1136	0.07795	0.08064

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_gruppiert, App_Dauer_clean, Einfluss_Swipe

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.802	0.072	2.230	11.11	123.5	1	< .001	1.936	2.569
M_1	(Intercept)	1.962	0.594	7.111	3.301	10.90	1	< .001	2.218	22.791
	gender (2)	0.338	0.196	1.402	1.720	2.958	1	.085	0.954	2.059
	z_age_omnibus_18 (2)	-0.711	0.362	0.4911	-1.965	3.862	1	.049	0.242	0.998
	z_age_omnibus_18 (3)	-0.743	0.357	0.4755	-2.080	4.328	1	.037	0.236	0.958
	z_age_omnibus_18 (4)	-1.251	0.357	0.2862	-3.506	12.29	1	< .001	0.142	0.576
	z_age_omnibus_18 (5)	-1.036	0.356	0.3548	-2.907	8.451	1	.004	0.176	0.713
	Finanzwissen_gruppiert (2)	-0.441	0.514	0.6433	-0.8585	0.7370	1	.391	0.235	1.761
	Finanzwissen_gruppiert (3)	-0.832	0.507	0.4351	-1.642	2.697	1	.101	0.161	1.175
	Finanzwissen_gruppiert (4)	-1.441	0.521	0.2366	-2.768	7.664	1	.006	0.085	0.656
	App_Dauer_clean (2)	0.222	0.259	1.249	0.8587	0.7374	1	.390	0.752	2.074
	App_Dauer_clean (3)	0.288	0.288	1.334	1.001	1.001	1	.317	0.759	2.344
	App_Dauer_clean (4)	0.331	0.305	1.393	1.085	1.177	1	.278	0.766	2.533
	Einfluss_Swipe (1)	0.813	0.181	2.256	4.493	20.19	1	< .001	1.582	3.217

Note. Ohne_Verstaendnis level '1' coded as class 1.

Logistic Regression

Model Summary - Ohne_Verstaendnis

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1182	1184.453	1189.324	963			0.000		0.000	
M_1	1087	1113.334	1176.658	951	95.119	< .001	0.08044	0.1330	0.09204	0.09396

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_gruppiert, App_Dauer_clean, Einfluss_SocialMedia

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.834	0.070	2.301	11.89	141.4	1	< .001	2.006	2.640
M_1	(Intercept)	1.765	0.596	5.843	2.961	8.767	1	.003	1.816	18.798
	gender (2)	0.407	0.189	1.503	2.160	4.666	1	.031	1.038	2.175
	z_age_omnibus_18 (2)	-0.556	0.366	0.5737	-1.519	2.308	1	.129	0.280	1.175
	z_age_omnibus_18 (3)	-0.528	0.362	0.5901	-1.457	2.124	1	.145	0.290	1.199
	z_age_omnibus_18 (4)	-1.018	0.360	0.3613	-2.825	7.982	1	.005	0.178	0.732
	z_age_omnibus_18 (5)	-0.741	0.361	0.4768	-2.051	4.207	1	.040	0.235	0.968
	Finanzwissen_gruppiert (2)	-0.580	0.511	0.5599	-1.135	1.288	1	.256	0.206	1.525
	Finanzwissen_gruppiert (3)	-0.918	0.507	0.3993	-1.811	3.279	1	.070	0.148	1.079
	Finanzwissen_gruppiert (4)	-1.532	0.522	0.2161	-2.934	8.611	1	.003	0.078	0.601
	App_Dauer_clean (2)	0.256	0.249	1.291	1.025	1.051	1	.305	0.792	2.105
	App_Dauer_clean (3)	0.376	0.280	1.457	1.343	1.802	1	.179	0.841	2.524
	App_Dauer_clean (4)	0.359	0.296	1.431	1.212	1.469	1	.225	0.801	2.556
	Einfluss_SocialMedia (1)	1.144	0.195	3.139	5.878	34.55	1	< .001	2.144	4.597

Note. Ohne_Verstaendnis level '1' coded as class 1.

Logistic Regression

Model Summary - Ohne_Verstaendnis

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1174	1176.067	1180.931	956			0.000		0.000	
M_1	1099	1124.677	1187.906	944	75.390	< .001	0.06421	0.1072	0.07545	0.07575

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_gruppiert, App_Dauer_clean, Einfluss_InApp

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.833	0.070	2.300	11.84	140.2	1	< .001	2.004	2.640
M_1	(Intercept)	2.116	0.585	8.298	3.620	13.11	1	< .001	2.639	26.093
	gender (2)	0.341	0.189	1.406	1.803	3.251	1	.071	0.971	2.038
	z_age_omnibus_18 (2)	-0.806	0.358	0.4466	-2.251	5.068	1	.024	0.221	0.901
	z_age_omnibus_18 (3)	-0.801	0.352	0.4488	-2.277	5.184	1	.023	0.225	0.894
	z_age_omnibus_18 (4)	-1.365	0.349	0.2554	-3.915	15.33	1	< .001	0.129	0.506
	z_age_omnibus_18 (5)	-1.180	0.347	0.3072	-3.400	11.56	1	< .001	0.156	0.607
	Finanzwissen_gruppiert (2)	-0.692	0.509	0.5008	-1.359	1.847	1	.174	0.185	1.358
	Finanzwissen_gruppiert (3)	-1.023	0.503	0.3596	-2.032	4.129	1	.042	0.134	0.964
	Finanzwissen_gruppiert (4)	-1.588	0.518	0.2044	-3.064	9.389	1	.002	0.074	0.564
	App_Dauer_clean (2)	0.394	0.253	1.483	1.560	2.433	1	.119	0.904	2.434
	App_Dauer_clean (3)	0.489	0.282	1.631	1.733	3.002	1	.083	0.938	2.837
	App_Dauer_clean (4)	0.475	0.299	1.608	1.590	2.527	1	.112	0.895	2.887
	Einfluss_InApp (1)	0.637	0.154	1.891	4.127	17.03	1	< .001	1.397	2.559

Note. Ohne_Verstaendnis level '1' coded as class 1.

Logistic Regression

Model Summary - Ohne_Verstaendnis

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1174	1175.549	1180.409	953			0.000		0.000	
M_1	1103	1129.007	1192.195	941	70.542	< .001	0.06011	0.1007	0.07084	0.07128

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_gruppiert, App_Dauer_clean, Einfluss_Email

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.823	0.070	2.278	11.71	137.1	1	< .001	1.985	2.615
M_1	(Intercept)	2.130	0.586	8.419	3.633	13.20	1	< .001	2.667	26.572
	gender (2)	0.347	0.189	1.415	1.834	3.365	1	.067	0.977	2.051
	z_age_omnibus_18 (2)	-0.723	0.359	0.4851	-2.016	4.063	1	.044	0.240	0.980
	z_age_omnibus_18 (3)	-0.731	0.354	0.4815	-2.067	4.271	1	.039	0.241	0.963
	z_age_omnibus_18 (4)	-1.264	0.353	0.2826	-3.585	12.85	1	< .001	0.142	0.564
	z_age_omnibus_18 (5)	-1.043	0.351	0.3524	-2.974	8.843	1	.003	0.177	0.701
	Finanzwissen_gruppiert (2)	-0.669	0.506	0.5124	-1.321	1.745	1	.186	0.190	1.382
	Finanzwissen_gruppiert (3)	-0.987	0.501	0.3728	-1.970	3.880	1	.049	0.140	0.995
	Finanzwissen_gruppiert (4)	-1.551	0.515	0.2121	-3.011	9.068	1	.003	0.077	0.582
	App_Dauer_clean (2)	0.314	0.252	1.369	1.248	1.559	1	.212	0.836	2.242
	App_Dauer_clean (3)	0.417	0.281	1.517	1.483	2.200	1	.138	0.875	2.633
	App_Dauer_clean (4)	0.318	0.296	1.375	1.075	1.156	1	.282	0.769	2.457
	Einfluss_Email (1)	0.627	0.170	1.871	3.686	13.59	1	< .001	1.341	2.611

Note. Ohne_Verstaendnis level '1' coded as class 1.

Contingency Tables Spontanes Trading

Contingency Tables

Einfluss_Push		Spontan_haeufig 0	Spontan_haeufig 1	Total
0	Count	538.0	52.00	590.0
	Expected count	497.5	92.55	590.0
	% within row	91.19 %	8.81 %	100.00 %
1	Count	279.0	100.0	379.0
	Expected count	319.5	59.45	379.0
	% within row	73.61 %	26.39 %	100.00 %
Total	Count	817.0	152.0	969.0
	Expected count	817.0	152.0	969.0
	% within row	84.31 %	15.69 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	53.87	1	< .001
N	969		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.311	0.946	1.676	
Fisher's exact test	1.309	0.932	1.696	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2358
Cramer's V	0.2358

Contingency Tables

Einfluss_Kursalarm		Spontan_haeufig 0	1	Total
0	Count	369.0	39.00	408.0
	Expected count	344.7	63.35	408.0
	% within row	90.44 %	9.56 %	100.00 %
1	Count	458.0	113.0	571.0
	Expected count	482.3	88.65	571.0
	% within row	80.21 %	19.79 %	100.00 %
Total	Count	827.0	152.0	979.0
	Expected count	827.0	152.0	979.0
	% within row	84.47 %	15.53 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	18.99	1	< .001
N	979		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.8478	0.459	1.237	
Fisher's exact test	0.8469	0.447	1.264	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1393
Cramer's V	0.1393

Contingency Tables

Einfluss_Swipe		Spontan_haeufig 0	Spontan_haeufig 1	Total
0	Count	562.0	48.00	610.0
	Expected count	510.9	99.10	610.0
	% within row	92.13 %	7.87 %	100.00 %
1	Count	201.0	100.0	301.0
	Expected count	252.1	48.90	301.0
	% within row	66.78 %	33.22 %	100.00 %
Total	Count	763.0	148.0	911.0
	Expected count	763.0	148.0	911.0
	% within row	83.75 %	16.25 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	95.22	1	< .001
N	911		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.762	1.382	2.142	
Fisher's exact test	1.760	1.367	2.164	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.3233
Cramer's V	0.3233

Contingency Tables

Einfluss_SocialMedia		Spontan_haeufig 0	Spontan_haeufig 1	Total
0	Count	616.0	62.00	678.0
	Expected count	573.6	104.4	678.0
	% within row	90.86 %	9.14 %	100.00 %
1	Count	214.0	89.00	303.0
	Expected count	256.4	46.64	303.0
	% within row	70.63 %	29.37 %	100.00 %
Total	Count	830.0	151.0	981.0
	Expected count	830.0	151.0	981.0
	% within row	84.61 %	15.39 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	65.80	1	< .001
N	981		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.419	1.059	1.778	
Fisher's exact test	1.417	1.044	1.796	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2590
Cramer's V	0.2590

Contingency Tables

Einfluss_InApp		Spontan_haeufig 0	Spontan_haeufig 1	Total
0	Count	504.0	50.00	554.0
	Expected count	468.7	85.32	554.0
	% within row	90.97 %	9.03 %	100.00 %
1	Count	320.0	100.0	420.0
	Expected count	355.3	64.68	420.0
	% within row	76.19 %	23.81 %	100.00 %
Total	Count	824.0	150.0	974.0
	Expected count	824.0	150.0	974.0
	% within row	84.60 %	15.40 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	40.08	1	< .001
N	974		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.147	0.780	1.515	
Fisher's exact test	1.146	0.766	1.536	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2028
Cramer's V	0.2028

Contingency Tables

Einfluss_Email		Spontan_haeufig 0	Spontan_haeufig 1	Total
0	Count	588.0	59.00	647.0
	Expected count	545.8	101.2	647.0
	% within row	90.88 %	9.12 %	100.00 %
1	Count	232.0	93.00	325.0
	Expected count	274.2	50.82	325.0
	% within row	71.38 %	28.62 %	100.00 %
Total	Count	820.0	152.0	972.0
	Expected count	820.0	152.0	972.0
	% within row	84.36 %	15.64 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	62.33	1	< .001
N	972		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.385	1.025	1.745	
Fisher's exact test	1.383	1.010	1.763	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2532
Cramer's V	0.2532

Logistic Regression Tables Spontanes Trading

Logistic Regression

Model Summary - Spontan_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	836.2	838.175	843.044	961			0.000		0.000	
M_1	698.7	726.719	794.886	948	137.455	< .001	0.1644	0.2293	0.1792	0.1331

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Push

Coefficients

									95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Test Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-1.681	0.089	0.1862	-18.97	359.7	1	< .001	0.156	0.222
M_1	(Intercept)	1.145	0.713	3.143	1.606	2.580	1	.108	0.777	12.717
	gender (2)	-0.035	0.254	0.9659	-0.1362	0.01856	1	.892	0.587	1.591
	z_age_omnibus_18 (2)	-0.156	0.322	0.8556	-0.4841	0.2343	1	.628	0.455	1.609
	z_age_omnibus_18 (3)	-0.704	0.345	0.4945	-2.044	4.176	1	.041	0.252	0.972
	z_age_omnibus_18 (4)	-0.756	0.366	0.4696	-2.063	4.257	1	.039	0.229	0.963
	z_age_omnibus_18 (5)	-0.557	0.345	0.5728	-1.617	2.616	1	.106	0.292	1.125
	Finanzwissen_clean (2)	-2.112	0.813	0.1210	-2.599	6.752	1	.009	0.025	0.595
	Finanzwissen_clean (3)	-3.287	0.702	0.03736	-4.680	21.90	1	< .001	0.009	0.148
	Finanzwissen_clean (4)	-2.861	0.673	0.05720	-4.251	18.07	1	< .001	0.015	0.214
	Finanzwissen_clean (5)	-1.753	0.676	0.1733	-2.591	6.714	1	.010	0.046	0.652
	App_Dauer_clean (2)	-0.290	0.328	0.7483	-0.8829	0.7796	1	.377	0.393	1.424
	App_Dauer_clean (3)	-0.415	0.370	0.6602	-1.122	1.259	1	.262	0.320	1.363
	App_Dauer_clean (4)	-0.368	0.404	0.6922	-0.9109	0.8297	1	.362	0.314	1.528
	Einfluss_Push (1)	1.001	0.204	2.722	4.918	24.19	1	< .001	1.826	4.057

Note. Spontan_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Spontan_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	839.9	841.908	846.788	972			0.000		0.000	
M_1	718.2	746.223	814.548	959	121.685	< .001	0.1449	0.2033	0.1598	0.1176

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Kursalarm

Coefficients

									95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Test Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-1.694	0.089	0.1837	-19.14	366.3	1	< .001	0.154	0.219
M_1	(Intercept)	1.463	0.714	4.319	2.050	4.204	1	.040	1.067	17.493
	gender (2)	-0.091	0.251	0.9133	-0.3608	0.1302	1	.718	0.558	1.495
	z_age_omnibus_18 (2)	-0.270	0.317	0.7636	-0.8499	0.7224	1	.395	0.410	1.422
	z_age_omnibus_18 (3)	-0.854	0.339	0.4259	-2.516	6.329	1	.012	0.219	0.828
	z_age_omnibus_18 (4)	-0.997	0.358	0.3688	-2.784	7.752	1	.005	0.183	0.744
	z_age_omnibus_18 (5)	-0.791	0.338	0.4532	-2.339	5.471	1	.019	0.233	0.880
	Finanzwissen_clean (2)	-2.286	0.828	0.1017	-2.762	7.629	1	.006	0.020	0.515
	Finanzwissen_clean (3)	-3.370	0.695	0.03438	-4.848	23.50	1	< .001	0.009	0.134
	Finanzwissen_clean (4)	-2.872	0.667	0.05659	-4.304	18.53	1	< .001	0.015	0.209
	Finanzwissen_clean (5)	-1.773	0.670	0.1698	-2.646	7.001	1	.008	0.046	0.631
	App_Dauer_clean (2)	-0.299	0.325	0.7414	-0.9220	0.8501	1	.357	0.392	1.401
	App_Dauer_clean (3)	-0.421	0.366	0.6563	-1.150	1.323	1	.250	0.320	1.345
	App_Dauer_clean (4)	-0.388	0.400	0.6783	-0.9705	0.9418	1	.332	0.310	1.485
	Einfluss_Kursalarm (1)	0.594	0.212	1.811	2.796	7.817	1	.005	1.194	2.746

Note. Spontan_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Spontan_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	803.4	805.413	810.222	905			0.000		0.000	
M_1	642.1	670.059	737.385	892	161.355	< .001	0.2008	0.2774	0.2172	0.1631

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Swipe

Coefficients

									95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Test Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-1.642	0.090	0.1937	-18.22	331.9	1	< .001	0.162	0.231
M_1	(Intercept)	0.882	0.728	2.416	1.212	1.468	1	.226	0.580	10.060
	gender (2)	0.033	0.266	1.033	0.1227	0.01507	1	.902	0.614	1.739
	z_age_omnibus_18 (2)	0.010	0.328	1.010	0.02980	8.882×10^{-4}	1	.976	0.531	1.922
	z_age_omnibus_18 (3)	-0.590	0.354	0.5545	-1.667	2.778	1	.096	0.277	1.109
	z_age_omnibus_18 (4)	-0.561	0.372	0.5706	-1.509	2.278	1	.131	0.275	1.182
	z_age_omnibus_18 (5)	-0.329	0.357	0.7198	-0.9207	0.8477	1	.357	0.357	1.449
	Finanzwissen_clean (2)	-1.969	0.831	0.1395	-2.370	5.615	1	.018	0.027	0.711
	Finanzwissen_clean (3)	-3.198	0.720	0.04085	-4.442	19.74	1	< .001	0.010	0.167
	Finanzwissen_clean (4)	-2.725	0.685	0.06552	-3.980	15.84	1	< .001	0.017	0.251
	Finanzwissen_clean (5)	-1.617	0.689	0.1985	-2.347	5.508	1	.019	0.051	0.766
	App_Dauer_clean (2)	-0.508	0.343	0.6015	-1.484	2.201	1	.138	0.307	1.177
	App_Dauer_clean (3)	-0.704	0.387	0.4946	-1.818	3.304	1	.069	0.232	1.057
	App_Dauer_clean (4)	-0.491	0.416	0.6123	-1.179	1.389	1	.239	0.271	1.384
	Einfluss_Swipe (1)	1.459	0.214	4.302	6.822	46.54	1	< .001	2.829	6.543

Note. Spontan_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Spontan_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	837.2	839.180	844.062	974			0.000		0.000	
M_1	699.3	727.275	795.629	961	137.905	< .001	0.1647	0.2289	0.1794	0.1319

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_SocialMedia

Coefficients

									95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Test Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-1.705	0.089	0.1818	-19.21	368.9	1	< .001	0.153	0.216
M_1	(Intercept)	1.123	0.715	3.075	1.571	2.469	1	.116	0.757	12.480
	gender (2)	-0.139	0.259	0.8706	-0.5355	0.2867	1	.592	0.524	1.446
	z_age_omnibus_18 (2)	0.012	0.323	1.012	0.03702	0.001371	1	.970	0.537	1.907
	z_age_omnibus_18 (3)	-0.591	0.348	0.5540	-1.695	2.873	1	.090	0.280	1.097
	z_age_omnibus_18 (4)	-0.628	0.371	0.5335	-1.691	2.860	1	.091	0.258	1.105
	z_age_omnibus_18 (5)	-0.317	0.357	0.7282	-0.8885	0.7895	1	.374	0.362	1.466
	Finanzwissen_clean (2)	-2.006	0.814	0.1346	-2.464	6.069	1	.014	0.027	0.664
	Finanzwissen_clean (3)	-3.184	0.707	0.04140	-4.506	20.31	1	< .001	0.010	0.165
	Finanzwissen_clean (4)	-2.669	0.675	0.06932	-3.956	15.65	1	< .001	0.018	0.260
	Finanzwissen_clean (5)	-1.581	0.679	0.2057	-2.329	5.423	1	.020	0.054	0.779
	App_Dauer_clean (2)	-0.558	0.326	0.5725	-1.710	2.924	1	.087	0.302	1.085
	App_Dauer_clean (3)	-0.649	0.370	0.5223	-1.755	3.081	1	.079	0.253	1.079
	App_Dauer_clean (4)	-0.621	0.404	0.5375	-1.538	2.365	1	.124	0.244	1.186
	Einfluss_SocialMedia (1)	1.060	0.213	2.886	4.972	24.72	1	< .001	1.900	4.383

Note. Spontan_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Spontan_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	831.4	833.432	838.307	967			0.000		0.000	
M_1	699.7	727.730	795.984	954	131.701	< .001	0.1584	0.2207	0.1764	0.1272

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_lnApp

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-1.704	0.089	0.1819	-19.13	366.1	1	< .001	0.153	0.217
M_1	(Intercept)	1.166	0.713	3.209	1.635	2.673	1	.102	0.793	12.981
	gender (2)	-0.158	0.257	0.8535	-0.6175	0.3814	1	.537	0.516	1.411
	z_age_omnibus_18 (2)	-0.239	0.323	0.7878	-0.7386	0.5456	1	.460	0.418	1.484
	z_age_omnibus_18 (3)	-0.719	0.342	0.4873	-2.100	4.410	1	.036	0.249	0.953
	z_age_omnibus_18 (4)	-0.903	0.362	0.4052	-2.498	6.241	1	.012	0.199	0.823
	z_age_omnibus_18 (5)	-0.670	0.341	0.5117	-1.967	3.871	1	.049	0.263	0.997
	Finanzwissen_clean (2)	-2.143	0.834	0.1172	-2.570	6.603	1	.010	0.023	0.601
	Finanzwissen_clean (3)	-3.324	0.701	0.03601	-4.742	22.49	1	< .001	0.009	0.142
	Finanzwissen_clean (4)	-2.794	0.670	0.06120	-4.167	17.37	1	< .001	0.016	0.228
	Finanzwissen_clean (5)	-1.720	0.675	0.1791	-2.549	6.497	1	.011	0.048	0.672
	App_Dauer_clean (2)	-0.251	0.334	0.7779	-0.7525	0.5663	1	.452	0.404	1.496
	App_Dauer_clean (3)	-0.365	0.376	0.6944	-0.9698	0.9406	1	.332	0.332	1.451
	App_Dauer_clean (4)	-0.288	0.409	0.7497	-0.7040	0.4956	1	.481	0.336	1.672
	Einfluss_lnApp (1)	0.923	0.204	2.517	4.529	20.51	1	< .001	1.688	3.752

Note. Spontan_haeufig level '1' coded as class 1.

Logistic Regression

Model Summary - Spontan_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	837.2	839.197	844.069	964			0.000		0.000	
M_1	699.8	727.767	795.976	951	137.431	< .001	0.1642	0.2288	0.1814	0.1327

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Email

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-1.685	0.089	0.1855	-19.01	361.5	1	< .001	0.156	0.221
M_1	(Intercept)	1.022	0.715	2.779	1.430	2.044	1	.153	0.684	11.288
	gender (2)	-0.118	0.254	0.8890	-0.4634	0.2148	1	.643	0.540	1.462
	z_age_omnibus_18 (2)	-0.099	0.322	0.9056	-0.3080	0.09485	1	.758	0.482	1.702
	z_age_omnibus_18 (3)	-0.691	0.345	0.5013	-2.004	4.017	1	.045	0.255	0.985
	z_age_omnibus_18 (4)	-0.785	0.367	0.4562	-2.141	4.584	1	.032	0.222	0.936
	z_age_omnibus_18 (5)	-0.580	0.344	0.5597	-1.688	2.850	1	.091	0.285	1.098
	Finanzwissen_clean (2)	-1.880	0.817	0.1526	-2.302	5.298	1	.021	0.031	0.756
	Finanzwissen_clean (3)	-3.069	0.703	0.04647	-4.363	19.04	1	< .001	0.012	0.184
	Finanzwissen_clean (4)	-2.565	0.676	0.07690	-3.795	14.40	1	< .001	0.020	0.289
	Finanzwissen_clean (5)	-1.524	0.680	0.2178	-2.242	5.027	1	.025	0.057	0.825
	App_Dauer_clean (2)	-0.391	0.328	0.6766	-1.190	1.416	1	.234	0.356	1.288
	App_Dauer_clean (3)	-0.536	0.371	0.5853	-1.442	2.081	1	.149	0.283	1.212
	App_Dauer_clean (4)	-0.439	0.404	0.6444	-1.089	1.186	1	.276	0.292	1.421
	Einfluss_Email (1)	1.073	0.202	2.923	5.303	28.12	1	< .001	1.966	4.345

Note. Spontan_haeufig level '1' coded as class 1.

Contingency Tables Derivate

Contingency Tables

Einfluss_Push		bank_savings_5 (Derivate) 0	1	Total
0	Count	545.0	47.00	592.0
	Expected count	531.3	60.72	592.0
	% within row	92.06 %	7.94 %	100.00 %
1	Count	330.0	53.00	383.0
	Expected count	343.7	39.28	383.0
	% within row	86.16 %	13.84 %	100.00 %
Total	Count	875.0	100.0	975.0
	Expected count	875.0	100.0	975.0
	% within row	89.74 %	10.26 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	8.792	1	.003
N	975		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.6218	0.206	1.038	
Fisher's exact test	0.6212	0.184	1.061	.003

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.09496
Cramer's V	0.09496

Contingency Tables

Einfluss_Kursalarm		bank_savings_5 (Derivate) 0	1	Total
0	Count	385.0	24.00	409.0
	Expected count	367.4	41.57	409.0
	% within row	94.13 %	5.87 %	100.00 %
1	Count	499.0	76.00	575.0
	Expected count	516.6	58.43	575.0
	% within row	86.78 %	13.22 %	100.00 %
Total	Count	884.0	100.0	984.0
	Expected count	884.0	100.0	984.0
	% within row	89.84 %	10.16 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	14.14	1	< .001
N	984		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.8933	0.416	1.371	
Fisher's exact test	0.8924	0.400	1.416	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1199
Cramer's V	0.1199

Contingency Tables

Einfluss_Swipe		bank_savings_5 (Derivate) 0	1	Total
0	Count	572.0	40.00	612.0
	Expected count	547.2	64.81	612.0
	% within row	93.46 %	6.54 %	100.00 %
1	Count	247.0	57.00	304.0
	Expected count	271.8	32.19	304.0
	% within row	81.25 %	18.75 %	100.00 %
Total	Count	819.0	97.00	916.0
	Expected count	819.0	97.00	916.0
	% within row	89.41 %	10.59 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	32.00	1	< .001
N	916		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	1.194	0.763	1.625	
Fisher's exact test	1.192	0.742	1.651	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1869
Cramer's V	0.1869

Contingency Tables

Einfluss_SocialMedia		bank_savings_5 (Derivate) 0	1	Total
0	Count	630.0	50.00	680.0
	Expected count	610.3	69.66	680.0
	% within row	92.65 %	7.35 %	100.00 %
1	Count	255.0	51.00	306.0
	Expected count	274.7	31.34	306.0
	% within row	83.33 %	16.67 %	100.00 %
Total	Count	885.0	101.0	986.0
	Expected count	885.0	101.0	986.0
	% within row	89.76 %	10.24 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	19.91	1	< .001
N	986		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.9243	0.508	1.341	
Fisher's exact test	0.9232	0.485	1.362	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1421
Cramer's V	0.1421

Contingency Tables

Einfluss_InApp		bank_savings_5 (Derivate) 0	1	Total
0	Count	511.0	45.00	556.0
	Expected count	499.3	56.73	556.0
	% within row	91.91 %	8.09 %	100.00 %
1	Count	369.0	55.00	424.0
	Expected count	380.7	43.27	424.0
	% within row	87.03 %	12.97 %	100.00 %
Total	Count	880.0	100.0	980.0
	Expected count	880.0	100.0	980.0
	% within row	89.80 %	10.20 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	6.247	1	.012
N	980		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.5262	0.110	0.942	
Fisher's exact test	0.5257	0.089	0.966	.014

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.07984
Cramer's V	0.07984

Contingency Tables

Einfluss_Email		bank_savings_5 (Derivate) 0	1	Total
0	Count	598.0	53.00	651.0
	Expected count	583.8	67.23	651.0
	% within row	91.86 %	8.14 %	100.00 %
1	Count	279.0	48.00	327.0
	Expected count	293.2	33.77	327.0
	% within row	85.32 %	14.68 %	100.00 %
Total	Count	877.0	101.0	978.0
	Expected count	877.0	101.0	978.0
	% within row	89.67 %	10.33 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	10.05	1	.002
N	978		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.6633	0.248	1.079	
Fisher's exact test	0.6626	0.224	1.100	.002

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1013
Cramer's V	0.1013

Logistic Regression Tables Derivate

Logistic Regression

Model Summary - bank_savings_5

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	639.0	640.973	645.848	967			0.000		0.000	
M_1	532.2	560.176	628.429	954	106.797	< .001	0.1671	0.2162	0.1445	0.1045

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Push

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-2.172	0.106	0.1139	-20.48	419.4	1	< .001	0.093	0.140
M_1	(Intercept)	0.539	0.623	1.714	0.8649	0.7481	1	.387	0.505	5.814
	gender (2)	-0.524	0.350	0.5923	-1.496	2.237	1	.135	0.298	1.176
	z_age_omnibus_18 (2)	-0.222	0.381	0.8010	-0.5817	0.3384	1	.561	0.379	1.692
	z_age_omnibus_18 (3)	-0.534	0.408	0.5865	-1.307	1.708	1	.191	0.263	1.305
	z_age_omnibus_18 (4)	-1.226	0.478	0.2936	-2.566	6.583	1	.010	0.115	0.749
	z_age_omnibus_18 (5)	-0.581	0.419	0.5595	-1.386	1.922	1	.166	0.246	1.272
	Finanzwissen_clean (2)	-1.450	0.716	0.2346	-2.025	4.099	1	.043	0.058	0.955
	Finanzwissen_clean (3)	-3.493	0.619	0.03042	-5.640	31.81	1	< .001	0.009	0.102
	Finanzwissen_clean (4)	-2.943	0.548	0.05271	-5.374	28.88	1	< .001	0.018	0.154
	Finanzwissen_clean (5)	-1.774	0.537	0.1696	-3.304	10.92	1	< .001	0.059	0.486
	App_Dauer_clean (2)	-0.151	0.458	0.8597	-0.3303	0.1091	1	.741	0.351	2.109
	App_Dauer_clean (3)	0.714	0.482	2.043	1.483	2.199	1	.138	0.795	5.252
	App_Dauer_clean (4)	0.833	0.515	2.299	1.618	2.617	1	.106	0.838	6.306
	Einfluss_Push (1)	0.189	0.246	1.208	0.7665	0.5876	1	.443	0.745	1.958

Note. bank_savings_5 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_5

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	641.1	643.119	648.005	977			0.000		0.000	
M_1	529.3	557.313	625.710	964	111.806	< .001	0.1744	0.2247	0.1499	0.1080

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Kursalarm

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-2.184	0.106	0.1126	-20.60	424.3	1	< .001	0.091	0.139
M_1	(Intercept)	0.062	0.635	1.064	0.09702	0.009412	1	.923	0.307	3.690
	gender (2)	-0.507	0.347	0.6025	-1.460	2.131	1	.144	0.305	1.190
	z_age_omnibus_18 (2)	-0.176	0.380	0.8385	-0.4633	0.2146	1	.643	0.398	1.767
	z_age_omnibus_18 (3)	-0.470	0.407	0.6250	-1.155	1.334	1	.248	0.282	1.388
	z_age_omnibus_18 (4)	-1.155	0.472	0.3149	-2.448	5.992	1	.014	0.125	0.794
	z_age_omnibus_18 (5)	-0.537	0.416	0.5843	-1.293	1.671	1	.196	0.259	1.320
	Finanzwissen_clean (2)	-1.520	0.759	0.2187	-2.003	4.013	1	.045	0.049	0.968
	Finanzwissen_clean (3)	-3.404	0.616	0.03326	-5.525	30.52	1	< .001	0.010	0.111
	Finanzwissen_clean (4)	-2.801	0.545	0.06073	-5.136	26.38	1	< .001	0.021	0.177
	Finanzwissen_clean (5)	-1.641	0.535	0.1938	-3.065	9.394	1	.002	0.068	0.553
	App_Dauer_clean (2)	-0.177	0.459	0.8377	-0.3863	0.1493	1	.699	0.341	2.058
	App_Dauer_clean (3)	0.655	0.482	1.924	1.358	1.843	1	.175	0.748	4.950
	App_Dauer_clean (4)	0.820	0.513	2.270	1.597	2.551	1	.110	0.830	6.208
	Einfluss_Kursalarm (1)	0.649	0.264	1.914	2.462	6.063	1	.014	1.142	3.209

Note. bank_savings_5 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_5

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	613.5	615.546	620.360	910			0.000		0.000	
M_1	502.2	530.172	597.575	897	111.374	< .001	0.1815	0.2348	0.1641	0.1151

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Swipe

Coefficients

									95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Test Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-2.139	0.108	0.1178	-19.82	392.9	1	< .001	0.095	0.146
M_1	(Intercept)	0.025	0.629	1.025	0.03956	0.001565	1	.968	0.299	3.517
	gender (2)	-0.446	0.353	0.6400	-1.265	1.600	1	.206	0.321	1.278
	z_age_omnibus_18 (2)	-0.148	0.387	0.8622	-0.3829	0.1466	1	.702	0.404	1.842
	z_age_omnibus_18 (3)	-0.343	0.415	0.7097	-0.8259	0.6821	1	.409	0.315	1.601
	z_age_omnibus_18 (4)	-1.003	0.478	0.3668	-2.097	4.398	1	.036	0.144	0.936
	z_age_omnibus_18 (5)	-0.296	0.426	0.7434	-0.6961	0.4846	1	.486	0.323	1.713
	Finanzwissen_clean (2)	-1.200	0.731	0.3013	-1.641	2.692	1	.101	0.072	1.263
	Finanzwissen_clean (3)	-3.197	0.625	0.04088	-5.118	26.20	1	< .001	0.012	0.139
	Finanzwissen_clean (4)	-2.826	0.555	0.05928	-5.095	25.96	1	< .001	0.020	0.176
	Finanzwissen_clean (5)	-1.635	0.543	0.1949	-3.012	9.071	1	.003	0.067	0.565
	App_Dauer_clean (2)	-0.222	0.467	0.8012	-0.4749	0.2255	1	.635	0.321	2.000
	App_Dauer_clean (3)	0.602	0.492	1.827	1.225	1.501	1	.220	0.697	4.788
	App_Dauer_clean (4)	0.825	0.521	2.282	1.583	2.505	1	.114	0.821	6.342
	Einfluss_Swipe (1)	0.778	0.254	2.178	3.071	9.429	1	.002	1.325	3.580

Note. bank_savings_5 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_5

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	645.9	647.906	652.794	979			0.000		0.000	
M_1	534.4	562.365	630.790	966	111.542	< .001	0.1727	0.2229	0.1515	0.1076

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_SocialMedia

Coefficients

									95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Test Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-2.175	0.106	0.1136	-20.61	424.8	1	< .001	0.092	0.140
M_1	(Intercept)	0.400	0.637	1.491	0.6274	0.3936	1	.530	0.428	5.199
	gender (2)	-0.586	0.349	0.5566	-1.678	2.817	1	.093	0.281	1.103
	z_age_omnibus_18 (2)	-0.134	0.382	0.8749	-0.3500	0.1225	1	.726	0.414	1.849
	z_age_omnibus_18 (3)	-0.432	0.411	0.6489	-1.052	1.106	1	.293	0.290	1.453
	z_age_omnibus_18 (4)	-1.167	0.481	0.3111	-2.425	5.883	1	.015	0.121	0.799
	z_age_omnibus_18 (5)	-0.476	0.431	0.6210	-1.105	1.220	1	.269	0.267	1.446
	Finanzwissen_clean (2)	-1.498	0.730	0.2235	-2.054	4.217	1	.040	0.053	0.934
	Finanzwissen_clean (3)	-3.481	0.635	0.03078	-5.484	30.08	1	< .001	0.009	0.107
	Finanzwissen_clean (4)	-2.936	0.563	0.05307	-5.215	27.20	1	< .001	0.018	0.160
	Finanzwissen_clean (5)	-1.816	0.556	0.1627	-3.266	10.67	1	.001	0.055	0.484
	App_Dauer_clean (2)	-0.132	0.465	0.8761	-0.2842	0.08075	1	.776	0.352	2.181
	App_Dauer_clean (3)	0.691	0.490	1.996	1.409	1.986	1	.159	0.763	5.217
	App_Dauer_clean (4)	0.848	0.522	2.334	1.625	2.640	1	.104	0.840	6.490
	Einfluss_SocialMedia (1)	0.440	0.259	1.552	1.701	2.893	1	.089	0.935	2.577

Note. bank_savings_5 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_5

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	640.3	642.264	647.145	973			0.000		0.000	
M_1	533.8	561.837	630.177	960	106.426	< .001	0.1662	0.2148	0.1458	0.1035

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_InApp

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-2.179	0.106	0.1131	-20.55	422.4	1	< .001	0.092	0.139
M_1	(Intercept)	0.417	0.619	1.517	0.6737	0.4539	1	.500	0.451	5.104
	gender (2)	-0.553	0.346	0.5751	-1.600	2.560	1	.110	0.292	1.133
	z_age_omnibus_18 (2)	-0.175	0.381	0.8397	-0.4591	0.2108	1	.646	0.398	1.770
	z_age_omnibus_18 (3)	-0.490	0.407	0.6129	-1.203	1.447	1	.229	0.276	1.361
	z_age_omnibus_18 (4)	-1.248	0.471	0.2872	-2.649	7.018	1	.008	0.114	0.723
	z_age_omnibus_18 (5)	-0.573	0.416	0.5637	-1.378	1.899	1	.168	0.249	1.274
	Finanzwissen_clean (2)	-1.557	0.753	0.2108	-2.068	4.276	1	.039	0.048	0.922
	Finanzwissen_clean (3)	-3.438	0.618	0.03214	-5.561	30.92	1	< .001	0.010	0.108
	Finanzwissen_clean (4)	-2.869	0.545	0.05677	-5.260	27.66	1	< .001	0.019	0.165
	Finanzwissen_clean (5)	-1.730	0.537	0.1773	-3.220	10.37	1	.001	0.062	0.508
	App_Dauer_clean (2)	-0.154	0.458	0.8571	-0.3367	0.1134	1	.736	0.349	2.102
	App_Dauer_clean (3)	0.692	0.483	1.998	1.434	2.055	1	.152	0.776	5.144
	App_Dauer_clean (4)	0.844	0.515	2.326	1.640	2.689	1	.101	0.848	6.382
	Einfluss_InApp (1)	0.315	0.242	1.371	1.302	1.695	1	.193	0.853	2.203

Note. bank_savings_5 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_5

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	644.0	645.960	650.838	970			0.000		0.000	
M_1	536.1	564.098	632.395	957	107.861	< .001	0.1675	0.2169	0.1470	0.1051

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Email

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-2.164	0.106	0.1148	-20.50	420.3	1	< .001	0.093	0.141
M_1	(Intercept)	0.641	0.637	1.899	1.007	1.013	1	.314	0.545	6.623
	gender (2)	-0.592	0.348	0.5530	-1.704	2.902	1	.088	0.280	1.093
	z_age_omnibus_18 (2)	-0.207	0.379	0.8130	-0.5459	0.2980	1	.585	0.387	1.710
	z_age_omnibus_18 (3)	-0.562	0.408	0.5698	-1.380	1.904	1	.168	0.256	1.267
	z_age_omnibus_18 (4)	-1.292	0.474	0.2746	-2.724	7.422	1	.006	0.108	0.696
	z_age_omnibus_18 (5)	-0.646	0.419	0.5243	-1.540	2.373	1	.123	0.231	1.192
	Finanzwissen_clean (2)	-1.535	0.730	0.2154	-2.104	4.429	1	.035	0.052	0.900
	Finanzwissen_clean (3)	-3.558	0.635	0.02849	-5.607	31.44	1	< .001	0.008	0.099
	Finanzwissen_clean (4)	-2.978	0.568	0.05088	-5.242	27.48	1	< .001	0.017	0.155
	Finanzwissen_clean (5)	-1.875	0.558	0.1533	-3.362	11.30	1	< .001	0.051	0.457
	App_Dauer_clean (2)	-0.107	0.464	0.8983	-0.2313	0.05349	1	.817	0.362	2.229
	App_Dauer_clean (3)	0.715	0.488	2.045	1.464	2.144	1	.143	0.785	5.326
	App_Dauer_clean (4)	0.872	0.519	2.391	1.680	2.822	1	.093	0.865	6.614
	Einfluss_Email (1)	0.193	0.252	1.213	0.7666	0.5877	1	.443	0.740	1.989

Note. bank_savings_5 level '1' coded as class 1.

Contingency Tables Kryptowährungen

Contingency Tables

Einfluss_Push		bank_savings_16 (Krypto) 0	1	Total
0	Count	378.0	214.0	592.0
	Expected count	368.6	223.4	592.0
	% within row	63.85 %	36.15 %	100.00 %
1	Count	229.0	154.0	383.0
	Expected count	238.4	144.6	383.0
	% within row	59.79 %	40.21 %	100.00 %
Total	Count	607.0	368.0	975.0
	Expected count	607.0	368.0	975.0
	% within row	62.26 %	37.74 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	1.632	1	.201
N	975		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.1721	-0.092	0.436	
Fisher's exact test	0.1720	-0.101	0.445	.223

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.04091
Cramer's V	0.04091

Contingency Tables

Einfluss_Kursalarm		bank_savings_16 (Krypto) 0	1	Total
0	Count	284.0	125.0	409.0
	Expected count	254.4	154.6	409.0
	% within row	69.44 %	30.56 %	100.00 %
1	Count	328.0	247.0	575.0
	Expected count	357.6	217.4	575.0
	% within row	57.04 %	42.96 %	100.00 %
Total	Count	612.0	372.0	984.0
	Expected count	612.0	372.0	984.0
	% within row	62.20 %	37.80 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	15.61	1	< .001
N	984		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.5370	0.270	0.804	
Fisher's exact test	0.5365	0.261	0.814	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1260
Cramer's V	0.1260

Contingency Tables

Einfluss_Swipe		bank_savings_16 (Krypto) 0	1	Total
0	Count	394.0	218.0	612.0
	Expected count	379.5	232.5	612.0
	% within row	64.38 %	35.62 %	100.00 %
1	Count	174.0	130.0	304.0
	Expected count	188.5	115.5	304.0
	% within row	57.24 %	42.76 %	100.00 %
Total	Count	568.0	348.0	916.0
	Expected count	568.0	348.0	916.0
	% within row	62.01 %	37.99 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	4.398	1	.036
N	916		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.3003	0.019	0.581	
Fisher's exact test	0.3000	0.009	0.591	.043

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.06929
Cramer's V	0.06929

Contingency Tables

Einfluss_SocialMedia		bank_savings_16 (Krypto) 0	1	Total
0	Count	441.0	239.0	680.0
	Expected count	421.4	258.6	680.0
	% within row	64.85 %	35.15 %	100.00 %
1	Count	170.0	136.0	306.0
	Expected count	189.6	116.4	306.0
	% within row	55.56 %	44.44 %	100.00 %
Total	Count	611.0	375.0	986.0
	Expected count	611.0	375.0	986.0
	% within row	61.97 %	38.03 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	7.740	1	.005
N	986		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.3894	0.114	0.664	
Fisher's exact test	0.3890	0.104	0.673	.006

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.08860
Cramer's V	0.08860

Contingency Tables

Einfluss_InApp		bank_savings_16 (Krypto) 0	1	Total
0	Count	355.0	201.0	556.0
	Expected count	345.5	210.5	556.0
	% within row	63.85 %	36.15 %	100.00 %
1	Count	254.0	170.0	424.0
	Expected count	263.5	160.5	424.0
	% within row	59.91 %	40.09 %	100.00 %
Total	Count	609.0	371.0	980.0
	Expected count	609.0	371.0	980.0
	% within row	62.14 %	37.86 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	1.590	1	.207
N	980		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.1673	-0.093	0.427	
Fisher's exact test	0.1671	-0.102	0.436	.232

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.04028
Cramer's V	0.04028

Contingency Tables

Einfluss_Email		bank_savings_16 (Krypto) 0	1	Total
0	Count	405.0	246.0	651.0
	Expected count	404.0	247.0	651.0
	% within row	62.21 %	37.79 %	100.00 %
1	Count	202.0	125.0	327.0
	Expected count	203.0	124.0	327.0
	% within row	61.77 %	38.23 %	100.00 %
Total	Count	607.0	371.0	978.0
	Expected count	607.0	371.0	978.0
	% within row	62.07 %	37.93 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	0.01776	1	.894
N	978		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.01860	-0.255	0.292	
Fisher's exact test	0.01859	-0.265	0.301	.944

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.004261
Cramer's V	0.004261

Logistic Regression Tables Kryptowährungen

Logistic Regression

Model Summary - bank_savings_16

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1285	1286.803	1291.678	967			0.000		0.000	
M_1	1220	1248.295	1316.548	954	64.508	< .001	0.05021	0.08774	0.06624	0.06447

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Push

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.493	0.066	0.6106	-7.445	55.43	1	< .001	0.536	0.695
M_1	(Intercept)	0.810	0.539	2.248	1.503	2.258	1	.133	0.781	6.467
	gender (2)	-0.293	0.177	0.7460	-1.660	2.755	1	.097	0.528	1.054
	z_age_omnibus_18 (2)	0.015	0.275	1.016	0.05594	0.003130	1	.955	0.592	1.742
	z_age_omnibus_18 (3)	0.423	0.270	1.526	1.563	2.443	1	.118	0.898	2.592
	z_age_omnibus_18 (4)	0.025	0.280	1.025	0.08926	0.007967	1	.929	0.592	1.776
	z_age_omnibus_18 (5)	-0.446	0.279	0.6404	-1.595	2.545	1	.111	0.370	1.107
	Finanzwissen_clean (2)	-2.258	0.715	0.1045	-3.160	9.985	1	.002	0.026	0.424
	Finanzwissen_clean (3)	-1.800	0.532	0.1653	-3.384	11.45	1	< .001	0.058	0.469
	Finanzwissen_clean (4)	-1.552	0.521	0.2118	-2.981	8.886	1	.003	0.076	0.588
	Finanzwissen_clean (5)	-1.143	0.528	0.3189	-2.163	4.679	1	.031	0.113	0.898
	App_Dauer_clean (2)	0.135	0.245	1.144	0.5494	0.3018	1	.583	0.708	1.849
	App_Dauer_clean (3)	0.440	0.269	1.552	1.637	2.679	1	.102	0.917	2.628
	App_Dauer_clean (4)	0.562	0.290	1.754	1.940	3.765	1	.052	0.994	3.094
	Einfluss_Push (1)	0.041	0.146	1.042	0.2812	0.07905	1	.779	0.783	1.387

Note. bank_savings_16 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_16

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1298	1300.281	1305.167	977			0.000		0.000	
M_1	1225	1252.712	1321.109	964	73.569	< .001	0.05667	0.09861	0.07481	0.07246

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Kursalarm

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.492	0.066	0.6112	-7.471	55.81	1	< .001	0.537	0.695
M_1	(Intercept)	0.306	0.541	1.358	0.5656	0.3199	1	.572	0.471	3.918
	gender (2)	-0.241	0.174	0.7862	-1.379	1.902	1	.168	0.559	1.107
	z_age_omnibus_18 (2)	0.091	0.276	1.096	0.3315	0.1099	1	.740	0.638	1.880
	z_age_omnibus_18 (3)	0.478	0.271	1.612	1.761	3.101	1	.078	0.947	2.743
	z_age_omnibus_18 (4)	0.076	0.278	1.079	0.2732	0.07465	1	.785	0.626	1.860
	z_age_omnibus_18 (5)	-0.374	0.277	0.6882	-1.349	1.820	1	.177	0.400	1.184
	Finanzwissen_clean (2)	-2.076	0.720	0.1255	-2.881	8.299	1	.004	0.031	0.515
	Finanzwissen_clean (3)	-1.634	0.531	0.1952	-3.077	9.465	1	.002	0.069	0.553
	Finanzwissen_clean (4)	-1.420	0.521	0.2417	-2.725	7.424	1	.006	0.087	0.671
	Finanzwissen_clean (5)	-1.025	0.529	0.3586	-1.938	3.757	1	.053	0.127	1.012
	App_Dauer_clean (2)	0.138	0.245	1.148	0.5641	0.3182	1	.573	0.710	1.856
	App_Dauer_clean (3)	0.449	0.269	1.566	1.667	2.780	1	.095	0.924	2.653
	App_Dauer_clean (4)	0.630	0.289	1.878	2.184	4.771	1	.029	1.067	3.306
	Einfluss_Kursalarm (1)	0.506	0.143	1.659	3.526	12.43	1	< .001	1.252	2.197

Note. bank_savings_16 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_16

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1211	1212.725	1217.539	910			0.000		0.000	
M_1	1155	1182.917	1250.320	897	55.808	< .001	0.04609	0.08082	0.06084	0.05942

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Swipe

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.486	0.068	0.6152	-7.119	50.68	1	< .001	0.538	0.703
M_1	(Intercept)	0.733	0.544	2.081	1.347	1.815	1	.178	0.717	6.042
	gender (2)	-0.340	0.182	0.7117	-1.864	3.475	1	.062	0.498	1.018
	z_age_omnibus_18 (2)	0.099	0.279	1.104	0.3538	0.1252	1	.723	0.639	1.908
	z_age_omnibus_18 (3)	0.407	0.276	1.503	1.476	2.178	1	.140	0.875	2.581
	z_age_omnibus_18 (4)	-0.014	0.286	0.9860	-0.04925	0.002426	1	.961	0.562	1.729
	z_age_omnibus_18 (5)	-0.310	0.286	0.7338	-1.081	1.168	1	.280	0.419	1.286
	Finanzwissen_clean (2)	-2.128	0.720	0.1191	-2.956	8.739	1	.003	0.029	0.488
	Finanzwissen_clean (3)	-1.745	0.536	0.1746	-3.254	10.59	1	.001	0.061	0.500
	Finanzwissen_clean (4)	-1.562	0.524	0.2097	-2.982	8.891	1	.003	0.075	0.586
	Finanzwissen_clean (5)	-1.168	0.531	0.3109	-2.201	4.846	1	.028	0.110	0.880
	App_Dauer_clean (2)	0.123	0.253	1.131	0.4859	0.2361	1	.627	0.688	1.858
	App_Dauer_clean (3)	0.454	0.276	1.575	1.643	2.701	1	.100	0.916	2.708
	App_Dauer_clean (4)	0.638	0.297	1.893	2.148	4.615	1	.032	1.058	3.387
	Einfluss_Swipe (1)	0.114	0.158	1.121	0.7205	0.5191	1	.471	0.822	1.528

Note. bank_savings_16 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_16

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1303	1305.121	1310.009	979			0.000		0.000	
M_1	1239	1266.608	1335.034	966	64.513	< .001	0.04951	0.08663	0.06527	0.06371

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_SocialMedia

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.483	0.066	0.6172	-7.340	53.87	1	< .001	0.543	0.702
M_1	(Intercept)	0.850	0.572	2.339	1.485	2.204	1	.138	0.762	7.180
	gender (2)	-0.284	0.173	0.7530	-1.638	2.684	1	.101	0.536	1.057
	z_age_omnibus_18 (2)	0.087	0.277	1.091	0.3141	0.09868	1	.753	0.634	1.878
	z_age_omnibus_18 (3)	0.451	0.274	1.570	1.647	2.714	1	.099	0.918	2.686
	z_age_omnibus_18 (4)	0.042	0.284	1.043	0.1473	0.02169	1	.883	0.598	1.818
	z_age_omnibus_18 (5)	-0.339	0.285	0.7127	-1.187	1.408	1	.235	0.407	1.247
	Finanzwissen_clean (2)	-2.437	0.736	0.08745	-3.309	10.95	1	< .001	0.021	0.370
	Finanzwissen_clean (3)	-1.842	0.563	0.1584	-3.275	10.73	1	.001	0.053	0.477
	Finanzwissen_clean (4)	-1.659	0.552	0.1903	-3.003	9.020	1	.003	0.064	0.562
	Finanzwissen_clean (5)	-1.306	0.560	0.2710	-2.332	5.438	1	.020	0.090	0.812
	App_Dauer_clean (2)	0.090	0.244	1.094	0.3690	0.1362	1	.712	0.678	1.765
	App_Dauer_clean (3)	0.415	0.267	1.514	1.550	2.403	1	.121	0.896	2.557
	App_Dauer_clean (4)	0.603	0.287	1.827	2.099	4.405	1	.036	1.041	3.208
	Einfluss_SocialMedia (1)	0.198	0.158	1.219	1.253	1.571	1	.210	0.894	1.661

Note. bank_savings_16 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_16

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1293	1295.479	1300.361	973			0.000		0.000	
M_1	1231	1259.039	1327.379	960	62.440	< .001	0.04827	0.08448	0.06388	0.06210

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_lnApp

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.490	0.066	0.6126	-7.423	55.11	1	< .001	0.538	0.697
M_1	(Intercept)	0.653	0.538	1.922	1.214	1.473	1	.225	0.669	5.521
	gender (2)	-0.306	0.174	0.7364	-1.761	3.100	1	.078	0.524	1.035
	z_age_omnibus_18 (2)	0.073	0.275	1.076	0.2654	0.07045	1	.791	0.628	1.842
	z_age_omnibus_18 (3)	0.410	0.269	1.507	1.525	2.324	1	.127	0.889	2.553
	z_age_omnibus_18 (4)	0.003	0.275	1.003	0.01147	1.316×10^{-4}	1	.991	0.585	1.721
	z_age_omnibus_18 (5)	-0.385	0.274	0.6807	-1.403	1.968	1	.161	0.398	1.165
	Finanzwissen_clean (2)	-2.167	0.718	0.1145	-3.018	9.109	1	.003	0.028	0.468
	Finanzwissen_clean (3)	-1.741	0.531	0.1753	-3.276	10.73	1	.001	0.062	0.497
	Finanzwissen_clean (4)	-1.543	0.521	0.2138	-2.960	8.762	1	.003	0.077	0.594
	Finanzwissen_clean (5)	-1.167	0.529	0.3114	-2.205	4.860	1	.027	0.110	0.879
	App_Dauer_clean (2)	0.202	0.249	1.223	0.8084	0.6535	1	.419	0.750	1.994
	App_Dauer_clean (3)	0.524	0.273	1.689	1.923	3.697	1	.055	0.990	2.882
	App_Dauer_clean (4)	0.729	0.293	2.072	2.488	6.188	1	.013	1.167	3.680
	Einfluss_lnApp (1)	0.143	0.141	1.154	1.015	1.030	1	.310	0.875	1.522

Note. bank_savings_16 level '1' coded as class 1.

Logistic Regression

Model Summary - bank_savings_16

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1291	1292.607	1297.485	970			0.000		0.000	
M_1	1226	1253.831	1322.128	957	64.776	< .001	0.05019	0.08777	0.06604	0.06453

Note. M_1 includes gender, z_age_omnibus_18, Finanzwissen_clean, App_Dauer_clean, Einfluss_Email

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-0.485	0.066	0.6156	-7.341	53.89	1	< .001	0.541	0.701
M_1	(Intercept)	1.096	0.572	2.991	1.914	3.664	1	.056	0.974	9.182
	gender (2)	-0.316	0.175	0.7293	-1.805	3.258	1	.071	0.518	1.027
	z_age_omnibus_18 (2)	0.001	0.278	1.001	0.004141	1.714×10^{-5}	1	.997	0.581	1.725
	z_age_omnibus_18 (3)	0.345	0.272	1.412	1.266	1.604	1	.205	0.828	2.408
	z_age_omnibus_18 (4)	-0.085	0.281	0.9185	-0.3021	0.09128	1	.763	0.529	1.594
	z_age_omnibus_18 (5)	-0.480	0.280	0.6186	-1.713	2.935	1	.087	0.357	1.072
	Finanzwissen_clean (2)	-2.576	0.738	0.07607	-3.491	12.19	1	< .001	0.018	0.323
	Finanzwissen_clean (3)	-2.031	0.565	0.1313	-3.593	12.91	1	< .001	0.043	0.397
	Finanzwissen_clean (4)	-1.846	0.556	0.1578	-3.319	11.02	1	< .001	0.053	0.470
	Finanzwissen_clean (5)	-1.472	0.562	0.2295	-2.617	6.848	1	.009	0.076	0.691
	App_Dauer_clean (2)	0.261	0.251	1.299	1.043	1.089	1	.297	0.795	2.122
	App_Dauer_clean (3)	0.584	0.274	1.793	2.134	4.554	1	.033	1.049	3.066
	App_Dauer_clean (4)	0.742	0.294	2.100	2.526	6.382	1	.012	1.181	3.733
	Einfluss_Email (1)	-0.147	0.153	0.8636	-0.9594	0.9204	1	.337	0.640	1.165

Note. bank_savings_16 level '1' coded as class 1.

Contingency Tables Einfluss mehrerer App-Funktionen

Contingency Tables

Einfluss_Gruppe		Trading_haeufig 0	Trading_haeufig 1	Total
0 Funktionen	Count	197.0	46.00	243.0
	Expected count	163.7	79.31	243.0
	% within row	81.07 %	18.93 %	100.00 %
1-2 Funktionen	Count	201.0	73.00	274.0
	Expected count	184.6	89.42	274.0
	% within row	73.36 %	26.64 %	100.00 %
3-4 Funktionen	Count	100.0	53.00	153.0
	Expected count	103.1	49.93	153.0
	% within row	65.36 %	34.64 %	100.00 %
5-6 Funktionen	Count	82.00	109.0	191.0
	Expected count	128.7	62.34	191.0
	% within row	42.93 %	57.07 %	100.00 %
Total	Count	580.0	281.0	861.0
	Expected count	580.0	281.0	861.0
	% within row	67.36 %	32.64 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	77.38	3	< .001
N	861		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.2998

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Contingency Tables

Einfluss_Gruppe		Ohne_Verstaendnis 0	Ohne_Verstaendnis 1	Total
0 Funktionen	Count	114.0	128.0	242.0
	Expected count	75.34	166.7	242.0
	% within row	47.11 %	52.89 %	100.00 %
1-2 Funktionen	Count	86.00	188.0	274.0
	Expected count	85.31	188.7	274.0
	% within row	31.39 %	68.61 %	100.00 %
3-4 Funktionen	Count	38.00	118.0	156.0
	Expected count	48.57	107.4	156.0
	% within row	24.36 %	75.64 %	100.00 %
5-6 Funktionen	Count	31.00	161.0	192.0
	Expected count	59.78	132.2	192.0
	% within row	16.15 %	83.85 %	100.00 %
Total	Count	269.0	595.0	864.0
	Expected count	269.0	595.0	864.0
	% within row	31.13 %	68.87 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	52.26	3	< .001
N	864		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.2459

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Contingency Tables

Einfluss_Gruppe		bank_savings_5 (Derivate) 0	1	Total
0 Funktionen	Count	230.0	16.00	246.0
	Expected count	219.3	26.74	246.0
	% within row	93.50 %	6.50 %	100.00 %
1-2 Funktionen	Count	254.0	23.00	277.0
	Expected count	246.9	30.11	277.0
	% within row	91.70 %	8.30 %	100.00 %
3-4 Funktionen	Count	142.0	14.00	156.0
	Expected count	139.0	16.96	156.0
	% within row	91.03 %	8.97 %	100.00 %
5-6 Funktionen	Count	153.0	42.00	195.0
	Expected count	173.8	21.20	195.0
	% within row	78.46 %	21.54 %	100.00 %
Total	Count	779.0	95.00	874.0
	Expected count	779.0	95.00	874.0
	% within row	89.13 %	10.87 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	30.21	3	< .001
N	874		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.1859

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Contingency Tables

Einfluss_Gruppe		bank_savings_16 (Krypto) 0	1	Total
0 Funktionen	Count	167.0	79.00	246.0
	Expected count	150.9	95.14	246.0
	% within row	67.89 %	32.11 %	100.00 %
1-2 Funktionen	Count	166.0	111.0	277.0
	Expected count	169.9	107.1	277.0
	% within row	59.93 %	40.07 %	100.00 %
3-4 Funktionen	Count	100.0	56.00	156.0
	Expected count	95.67	60.33	156.0
	% within row	64.10 %	35.90 %	100.00 %
5-6 Funktionen	Count	103.0	92.00	195.0
	Expected count	119.6	75.41	195.0
	% within row	52.82 %	47.18 %	100.00 %
Total	Count	536.0	338.0	874.0
	Expected count	536.0	338.0	874.0
	% within row	61.33 %	38.67 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	11.15	3	.011
N	874		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.1129

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Contingency Tables

Einfluss_Gruppe		Spontan_haeufig 0	Spontan_haeufig 1	Total
0 Funktionen	Count	222.0	24.00	246.0
	Expected count	205.6	40.43	246.0
	% within row	90.24 %	9.76 %	100.00 %
1-2 Funktionen	Count	260.0	16.00	276.0
	Expected count	230.6	45.37	276.0
	% within row	94.20 %	5.80 %	100.00 %
3-4 Funktionen	Count	130.0	26.00	156.0
	Expected count	130.4	25.64	156.0
	% within row	83.33 %	16.67 %	100.00 %
5-6 Funktionen	Count	115.0	77.00	192.0
	Expected count	160.4	31.56	192.0
	% within row	59.90 %	40.10 %	100.00 %
Total	Count	727.0	143.0	870.0
	Expected count	727.0	143.0	870.0
	% within row	83.56 %	16.44 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	109.0	3	< .001
N	870		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.3540

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Frequency Tables Aussagen verändertes Tradingverhalten

Frequencies for Anlage08_1 („Ich trade häufiger als vorher“)

Anlage08_1	Frequency	Percent	Valid Percent	Cumulative Percent
0	734	71.9	71.9	71.9
1	287	28.1	28.1	100.0
Missing	0	0.0		
Total	1021	100.0		

Frequencies for Anlage08_3 („Ich treffe Entscheidungen schneller / spontaner“)

Anlage08_3	Frequency	Percent	Valid Percent	Cumulative Percent
0	729	71.4	71.4	71.4
1	292	28.6	28.6	100.0
Missing	0	0.0		
Total	1021	100.0		

Frequencies for Anlage08_4 („Ich gehe höhere Risiken ein“)

Anlage08_4	Frequency	Percent	Valid Percent	Cumulative Percent
0	867	84.9	84.9	84.9
1	154	15.1	15.1	100.0
Missing	0	0.0		
Total	1021	100.0		

Contingency Tables Aussage „Ich trade häufiger als vorher“

Contingency Tables

Einfluss_Push		Anlage08_1 („Ich trade häufiger als vorher“) 0	1	Total
0	Count	436.0	156.0	592.0
	Expected count	425.6	166.4	592.0
	% within row	73.65 %	26.35 %	100.00 %
1	Count	265.0	118.0	383.0
	Expected count	275.4	107.6	383.0
	% within row	69.19 %	30.81 %	100.00 %
Total	Count	701.0	274.0	975.0
	Expected count	701.0	274.0	975.0
	% within row	71.90 %	28.10 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	2.287	1	.130
N	975		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.2187	-0.065	0.502	
Fisher's exact test	0.2185	-0.076	0.512	.145

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.04844
Cramer's V	0.04844

Contingency Tables

Einfluss_Kursalarm		Anlage08_1 („Ich trade häufiger als vorher“) 0	1	Total
0	Count	313.0	96.00	409.0
	Expected count	292.6	116.4	409.0
	% within row	76.53 %	23.47 %	100.00 %
1	Count	391.0	184.0	575.0
	Expected count	411.4	163.6	575.0
	% within row	68.00 %	32.00 %	100.00 %
Total	Count	704.0	280.0	984.0
	Expected count	704.0	280.0	984.0
	% within row	71.54 %	28.46 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	8.538	1	.003
N	984		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.4281	0.140	0.716	
Fisher's exact test	0.4276	0.131	0.728	.004

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.09315
Cramer's V	0.09315

Contingency Tables

Einfluss_Swipe		Anlage08_1 („Ich trade häufiger als vorher“) 0	1	Total
0	Count	450.0	162.0	612.0
	Expected count	440.3	171.7	612.0
	% within row	73.53 %	26.47 %	100.00 %
1	Count	209.0	95.00	304.0
	Expected count	218.7	85.29	304.0
	% within row	68.75 %	31.25 %	100.00 %
Total	Count	659.0	257.0	916.0
	Expected count	659.0	257.0	916.0
	% within row	71.94 %	28.06 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	2.299	1	.129
N	916		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.2332	-0.069	0.535	
Fisher's exact test	0.2329	-0.082	0.545	.138

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.05009
Cramer's V	0.05009

Contingency Tables

Einfluss_SocialMedia		Anlage08_1 („Ich trade häufiger als vorher“) 0	1	Total
0	Count	493.0	187.0	680.0
	Expected count	488.3	191.7	680.0
	% within row	72.50 %	27.50 %	100.00 %
1	Count	215.0	91.00	306.0
	Expected count	219.7	86.28	306.0
	% within row	70.26 %	29.74 %	100.00 %
Total	Count	708.0	278.0	986.0
	Expected count	708.0	278.0	986.0
	% within row	71.81 %	28.19 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	0.5224	1	.470
N	986		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.1096	-0.188	0.407	
Fisher's exact test	0.1095	-0.201	0.416	.491

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.02302
Cramer's V	0.02302

Contingency Tables

Einfluss_InApp		Anlage08_1 („Ich trade häufiger als vorher“) 0	1	Total
0	Count	412.0	144.0	556.0
	Expected count	400.5	155.5	556.0
	% within row	74.10 %	25.90 %	100.00 %
1	Count	294.0	130.0	424.0
	Expected count	305.5	118.5	424.0
	% within row	69.34 %	30.66 %	100.00 %
Total	Count	706.0	274.0	980.0
	Expected count	706.0	274.0	980.0
	% within row	72.04 %	27.96 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	2.707	1	.100
N	980		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.2352	-0.045	0.516	
Fisher's exact test	0.2349	-0.056	0.525	.114

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.05256
Cramer's V	0.05256

Contingency Tables

Einfluss_Email		Anlage08_1 („Ich trade häufiger als vorher“) 0	1	Total
0	Count	478.0	173.0	651.0
	Expected count	468.6	182.4	651.0
	% within row	73.43 %	26.57 %	100.00 %
1	Count	226.0	101.0	327.0
	Expected count	235.4	91.61	327.0
	% within row	69.11 %	30.89 %	100.00 %
Total	Count	704.0	274.0	978.0
	Expected count	704.0	274.0	978.0
	% within row	71.98 %	28.02 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	2.007	1	.157
N	978		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.2109	-0.081	0.503	
Fisher's exact test	0.2107	-0.093	0.512	.174

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.04530
Cramer's V	0.04530

Contingency Tables Aussage „Ich treffe Entscheidungen schneller / spontaner“

Contingency Tables

Einfluss_Push		Anlage08_3 („Ich treffe Entscheidungen schneller / spontaner“) 0	1	Total
0	Count	441.0	151.0	592.0
	Expected count	422.6	169.4	592.0
	% within row	74.49 %	25.51 %	100.00 %
1	Count	255.0	128.0	383.0
	Expected count	273.4	109.6	383.0
	% within row	66.58 %	33.42 %	100.00 %
Total	Count	696.0	279.0	975.0
	Expected count	696.0	279.0	975.0
	% within row	71.38 %	28.62 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	7.130	1	.008
N	975		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.3825	0.101	0.664	
Fisher's exact test	0.3821	0.090	0.673	.009

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Phi-coefficient	0.08551			
Cramer's V	0.08551			

Contingency Tables

Einfluss_Kursalarm		Anlage08_3 („Ich treffe Entscheidungen schneller / spontaner“)		Total
		0	1	
0	Count	319.0	90.00	409.0
	Expected count	291.4	117.6	409.0
	% within row	78.00 %	22.00 %	100.00 %
1	Count	382.0	193.0	575.0
	Expected count	409.6	165.4	575.0
	% within row	66.43 %	33.57 %	100.00 %
Total	Count	701.0	283.0	984.0
	Expected count	701.0	283.0	984.0
	% within row	71.24 %	28.76 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	15.59	1	< .001
N	984		

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Log Odds Ratio	0.5827	0.292	0.874	
Fisher's exact test	0.5821	0.283	0.886	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Phi-coefficient	0.1259			
Cramer's V	0.1259			

Contingency Tables

Einfluss_Swipe		Anlage08_3 („Ich treffe Entscheidungen schneller / spontaner“) 0	1	Total
0	Count	455.0	157.0	612.0
	Expected count	438.3	173.7	612.0
	% within row	74.35 %	25.65 %	100.00 %
1	Count	201.0	103.0	304.0
	Expected count	217.7	86.29	304.0
	% within row	66.12 %	33.88 %	100.00 %
Total	Count	656.0	260.0	916.0
	Expected count	656.0	260.0	916.0
	% within row	71.62 %	28.38 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	6.764	1	.009
N	916		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.3955	0.097	0.694	
Fisher's exact test	0.3951	0.084	0.704	.010

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.08593

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Cramer's V	0.08593			

Contingency Tables

Einfluss_InApp		Anlage08_3 („Ich treffe Entscheidungen schneller / spontaner“) 0	1	Total
0	Count	422.0	134.0	556.0
	Expected count	394.3	161.7	556.0
	% within row	75.90 %	24.10 %	100.00 %
1	Count	273.0	151.0	424.0
	Expected count	300.7	123.3	424.0
	% within row	64.39 %	35.61 %	100.00 %
Total	Count	695.0	285.0	980.0
	Expected count	695.0	285.0	980.0
	% within row	70.92 %	29.08 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	15.46	1	< .001
N	980		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.5550	0.277	0.833	
Fisher's exact test	0.5544	0.267	0.843	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1256

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Cramer's V	0.1256			

Contingency Tables

Einfluss_Email		Anlage08_3 („Ich treffe Entscheidungen schneller / spontaner“) 0	1	Total
0	Count	479.0	172.0	651.0
	Expected count	461.3	189.7	651.0
	% within row	73.58 %	26.42 %	100.00 %
1	Count	214.0	113.0	327.0
	Expected count	231.7	95.29	327.0
	% within row	65.44 %	34.56 %	100.00 %
Total	Count	693.0	285.0	978.0
	Expected count	693.0	285.0	978.0
	% within row	70.86 %	29.14 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	6.977	1	.008
N	978		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.3856	0.099	0.672	
Fisher's exact test	0.3853	0.087	0.682	.009

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.08446
Cramer's V	0.08446

Contingency Tables

Einfluss_SocialMedia		Anlage08_3 („Ich treffe Entscheidungen schneller / spontaner“)		
		0	1	Total
0	Count	495.0	185.0	680.0
	Expected count	482.8	197.2	680.0
	% within row	72.79 %	27.21 %	100.00 %
1	Count	205.0	101.0	306.0
	Expected count	217.2	88.76	306.0
	% within row	66.99 %	33.01 %	100.00 %
Total	Count	700.0	286.0	986.0
	Expected count	700.0	286.0	986.0
	% within row	70.99 %	29.01 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	3.448	1	.063
N	986		

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Log Odds Ratio	0.2763	-0.016	0.568	
Fisher's exact test	0.2760	-0.028	0.578	.069

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.05914

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Cramer's V	0.05914			

Contingency Tables Aussage „Ich gehe höhere Risiken ein“

Contingency Tables

Einfluss_Push		Anlage08_4 („Ich gehe höhere Risiken ein“) 0	1	Total
0	Count	529.0	63.00	592.0
	Expected count	499.7	92.29	592.0
	% within row	89.36 %	10.64 %	100.00 %
1	Count	294.0	89.00	383.0
	Expected count	323.3	59.71	383.0
	% within row	76.76 %	23.24 %	100.00 %
Total	Count	823.0	152.0	975.0
	Expected count	823.0	152.0	975.0
	% within row	84.41 %	15.59 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	28.04	1	< .001
N	975		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.9329	0.580	1.286	
Fisher's exact test	0.9319	0.565	1.303	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1696
Cramer's V	0.1696

Contingency Tables

Einfluss_Kursalarm		Anlage08_4 („Ich gehe höhere Risiken ein“) 0	1	Total
0	Count	373.0	36.00	409.0
	Expected count	345.8	63.18	409.0
	% within row	91.20 %	8.80 %	100.00 %
1	Count	459.0	116.0	575.0
	Expected count	486.2	88.82	575.0
	% within row	79.83 %	20.17 %	100.00 %
Total	Count	832.0	152.0	984.0
	Expected count	832.0	152.0	984.0
	% within row	84.55 %	15.45 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	23.66	1	< .001
N	984		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.9626	0.564	1.361	
Fisher's exact test	0.9617	0.553	1.390	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1551
Cramer's V	0.1551

Contingency Tables

Einfluss_Swipe		Anlage08_4 („Ich gehe höhere Risiken ein“) 0	1	Total
0	Count	551.0	61.00	612.0
	Expected count	518.5	93.54	612.0
	% within row	90.03 %	9.97 %	100.00 %
1	Count	225.0	79.00	304.0
	Expected count	257.5	46.46	304.0
	% within row	74.01 %	25.99 %	100.00 %
Total	Count	776.0	140.0	916.0
	Expected count	776.0	140.0	916.0
	% within row	84.72 %	15.28 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	40.26	1	< .001
N	916		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	1.154	0.786	1.523	
Fisher's exact test	1.153	0.769	1.540	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2096
Cramer's V	0.2096

Contingency Tables

Einfluss_SocialMedia		Anlage08_4 („Ich gehe höhere Risiken ein“) 0	1	Total
0	Count	611.0	69.00	680.0
	Expected count	577.9	102.1	680.0
	% within row	89.85 %	10.15 %	100.00 %
1	Count	227.0	79.00	306.0
	Expected count	260.1	45.93	306.0
	% within row	74.18 %	25.82 %	100.00 %
Total	Count	838.0	148.0	986.0
	Expected count	838.0	148.0	986.0
	% within row	84.99 %	15.01 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	40.62	1	< .001
N	986		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	1.125	0.768	1.483	
Fisher's exact test	1.124	0.752	1.499	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2030
Cramer's V	0.2030

Contingency Tables

Einfluss_InApp		Anlage08_4 („Ich gehe höhere Risiken ein“) 0	1	Total
0	Count	502.0	54.00	556.0
	Expected count	470.9	85.10	556.0
	% within row	90.29 %	9.71 %	100.00 %
1	Count	328.0	96.00	424.0
	Expected count	359.1	64.90	424.0
	% within row	77.36 %	22.64 %	100.00 %
Total	Count	830.0	150.0	980.0
	Expected count	830.0	150.0	980.0
	% within row	84.69 %	15.31 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	31.02	1	< .001
N	980		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	1.001	0.640	1.362	
Fisher's exact test	0.9999	0.626	1.382	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1779
Cramer's V	0.1779

Contingency Tables

Einfluss_Email		Anlage08_4 („Ich gehe höhere Risiken ein“) 0	1	Total
0	Count	583.0	68.00	651.0
	Expected count	551.2	99.85	651.0
	% within row	89.55 %	10.45 %	100.00 %
1	Count	245.0	82.00	327.0
	Expected count	276.8	50.15	327.0
	% within row	74.92 %	25.08 %	100.00 %
Total	Count	828.0	150.0	978.0
	Expected count	828.0	150.0	978.0
	% within row	84.66 %	15.34 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	35.88	1	< .001
N	978		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	1.054	0.700	1.409	
Fisher's exact test	1.053	0.684	1.425	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1915
Cramer's V	0.1915

Contingency Tables Bereutes Investment

Contingency Tables

Einfluss_Push		Investment_bereut		Total
		0	1	
0	Count	238.0	346.0	584.0
	Expected count	194.9	389.1	584.0
	% within row	40.75 %	59.25 %	100.00 %
1	Count	84.00	297.0	381.0
	Expected count	127.1	253.9	381.0
	% within row	22.05 %	77.95 %	100.00 %
Total	Count	322.0	643.0	965.0
	Expected count	322.0	643.0	965.0
	% within row	33.37 %	66.63 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	36.29	1	< .001
N	965		

Log Odds Ratio

		95% Confidence Intervals		
	Estimate	Lower	Upper	p
Log Odds Ratio	0.8887	0.596	1.182	
Fisher's exact test	0.8878	0.587	1.195	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1939
Cramer's V	0.1939

Contingency Tables

Einfluss_Kursalarm		Investment_bereut 0	1	Total
0	Count	183.0	222.0	405.0
	Expected count	135.0	270.0	405.0
	% within row	45.19 %	54.81 %	100.00 %
1	Count	141.0	426.0	567.0
	Expected count	189.0	378.0	567.0
	% within row	24.87 %	75.13 %	100.00 %
Total	Count	324.0	648.0	972.0
	Expected count	324.0	648.0	972.0
	% within row	33.33 %	66.67 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	43.89	1	< .001
N	972		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.9125	0.639	1.186	
Fisher's exact test	0.9115	0.630	1.195	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2125
Cramer's V	0.2125

Contingency Tables

Einfluss_Swipe		Investment_bereut 0	Investment_bereut 1	Total
0	Count	246.0	360.0	606.0
	Expected count	206.2	399.8	606.0
	% within row	40.59 %	59.41 %	100.00 %
1	Count	63.00	239.0	302.0
	Expected count	102.8	199.2	302.0
	% within row	20.86 %	79.14 %	100.00 %
Total	Count	309.0	599.0	908.0
	Expected count	309.0	599.0	908.0
	% within row	34.03 %	65.97 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	34.96	1	< .001
N	908		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.9526	0.631	1.274	
Fisher's exact test	0.9516	0.622	1.291	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1962
Cramer's V	0.1962

Contingency Tables

Einfluss_SocialMedia		Investment_bereut 0	1	Total
0	Count	264.0	410.0	674.0
	Expected count	228.6	445.4	674.0
	% within row	39.17 %	60.83 %	100.00 %
1	Count	67.00	235.0	302.0
	Expected count	102.4	199.6	302.0
	% within row	22.19 %	77.81 %	100.00 %
Total	Count	331.0	645.0	976.0
	Expected count	331.0	645.0	976.0
	% within row	33.91 %	66.09 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	26.84	1	< .001
N	976		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	0.8147	0.502	1.127	
Fisher's exact test	0.8139	0.493	1.143	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1658
Cramer's V	0.1658

Contingency Tables

Einfluss_InApp		Investment_bereut 0	Investment_bereut 1	Total
0	Count	218.0	333.0	551.0
	Expected count	183.1	367.9	551.0
	% within row	39.56 %	60.44 %	100.00 %
1	Count	104.0	314.0	418.0
	Expected count	138.9	279.1	418.0
	% within row	24.88 %	75.12 %	100.00 %
Total	Count	322.0	647.0	969.0
	Expected count	322.0	647.0	969.0
	% within row	33.23 %	66.77 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	23.10	1	< .001
N	969		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.6814	0.401	0.961	
Fisher's exact test	0.6807	0.393	0.972	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1544
Cramer's V	0.1544

Contingency Tables

Einfluss_Email		Investment_bereut 0	Investment_bereut 1	Total
0	Count	245.0	399.0	644.0
	Expected count	216.2	427.8	644.0
	% within row	38.04 %	61.96 %	100.00 %
1	Count	80.00	244.0	324.0
	Expected count	108.8	215.2	324.0
	% within row	24.69 %	75.31 %	100.00 %
Total	Count	325.0	643.0	968.0
	Expected count	325.0	643.0	968.0
	% within row	33.57 %	66.43 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	17.23	1	< .001
N	968		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.6274	0.329	0.926	
Fisher's exact test	0.6268	0.320	0.940	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1334
Cramer's V	0.1334

Contingency Tables Verlust

Contingency Tables

Einfluss_Push		Finaler_Verlust 0	Finaler_Verlust 1	Total
0	Count	265.0	309.0	574.0
	Expected count	246.4	327.6	574.0
	% within row	46.17 %	53.83 %	100.00 %
1	Count	142.0	232.0	374.0
	Expected count	160.6	213.4	374.0
	% within row	37.97 %	62.03 %	100.00 %
Total	Count	407.0	541.0	948.0
	Expected count	407.0	541.0	948.0
	% within row	42.93 %	57.07 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	6.214	1	.013
N	948		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.3373	0.072	0.603	
Fisher's exact test	0.3369	0.063	0.612	.013

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.08096
Cramer's V	0.08096

Contingency Tables

Einfluss_Kursalarm		Finaler_Verlust 0	Finaler_Verlust 1	Total
0	Count	198.0	199.0	397.0
	Expected count	170.4	226.6	397.0
	% within row	49.87 %	50.13 %	100.00 %
1	Count	212.0	346.0	558.0
	Expected count	239.6	318.4	558.0
	% within row	37.99 %	62.01 %	100.00 %
Total	Count	410.0	545.0	955.0
	Expected count	410.0	545.0	955.0
	% within row	42.93 %	57.07 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	13.37	1	< .001
N	955		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.4848	0.224	0.745	
Fisher's exact test	0.4843	0.215	0.754	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1183
Cramer's V	0.1183

Contingency Tables

Einfluss_Swipe		Finaler_Verlust 0	Finaler_Verlust 1	Total
0	Count	278.0	315.0	593.0
	Expected count	255.9	337.1	593.0
	% within row	46.88 %	53.12 %	100.00 %
1	Count	107.0	192.0	299.0
	Expected count	129.1	169.9	299.0
	% within row	35.79 %	64.21 %	100.00 %
Total	Count	385.0	507.0	892.0
	Expected count	385.0	507.0	892.0
	% within row	43.16 %	56.84 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	9.973	1	.002
N	892		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.4597	0.173	0.746	
Fisher's exact test	0.4592	0.164	0.757	.002

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1057
Cramer's V	0.1057

Contingency Tables

Einfluss_SocialMedia		Finaler_Verlust 0	Finaler_Verlust 1	Total
0	Count	314.0	347.0	661.0
	Expected count	287.0	374.0	661.0
	% within row	47.50 %	52.50 %	100.00 %
1	Count	102.0	195.0	297.0
	Expected count	129.0	168.0	297.0
	% within row	34.34 %	65.66 %	100.00 %
Total	Count	416.0	542.0	958.0
	Expected count	416.0	542.0	958.0
	% within row	43.42 %	56.58 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	14.45	1	< .001
N	958		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.5481	0.264	0.832	
Fisher's exact test	0.5475	0.255	0.844	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.1228
Cramer's V	0.1228

Contingency Tables

Einfluss_InApp		Finaler_Verlust 0	Finaler_Verlust 1	Total
0	Count	235.0	308.0	543.0
	Expected count	232.5	310.5	543.0
	% within row	43.28 %	56.72 %	100.00 %
1	Count	173.0	237.0	410.0
	Expected count	175.5	234.5	410.0
	% within row	42.20 %	57.80 %	100.00 %
Total	Count	408.0	545.0	953.0
	Expected count	408.0	545.0	953.0
	% within row	42.81 %	57.19 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	0.1119	1	.738
N	953		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.04425	-0.215	0.304	
Fisher's exact test	0.04423	-0.223	0.312	.741

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.01084
Cramer's V	0.01084

Contingency Tables

Einfluss_Email		Finaler_Verlust 0	Finaler_Verlust 1	Total
0	Count	276.0	357.0	633.0
	Expected count	271.6	361.4	633.0
	% within row	43.60 %	56.40 %	100.00 %
1	Count	132.0	186.0	318.0
	Expected count	136.4	181.6	318.0
	% within row	41.51 %	58.49 %	100.00 %
Total	Count	408.0	543.0	951.0
	Expected count	408.0	543.0	951.0
	% within row	42.90 %	57.10 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	0.3783	1	.539
N	951		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	0.08561	-0.187	0.358	
Fisher's exact test	0.08551	-0.196	0.368	.579

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.01995
Cramer's V	0.01995

Contingency Tables Aussage App verleitet zum Trading

Contingency Tables

Einfluss_Push		App_verleitet 0	App_verleitet 1	Total
0	Count	325.0	242.0	567.0
	Expected count	249.6	317.4	567.0
	% within row	57.32 %	42.68 %	100.00 %
1	Count	88.00	283.0	371.0
	Expected count	163.4	207.6	371.0
	% within row	23.72 %	76.28 %	100.00 %
Total	Count	413.0	525.0	938.0
	Expected count	413.0	525.0	938.0
	% within row	44.03 %	55.97 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	102.7	1	< .001
N	938		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.463	1.172	1.754	
Fisher's exact test	1.461	1.162	1.767	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.3309
Cramer's V	0.3309

Contingency Tables

Einfluss_Kursalarm		App_verleitet 0	App_verleitet 1	Total
0	Count	240.0	156.0	396.0
	Expected count	173.2	222.8	396.0
	% within row	60.61 %	39.39 %	100.00 %
1	Count	175.0	378.0	553.0
	Expected count	241.8	311.2	553.0
	% within row	31.65 %	68.35 %	100.00 %
Total	Count	415.0	534.0	949.0
	Expected count	415.0	534.0	949.0
	% within row	43.73 %	56.27 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	78.65	1	< .001
N	949		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.201	0.931	1.471	
Fisher's exact test	1.199	0.922	1.480	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.2879
Cramer's V	0.2879

Contingency Tables

Einfluss_Swipe		App_verleitet 0	App_verleitet 1	Total
0	Count	335.0	252.0	587.0
	Expected count	261.3	325.7	587.0
	% within row	57.07 %	42.93 %	100.00 %
1	Count	58.00	238.0	296.0
	Expected count	131.7	164.3	296.0
	% within row	19.59 %	80.41 %	100.00 %
Total	Count	393.0	490.0	883.0
	Expected count	393.0	490.0	883.0
	% within row	44.51 %	55.49 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	111.9	1	< .001
N	883		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.697	1.366	2.027	
Fisher's exact test	1.695	1.356	2.045	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.3560
Cramer's V	0.3560

Contingency Tables

Einfluss_SocialMedia		App_verleitet 0	App_verleitet 1	Total
0	Count	352.0	298.0	650.0
	Expected count	283.9	366.1	650.0
	% within row	54.15 %	45.85 %	100.00 %
1	Count	62.00	236.0	298.0
	Expected count	130.1	167.9	298.0
	% within row	20.81 %	79.19 %	100.00 %
Total	Count	414.0	534.0	948.0
	Expected count	414.0	534.0	948.0
	% within row	43.67 %	56.33 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	92.37	1	< .001
N	948		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.503	1.184	1.823	
Fisher's exact test	1.502	1.174	1.839	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.3122
Cramer's V	0.3122

Contingency Tables

Einfluss_InApp		App_verleitet 0	App_verleitet 1	Total
0	Count	313.0	222.0	535.0
	Expected count	232.4	302.6	535.0
	% within row	58.50 %	41.50 %	100.00 %
1	Count	97.00	312.0	409.0
	Expected count	177.6	231.4	409.0
	% within row	23.72 %	76.28 %	100.00 %
Total	Count	410.0	534.0	944.0
	Expected count	410.0	534.0	944.0
	% within row	43.43 %	56.57 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	114.2	1	< .001
N	944		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.512	1.226	1.797	
Fisher's exact test	1.510	1.217	1.809	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.3478
Cramer's V	0.3478

Contingency Tables

Einfluss_Email		App_verleitet 0	App_verleitet 1	Total
0	Count	348.0	278.0	626.0
	Expected count	275.5	350.5	626.0
	% within row	55.59 %	44.41 %	100.00 %
1	Count	67.00	250.0	317.0
	Expected count	139.5	177.5	317.0
	% within row	21.14 %	78.86 %	100.00 %
Total	Count	415.0	528.0	943.0
	Expected count	415.0	528.0	943.0
	% within row	44.01 %	55.99 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	101.4	1	< .001
N	943		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	95% Confidence Intervals Upper	p
Log Odds Ratio	1.541	1.229	1.854	
Fisher's exact test	1.540	1.220	1.869	< .001

Note. Log odds ratio indicates the following:
(Ratio > 0): Group *0* is more likely in group *0*
(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	0.3279
Cramer's V	0.3279

Contingency Table Push Investments & Altersgruppen

Contingency Tables

z_age_omnibus_18		Nach_Push_investiert 0	Nach_Push_investiert 1	Total
1	Count	29.00	67.00	96.00
	Expected count	60.78	35.22	96.00
	% within row	30.21 %	69.79 %	100.00 %
2	Count	89.00	73.00	162.0
	Expected count	102.6	59.43	162.0
	% within row	54.94 %	45.06 %	100.00 %
3	Count	152.0	75.00	227.0
	Expected count	143.7	83.28	227.0
	% within row	66.96 %	33.04 %	100.00 %
4	Count	139.0	69.00	208.0
	Expected count	131.7	76.31	208.0
	% within row	66.83 %	33.17 %	100.00 %
5	Count	195.0	66.00	261.0
	Expected count	165.2	95.75	261.0
	% within row	74.71 %	25.29 %	100.00 %
Total	Count	604.0	350.0	954.0
	Expected count	604.0	350.0	954.0
	% within row	63.31 %	36.69 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	67.19	4	< .001
N	954		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value
Cramer's V	0.2654

Logistic Regression Tables Diverse Faktoren

Logistic Regression

Model Summary - Spontan_haeufig

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	772.5	774.457	779.220	864			0.000		0.000	
M_1	669.3	687.317	730.182	856	103.140	< .001	0.1335	0.1903	0.1406	0.1124

Note. M_1 includes Anzahl_Einfluss, Finanzwissen_clean, App_Dauer_clean, gender, z_age_omnibus_18

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-1.628	0.092	0.1964	-17.73	314.4	1	< .001	0.164	0.235
M_1	(Intercept)	-2.328	0.539	0.09751	-4.316	18.63	1	< .001	0.034	0.281
	Anzahl_Einfluss	0.357	0.048	1.429	7.366	54.26	1	< .001	1.299	1.571
	Finanzwissen_clean	0.075	0.108	1.078	0.6977	0.4868	1	.485	0.873	1.332
	App_Dauer_clean	0.001	0.123	1.001	0.008702	7.573×10^{-5}	1	.993	0.786	1.275
	gender (2)	-0.121	0.256	0.8861	-0.4717	0.2225	1	.637	0.536	1.465
	z_age_omnibus_18 (2)	-0.380	0.310	0.6838	-1.225	1.501	1	.220	0.372	1.256
	z_age_omnibus_18 (3)	-1.086	0.332	0.3376	-3.270	10.69	1	.001	0.176	0.647
	z_age_omnibus_18 (4)	-0.877	0.353	0.4160	-2.486	6.181	1	.013	0.208	0.831
	z_age_omnibus_18 (5)	-0.618	0.334	0.5389	-1.850	3.422	1	.064	0.280	1.038

Note. Spontan_haeufig level '1' coded as class 1.

Multicollinearity Diagnostics

	Tolerance	VIF
Anzahl_Einfluss	0.8529	1.173
Finanzwissen_clean	0.9157	1.092
App_Dauer_clean	0.8446	1.184
gender	0.9553	1.047
z_age_omnibus_18	0.7869	1.271

Logistic Regression

Model Summary - Investment_bereut

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1101	1103.010	1107.769	861			0.000		0.000	
M_1	1027	1044.732	1087.565	853	74.278	< .001	0.06746	0.1145	0.08160	0.08256

Note. M_1 includes Anzahl_Einfluss, Finanzwissen_clean, App_Dauer_clean, gender, z_age_omnibus_18

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.679	0.072	1.972	9.423	88.79	1	< .001	1.713	2.272
M_1	(Intercept)	1.378	0.521	3.969	2.646	7.002	1	.008	1.430	11.016
	Anzahl_Einfluss	0.229	0.040	1.258	5.803	33.68	1	< .001	1.164	1.359
	Finanzwissen_clean	-0.253	0.103	0.7765	-2.454	6.021	1	.014	0.634	0.950
	App_Dauer_clean	0.258	0.089	1.294	2.885	8.326	1	.004	1.086	1.542
	gender (2)	-0.332	0.185	0.7176	-1.797	3.228	1	.072	0.500	1.031
	z_age_omnibus_18 (2)	-0.713	0.352	0.4901	-2.029	4.116	1	.042	0.246	0.976
	z_age_omnibus_18 (3)	-0.963	0.341	0.3818	-2.823	7.969	1	.005	0.196	0.745
	z_age_omnibus_18 (4)	-0.668	0.351	0.5128	-1.903	3.623	1	.057	0.258	1.020
	z_age_omnibus_18 (5)	-0.979	0.342	0.3756	-2.861	8.185	1	.004	0.192	0.735

Note. Investment_bereut level '1' coded as class 1.

Multicollinearity Diagnostics

	Tolerance	VIF
Anzahl_Einfluss	0.9261	1.080
Finanzwissen_clean	0.8621	1.160
App_Dauer_clean	0.8461	1.182
gender	0.9203	1.087
z_age_omnibus_18	0.8665	1.154

Logistic Regression

Model Summary - Finaler_Verlust

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1164	1166.148	1170.895	850			0.000		0.000	
M_1	1111	1128.654	1171.372	842	53.494	< .001	0.04595	0.08174	0.06214	0.06093

Note. M_1 includes Anzahl_Einfluss, Finanzwissen_clean, App_Dauer_clean, gender, z_age_omnibus_18

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.272	0.069	1.313	3.930	15.45	1	< .001	1.146	1.503
M_1	(Intercept)	0.007	0.441	1.007	0.01611	2.597×10^{-4}	1	.987	0.424	2.390
	Anzahl_Einfluss	0.064	0.035	1.067	1.820	3.312	1	.069	0.995	1.143
	Finanzwissen_clean	-0.066	0.089	0.9365	-0.7338	0.5384	1	.463	0.786	1.116
	App_Dauer_clean	0.415	0.087	1.514	4.773	22.78	1	< .001	1.277	1.795
	gender (2)	-0.515	0.178	0.5974	-2.887	8.337	1	.004	0.421	0.848
	z_age_omnibus_18 (2)	-0.469	0.287	0.6253	-1.635	2.674	1	.102	0.356	1.098
	z_age_omnibus_18 (3)	-0.333	0.282	0.7165	-1.181	1.394	1	.238	0.412	1.246
	z_age_omnibus_18 (4)	-0.756	0.291	0.4697	-2.598	6.748	1	.009	0.266	0.831
	z_age_omnibus_18 (5)	-0.830	0.286	0.4360	-2.905	8.439	1	.004	0.249	0.763

Note. Finaler_Verlust level '1' coded as class 1.

Multicollinearity Diagnostics

	Tolerance	VIF
Anzahl_Einfluss	0.8769	1.140
Finanzwissen_clean	0.8988	1.113
App_Dauer_clean	0.8547	1.170
gender	0.9439	1.059
z_age_omnibus_18	0.8145	1.228

Logistic Regression

Model Summary - App_verleitet

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1157	1158.857	1163.592	840			0.000		0.000	
M_1	942.4	960.372	1002.984	832	214.485	< .001	0.1854	0.3012	0.2280	0.2251

Note. M_1 includes Anzahl_Einfluss, Finanzwissen_clean, App_Dauer_clean, gender, z_age_omnibus_18

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.208	0.069	1.231	2.995	8.968	1	.003	1.074	1.410
M_1	(Intercept)	-1.481	0.501	0.2273	-2.959	8.758	1	.003	0.085	0.606
	Anzahl_Einfluss	0.484	0.045	1.623	10.85	117.8	1	< .001	1.487	1.771
	Finanzwissen_clean	0.278	0.102	1.320	2.709	7.339	1	.007	1.080	1.614
	App_Dauer_clean	-0.096	0.093	0.9089	-1.031	1.064	1	.302	0.758	1.090
	gender (2)	0.039	0.197	1.040	0.1993	0.03971	1	.842	0.706	1.532
	z_age_omnibus_18 (2)	0.255	0.344	1.291	0.7411	0.5492	1	.459	0.657	2.534
	z_age_omnibus_18 (3)	0.121	0.331	1.128	0.3652	0.1333	1	.715	0.590	2.159
	z_age_omnibus_18 (4)	-0.246	0.334	0.7820	-0.7352	0.5405	1	.462	0.406	1.506
	z_age_omnibus_18 (5)	-0.701	0.327	0.4960	-2.143	4.594	1	.032	0.261	0.942

Note. App_verleitet level '1' coded as class 1.

Multicollinearity Diagnostics

	Tolerance	VIF
Anzahl_Einfluss	0.9286	1.077
Finanzwissen_clean	0.8765	1.141
App_Dauer_clean	0.8539	1.171
gender	0.9301	1.075
z_age_omnibus_18	0.8770	1.140

Contingency Tables Einfluss App-Funktionen gruppiert

Contingency Tables

Einfluss_Gruppe		Spontan_haeufig 0	Spontan_haeufig 1	Total
0 Funktionen	Count	222.0	24.00	246.0
	Expected count	205.6	40.43	246.0
	% within row	90.24 %	9.76 %	100.00 %
1-2 Funktionen	Count	260.0	16.00	276.0
	Expected count	230.6	45.37	276.0
	% within row	94.20 %	5.80 %	100.00 %
3-4 Funktionen	Count	130.0	26.00	156.0
	Expected count	130.4	25.64	156.0
	% within row	83.33 %	16.67 %	100.00 %
5-6 Funktionen	Count	115.0	77.00	192.0
	Expected count	160.4	31.56	192.0
	% within row	59.90 %	40.10 %	100.00 %
Total	Count	727.0	143.0	870.0
	Expected count	727.0	143.0	870.0
	% within row	83.56 %	16.44 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	109.0	3	< .001
N	870		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.3540

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Contingency Tables

Einfluss_Gruppe		Investment_bereut 0	Investment_bereut 1	Total
0 Funktionen	Count	120.0	124.0	244.0
	Expected count	82.18	161.8	244.0
	% within row	49.18 %	50.82 %	100.00 %
1-2 Funktionen	Count	95.00	180.0	275.0
	Expected count	92.62	182.4	275.0
	% within row	34.55 %	65.45 %	100.00 %
3-4 Funktionen	Count	43.00	111.0	154.0
	Expected count	51.87	102.1	154.0
	% within row	27.92 %	72.08 %	100.00 %
5-6 Funktionen	Count	34.00	160.0	194.0
	Expected count	65.34	128.7	194.0
	% within row	17.53 %	82.47 %	100.00 %
Total	Count	292.0	575.0	867.0
	Expected count	292.0	575.0	867.0
	% within row	33.68 %	66.32 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	51.29	3	< .001
N	867		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.2432

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Contingency Tables

Einfluss_Gruppe		Finaler_Verlust 0	Finaler_Verlust 1	Total
0 Funktionen	Count	114.0	126.0	240.0
	Expected count	103.3	136.7	240.0
	% within row	47.50 %	52.50 %	100.00 %
1-2 Funktionen	Count	119.0	152.0	271.0
	Expected count	116.6	154.4	271.0
	% within row	43.91 %	56.09 %	100.00 %
3-4 Funktionen	Count	69.00	82.00	151.0
	Expected count	64.99	86.01	151.0
	% within row	45.70 %	54.30 %	100.00 %
5-6 Funktionen	Count	66.00	127.0	193.0
	Expected count	83.07	109.9	193.0
	% within row	34.20 %	65.80 %	100.00 %
Total	Count	368.0	487.0	855.0
	Expected count	368.0	487.0	855.0
	% within row	43.04 %	56.96 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	8.622	3	.035
N	855		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.1004

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Contingency Tables

Einfluss_Gruppe		App_verleitet 0	App_verleitet 1	Total
0 Funktionen	Count	162.0	73.00	235.0
	Expected count	105.4	129.6	235.0
	% within row	68.94 %	31.06 %	100.00 %
1-2 Funktionen	Count	144.0	123.0	267.0
	Expected count	119.7	147.3	267.0
	% within row	53.93 %	46.07 %	100.00 %
3-4 Funktionen	Count	52.00	101.0	153.0
	Expected count	68.60	84.40	153.0
	% within row	33.99 %	66.01 %	100.00 %
5-6 Funktionen	Count	20.00	168.0	188.0
	Expected count	84.30	103.7	188.0
	% within row	10.64 %	89.36 %	100.00 %
Total	Count	378.0	465.0	843.0
	Expected count	378.0	465.0	843.0
	% within row	44.84 %	55.16 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	160.3	3	< .001
N	843		

Note. Continuity correction is available only for 2x2 tables.

Nominal

	Value[a]
Phi-coefficient	NaN
Cramer's V	0.4361

[a] Phi coefficient is only available for 2 by 2 contingency Tables

Generalized Linear Model Verlusthöhe

Model Summary - Verlusthoehe_clean

Model	Deviance	AIC	BIC	df	X^2	p
H_0	1064	1070	1083	1383		
H_1	966.9	988.9	1034	1375	97.21	< .001

Coefficients

	Estimate	Standard Error	z	p
(Intercept) ⁎ 1	2.837	0.5315	5.339	< .001
(Intercept) ⁎ 2	4.748	0.5638	8.422	< .001
(Intercept) ⁎ 3	6.974	0.6305	11.06	< .001
gender2	0.3345	0.2555	1.309	.190
z_age_omnibus_182	0.3340	0.3352	0.9964	.319
z_age_omnibus_183	0.4646	0.3189	1.457	.145
z_age_omnibus_184	-0.3961	0.3437	-1.152	.249
z_age_omnibus_185	-0.1422	0.3402	-0.4181	.676
Anzahl_Einfluss	-0.2514	0.04512	-5.573	< .001
Finanzwissen_clean	-0.2377	0.1021	-2.329	.020
App_Dauer_clean	-0.6807	0.1155	-5.892	< .001

Note. Verlusthoehe_clean levels: 1:1, 1:2, 1:3, 1:4. Linear predictors: logitlink(P[Y<=1]), logitlink(P[Y<=2]), logitlink(P[Y<=3]).

Generalized Linear Model Portfolioentwicklung

Model Summary - Portfolioentwicklung_clean

Model	Deviance	AIC	BIC	df	X^2	p
H_0	2453	2465	2493	4896		
H_1	2390	2418	2484	4888	62.44	< .001

Coefficients

	Estimate	Standard Error	z	p
(Intercept) ⁎ 1	-2.859	0.4017	-7.117	< .001
(Intercept) ⁎ 2	-0.6270	0.3903	-1.607	.108
(Intercept) ⁎ 3	0.5964	0.3906	1.527	.127
(Intercept) ⁎ 4	1.320	0.3960	3.332	< .001
(Intercept) ⁎ 5	1.854	0.4051	4.576	< .001
(Intercept) ⁎ 6	3.025	0.4553	6.645	< .001
gender2	-0.02735	0.1622	-0.1686	.866
z_age_omnibus_182	0.4369	0.2521	1.733	.083
z_age_omnibus_183	0.5043	0.2467	2.044	.041
z_age_omnibus_184	0.2421	0.2564	0.9442	.345
z_age_omnibus_185	0.1981	0.2525	0.7846	.433
Anzahl_Einfluss	-0.1703	0.03248	-5.244	< .001
Finanzwissen_clean	0.1630	0.07875	2.070	.038
App_Dauer_clean	0.2287	0.07721	2.963	.003

Note. Portfolioentwicklung_clean levels: 1:1, 1:2, 1:3, 1:4, 1:5, 1:6, 1:7. Linear predictors: logitlink(P[Y<=1]), logitlink(P[Y<=2]), logitlink(P[Y<=3]), logitlink(P[Y<=4]), logitlink(P[Y<=5]), logitlink(P[Y<=6]).

Logistic Regression Table Portfolioentwicklung

Logistic Regression

Model Summary - Portfolio_negativ

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	501.1	503.117	507.822	816			0.000		0.000	
M_1	473.5	491.518	533.869	808	27.599	< .001	0.05507	0.07245	0.03694	0.03322

Note. M_1 includes Anzahl_Einfluss, Finanzwissen_clean, App_Dauer_clean, gender, z_age_omnibus_18

Coefficients

									95% Confidence interval (odds ratio scale)	
						Wald Test				
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	-2.292	0.121	0.1011	-18.92	357.8	1	< .001	0.080	0.128
M_1	(Intercept)	-3.058	0.722	0.04699	-4.237	17.95	1	< .001	0.011	0.193
	Anzahl_Einfluss	0.167	0.061	1.182	2.743	7.526	1	.006	1.049	1.331
	Finanzwissen_clean	0.277	0.148	1.320	1.875	3.516	1	.061	0.988	1.764
	App_Dauer_clean	-0.107	0.149	0.8989	-0.7166	0.5136	1	.474	0.672	1.203
	gender (2)	-0.164	0.330	0.8484	-0.4975	0.2475	1	.619	0.444	1.621
	z_age_omnibus_18 (2)	-0.625	0.414	0.5351	-1.510	2.280	1	.131	0.238	1.205
	z_age_omnibus_18 (3)	-1.364	0.474	0.2556	-2.879	8.291	1	.004	0.101	0.647
	z_age_omnibus_18 (4)	-0.346	0.419	0.7073	-0.8258	0.6819	1	.409	0.311	1.609
	z_age_omnibus_18 (5)	-0.177	0.407	0.8376	-0.4357	0.1899	1	.663	0.377	1.859

Note. Portfolio_negativ level '1' coded as class 1.

Multicollinearity Diagnostics

	Tolerance	VIF
Anzahl_Einfluss	0.8054	1.242
Finanzwissen_clean	0.9118	1.097
App_Dauer_clean	0.8548	1.170
gender	0.9579	1.044
z_age_omnibus_18	0.7494	1.334

Contingency Table Portfolio & Verluste

Portfolio_positiv		Finaler_Verlust 0	1	Total
0	Count	54.00	96.00	150.0
	Expected count	64.75	85.25	150.0
	% within row	36.00 %	64.00 %	100.00 %
1	Count	347.0	432.0	779.0
	Expected count	336.3	442.7	779.0
	% within row	44.54 %	55.46 %	100.00 %
Total	Count	401.0	528.0	929.0
	Expected count	401.0	528.0	929.0
	% within row	43.16 %	56.84 %	100.00 %

Chi-Squared Tests

	Value	df	p
X^2	3.743	1	.053
N	929		

Log Odds Ratio

	Estimate	95% Confidence Intervals Lower	Upper	p
Log Odds Ratio	-0.3563	-0.718	0.006	
Fisher's exact test	-0.3559	-0.739	0.019	.059

Note. Log odds ratio indicates the following:

(Ratio > 0): Group *0* is more likely in group *0*

(Ratio < 0): Group *0* is less likely in group *0*

Nominal

	Value
Phi-coefficient	-0.06347
Cramer's V	0.06347

Logistic Regression Table Mehrfaktorenmodell Finaler Verlust

Model Summary - Finaler_Verlust

Model	Deviance	AIC	BIC	df	ΔX²	p	McFadden R²	Nagelkerke R²	Tjur R²	Cox & Snell R²
M_0	1069	1070.794	1075.452	778			0.000		0.000	
M_1	941.0	977.026	1060.871	761	127.768	< .001	0.1195	0.2027	0.1506	0.1513

Note. M_1 includes gender, z_age_omnibus_18, Trading_haeufig, Ohne_Verstaendnis, bank_savings_5, bank_savings_16, Anzahl_Einfluss, Finanzwissen_gruppiert, hinc_yks

Coefficients

						Wald Test			95% Confidence interval (odds ratio scale)	
Model		Estimate	Standard Error	Odds Ratio	z	Wald Statistic	df	p	Lower bound	Upper bound
M_0	(Intercept)	0.240	0.072	1.271	3.324	11.05	1	< .001	1.103	1.464
M_1	(Intercept)	0.281	0.632	1.324	0.4444	0.1975	1	.657	0.383	4.574
	gender (2)	-0.545	0.201	0.5796	-2.718	7.386	1	.007	0.391	0.859
	z_age_omnibus_18 (2)	-0.134	0.330	0.8748	-0.4050	0.1640	1	.686	0.458	1.671
	z_age_omnibus_18 (3)	0.234	0.328	1.264	0.7151	0.5114	1	.475	0.665	2.403
	z_age_omnibus_18 (4)	-0.067	0.337	0.9356	-0.1975	0.03899	1	.843	0.483	1.811
	z_age_omnibus_18 (5)	-0.010	0.326	0.9897	-0.03179	0.001011	1	.975	0.523	1.874
	Trading_haeufig (1)	0.647	0.194	1.909	3.332	11.10	1	< .001	1.305	2.792
	Ohne_Verstaendnis (1)	0.938	0.181	2.555	5.171	26.74	1	< .001	1.791	3.646
	bank_savings_5 (1)	1.067	0.346	2.906	3.085	9.519	1	.002	1.476	5.724
	bank_savings_16 (1)	0.493	0.166	1.638	2.970	8.822	1	.003	1.183	2.268
	Anzahl_Einfluss	-0.024	0.041	0.9759	-0.5940	0.3529	1	.552	0.901	1.058
	Finanzwissen_gruppiert (2)	-1.180	0.533	0.3074	-2.214	4.900	1	.027	0.108	0.874
	Finanzwissen_gruppiert (3)	-0.860	0.524	0.4230	-1.643	2.700	1	.100	0.152	1.180
	Finanzwissen_gruppiert (4)	-0.718	0.545	0.4878	-1.317	1.733	1	.188	0.168	1.420
	hinc_yks (2)	0.025	0.349	1.025	0.07199	0.005182	1	.943	0.517	2.034
	hinc_yks (3)	-0.097	0.348	0.9073	-0.2800	0.07842	1	.779	0.459	1.793
	hinc_yks (4)	-0.311	0.345	0.7325	-0.9015	0.8127	1	.367	0.372	1.441
	hinc_yks (5)	-0.130	0.331	0.8783	-0.3926	0.1541	1	.695	0.459	1.679

Note. Finaler_Verlust level '1' coded as class 1.

Multicollinearity Diagnostics

	Tolerance	VIF
gender	0.9220	1.085
z_age_omnibus_18	0.7565	1.322
Trading_haeufig	0.8108	1.233
Ohne_Verstaendnis	0.8610	1.161
bank_savings_5	0.9105	1.098
bank_savings_16	0.9563	1.046
Anzahl_Einfluss	0.7935	1.260
Finanzwissen_gruppiert	0.7604	1.315
hinc_yks	0.8443	1.184