

Mensch oder Maschine? Wo Künstliche Intelligenz in der Vermögensanlage Mehrwert liefert und wo menschliches Verhalten überlegen bleibt

Allokation und Titelselektion bei privaten und professionellen Anlegern

Roland Rupprechter¹

September 2026

Abstract

Diese Studie analysiert die komparativen Vorteile Künstlicher Intelligenz (KI) gegenüber dem menschlichen Urteilsvermögen innerhalb des Anlageprozesses. Dabei wird differenziert zwischen dem Privatanleger, dessen Entscheidungsgrundlage primär auf selbst erworbenem Wissen basiert, und dem professionellen Asset-Manager mit institutionellem Mandat und Rechenschaftspflicht. Im Fokus stehen Allokationsentscheidungen sowie die Titelselektion für Staats- und Unternehmensanleihen, global gestreute Aktienanlagen, Aktienfonds und ETFs. Die Analyse stützt sich auf verhaltensökonomische Evidenz und die empirische Bilanz realer KI-Anwendungen.

Menschen – sowohl private als auch professionelle Anleger – unterliegen systematischen Verhaltensfehlern wie Ungeduld, mangelnder Strategietreue sowie prozyklischem Handelsverhalten; die daraus resultierende Renditelücke beträgt in den Vereinigten Staaten über einen Zehnjahreszeitraum durchschnittlich 1,2 Prozentpunkte jährlich. Maschinelle Systeme generieren einen belegbaren Mehrwert in datenintensiven, repetitiven und regelbasierten Aufgabenbereichen – insbesondere bei der Textanalyse, dem Anleihen-Ranking, dem Rebalancing sowie der Handelsausführung. Im Gegensatz dazu blieben KI-gesteuerte Fonds langfristig hinter ihren Vergleichsindizes zurück, und generative Sprachmodelle weisen ohne Validierung zu faktischen Fehlern (Halluzinationen) tendierende Ergebnisse auf.

¹Roland Rupprechter, Economic Research, R&B Wealth Management, Kreuzgasse 1a, 6850 Dornbirn; Member Austrian Association for Financial Analysis and Asset Management. Email: roland.rupprechter@rbvm.at.
Erklärung zum Einsatz von KI-Tools: Diese Arbeit entstand unter punktuelltem Einsatz der KI Claude (Anthropic). Der Text stammt vom Autor. Weiters wurden vom Autor inhaltliche Kernleistungen – darunter die Forschungsfrage, das Ziel, die Methodik, die Datenanalyse, sämtliche Berechnungen sowie das Fachwissen und das Layout – komplett eigenständig erbracht. Claude diente unter Anleitung als Assistenzwerkzeug zur Unterstützung bei der Textkürzung und zur Überprüfung von Herleitungen sowie zum Abgleich von Quellen. Wenige KI-generierte Textpassagen wurden vom Autor intensiv geprüft und erst nach Erreichen der inhaltlichen Ziele integriert. Zuletzt wurde das System für das Lektorat (Rechtschreibung und akademischer Stil) genutzt. Der Autor trägt die alleinige Verantwortung für den Inhalt der Arbeit.

Die Arbeit mündet in Handlungsempfehlungen für beide Anlegertypen: Die KI ersetzt nicht den Anleger, sondern substituiert dessen suboptimales Verhalten; die Definition von Zielen, die Bestimmung der Risikotragfähigkeit sowie die finale Verantwortung verbleiben in menschlicher Hand.

Schlüsselwörter: Künstliche Intelligenz · Maschinelles Lernen · Behavioral Finance · Asset Allocation · Titelselektion · Robo-Advisor · Anlageberatung

JEL Klassifizierung: C45, D91, G11, G23, G41, G53, O33

Nicht-technische Zusammenfassung

Die Künstliche Intelligenz (KI) hat die Erwartungshaltungen innerhalb der Vermögensverwaltung grundlegend transformiert. Durch die Fähigkeit, massive Datenmengen in Echtzeit zu prozessieren, Muster in Kursverläufen zu identifizieren und komplexe Berichte effizient zu analysieren, stellt sich die zentrale Frage nach der tatsächlichen Überlegenheit der Maschine gegenüber dem menschlichen Urteil.

Die Untersuchung betrachtet zwei Anlegertypen: den Privatanleger mit autodidaktischen Kenntnissen und den professionellen Vermögensverwalter, der fremdes Kapital innerhalb eines strukturierten Prozesses administriert. Die Forschung belegt, dass beide Typen zu systematischen Fehlern neigen: Ungeduld, mangelnde Disziplin bei der Strategieumsetzung sowie ein tendenziell prozyklisches Timing führen zu signifikanten Renditeeinbußen. Für Fondsanleger in den Vereinigten Staaten resultiert daraus eine jährliche Renditelücke von etwa 1,2 Prozentpunkten über zehn Jahre.

Demgegenüber steht die Effizienz maschineller Systeme bei datenreichen, regelhaften Aufgaben: Robo-Advisor optimieren die Allokation durch Indexfonds und sichern die Balance; lernende Systeme evaluieren Nachrichten und Bilanzen. Die empirische Prüfung zeigt jedoch ein differenziertes Bild: Während KI-gestützte Analysewerkzeuge oft präzisere Vorhersagen liefern als menschliche Analysten, blieben viele KI-Fonds hinter dem Markt zurück. Zudem können starre Risikomodelle in extremen Marktsituationen zu suboptimalen Verkaufsentscheidungen führen.

Zusammenfassend lässt sich festhalten: Die KI ist in der Verarbeitung, Sortierung und Ausführung komplexer Datenmengen überlegen. Der Mensch bleibt unverzichtbar bei der Zielsetzung, der Bewertung der individuellen Risikotragfähigkeit, dem Umgang mit beispiellosen Marktsituationen sowie der Übernahme von Verantwortung. Die optimalen Ergebnisse werden durch eine synergetische Kombination erzielt. Für Privatanleger bedeutet dies: Strategien schriftlich fixieren, die Umsetzung automatisieren und die KI als Wissenswerkzeug nutzen, ohne blind auf Zahlen zu vertrauen. Für professionelle Vermögensverwalter bedeutet es: die KI als analytischen Partner in datenintensiven Bereichen einzusetzen, die finale Entscheidung bei Strategiewechseln jedoch menschlich zu steuern.

Inhalt

Nicht-technische Zusammenfassung	3
1 Einleitung	6
2.1 Differenzierung: Der Privatanleger und der professionelle Anleger	7
2.2 Informationsquellen und Aufmerksamkeitssteuerung	8
2.3 Kognitive Architektur: Rationalität versus Emotion	9
2.4 Vom Research zur Allokation: Der Prozess der Verdichtung.....	10
2.5 Titelselektion: Anleihen und globale Aktienanlagen.....	11
2.6 Die zeitliche Dimension des Depots.....	12
3 Systematische Schwächen menschlichen Anlageverhaltens	13
3.1 Ungeduld und mangelnde Strategietreue.....	13
3.2 Prozyklisches Verhalten: Kauf im Hoch, Verkauf im Tief.....	13
3.3 Modetrends und Herdenverhalten	14
3.4 Überkonfidenz, Dispositionseffekt und Verlustaversion.....	15
3.5 Komparative Analyse: Professioneller Anleger vs. Privatanleger	15
3.6 Strategien zur Optimierung menschlicher Entscheidungen	16
4 Die Implementierung Künstlicher Intelligenz in Allokation und Titelselektion	16
4.1 Taxonomie der Automatisierungsstufen	16
4.2 Datenanalyse und Sentiment-Messung	17
4.3 Maschinelle Allokationsbildung: Vom Optimierer zum Robo-Advisor	18
4.4 Maschinelle Titelselektion: Anleihen und Aktien	19
4.5 Algorithmischer Handel und Signalgeber	20
4.6 Interaktive Beratung und generative KI	20
4.7 Synthese der KI-Anwendungen	20
5 Empirische Bilanz: Erfolge und Fehlschläge der KI.....	22
5.1 Nachgewiesene Mehrwerte.....	22
5.2 Dokumentierte Versagen	22
5.3 Synthese: Komparative Vorteile von Mensch und Maschine.....	23
6 Grenzen und Risiken der Künstlichen Intelligenz in der Vermögensanlage	24
7 Handlungsempfehlungen zur nutzbringenden Integration von KI.....	25
7.1 Empfehlungen für den Privatanleger.....	25
7.2 Empfehlungen für den professionellen Anleger.....	27
7.3 Bereiche für die vollständige Automatisierung.....	28
7.4 Die Transformation der Anlageberatung.....	28
8 Fazit und Ausblick	29
Literaturverzeichnis	31

1 Einleitung

Die Vermögensanlage konstituiert sich als Prozess der Informationsverarbeitung, bei dem aus Kursdaten, Bilanzen, Nachrichten und Erwartungen die Allokation des Vermögens auf Anlageklassen sowie die Selektion einzelner Titel abgeleitet wird. An dieser Schnittstelle setzt die Künstliche Intelligenz (KI) an. Sie verspricht, Informationsmengen in einem Umfang und einer Geschwindigkeit zu verarbeiten, die menschliche Möglichkeiten bei weitem übersteigen, und dies ohne die durch Ermüdung, Angst oder Gier bedingten kognitiven Verzerrungen.

Dieses Versprechen ist insbesondere vor dem Hintergrund der verhaltensökonomischen Forschung von hoher Relevanz. Über vier Jahrzehnte wurde belegt, dass Anleger systematische Fehler begehen: ein übermäßiges Handelsvolumen (Odean 1999; Barber und Odean 2000), die tendenziell zu frühe Realisierung von Gewinnen bei gleichzeitigem Festhalten an Verlustpositionen (Shefrin und Statman 1985; Odean 1998), eine ausgeprägte Überkonfidenz (Barber und Odean 2001) sowie die lineare Extrapolation der jüngsten Vergangenheit in die Zukunft (Greenwood und Shleifer 2014). Die Vorstellung, eine rationale Maschine könne diese psychologischen Schwachstellen eliminieren, ist folglich plausibel.²

Gleichwohl mahnt die Kapitalmarkttheorie zur Vorsicht. Sofern Informationen frei verfügbar und Rechenleistungen kostengünstig sind, können nicht alle Marktteilnehmer durch den Einsatz identischer Verfahren eine Überrendite erzielen (Grossman und Stiglitz 1980; Sharpe 1991). Ein ubiquitärer Vorteil ist definitionsgemäß kein Wettbewerbsvorteil. Die zentrale Fragestellung dieser Arbeit ist daher nicht die allgemeine Überlegenheit der KI gegenüber dem Menschen, sondern die Identifikation spezifischer Bereiche des Anlageprozesses, in denen die Maschine einen nachweisbaren Mehrwert generiert, während das menschliche Urteilsvermögen in anderen Bereichen überlegen bleibt. Dabei wird differenziert zwischen dem Privatanleger mit autodidaktischen Kenntnissen und dem professionellen Vermögensverwalter, der innerhalb eines institutionellen Rahmens agiert.

Die Untersuchung erfolgt in drei Schritten. Zunächst wird analysiert, wie Menschen zu Anlageentscheidungen gelangen – unter Berücksichtigung rationaler und emotionaler Faktoren sowie der Rolle von Finanzmedien und sozialen Medien – und wie aus diesem Research Allokationen und Titelselektionen resultieren. In einem zweiten Schritt wird die technologische Entsprechung analysiert: die Bildung von Allokationen und die Titelselektion durch KI, belegt an realen Anwendungen wie digitalen Vermögensverwaltern, KI-gesteuerten Fonds und generativen Sprachmodellen.

² Der Begriff Künstliche Intelligenz wird in dieser Arbeit als Sammelbegriff für regelbasierte Automatisierung, maschinelles Lernen und generative Sprachmodelle verwendet; Abschnitt 4.1 grenzt die drei Stufen voneinander ab.

Abschließend wird eine empirische Bilanz gezogen, um Erfolge und Fehlschläge zu evaluieren und daraus Ableitungen für beide Anlegertypen zu treffen.

Im Zentrum der Analyse steht die Allokationsentscheidung, da diese den maßgeblichen Teil der Ergebnisschwankung eines Portfolios determiniert (Brinson et al. 1986; Ibbotson und Kaplan 2000). Bei der Titelselektion beschränkt sich die Betrachtung auf Staatsanleihen, Unternehmensanleihen und global gestreute Aktienanlagen; Einzeltitel unter einer Streuung von zwanzig Positionen werden zugunsten von globalen Aktienfonds und ETFs ausgeklammert. Diese Eingrenzung entspricht dem relevanten Anlageuniversum für den langfristigen Vermögensaufbau und vermeidet anekdotische Evidenz durch spektakuläre Einzeltitelgeschäfte.

Die Arbeit integriert verschiedene Forschungsströme: die Verhaltensökonomik (Kahneman und Tversky 1979 bis Kahneman 2011), die Messung der Anlegerrenditelücke (Friesen und Sapp 2007; Morningstar 2025b), die Debatte über klinische versus statistische Prognosen (Meehl 1954; Kahneman und Klein 2009), die Literatur zum maschinellen Lernen in der Finanzwirtschaft (Gu et al. 2020; Kelly und Xiu 2023) sowie die empirische Forschung zu digitalen Vermögensverwaltern (D'Acunto et al. 2019; Reher und Sokolinski 2024).³

Der Beitrag dieser Untersuchung besteht in der Synthese dieser Ansätze und deren Überprüfung an realen Anwendungen. Sie ist eingebettet in eine Working-Paper-Reihe des Autors, in der zuvor die Investition in KI (Rupprechter 2026a) sowie die transparente Beantwortung von Allokationsfragen mittels Markowitz- und Black-Litterman-Verfahren (Rupprechter 2026b) behandelt wurden. Die vorliegende Arbeit verschiebt den Fokus: Nicht die Investition in die KI steht im Zentrum, sondern die Investition mittels KI.

Die Arbeit ist wie folgt aufgebaut: Kapitel 1 dient als Einleitung, formuliert die Forschungsfrage und gibt einen Überblick über die bisherige Literatur. In Kapitel 2 werden die Entscheidungsprozesse von unerfahrenen und professionellen Anlegern analysiert. In Kapitel 3 werden die Schwächen des menschlichen Anlageverhaltens beleuchtet. In Kapitel 4 wird beschrieben, wie die KI zu einer Portfolioallokation und Titelauswahl gelangt. In Kapitel 5 wird eine empirische Bilanz aus Erfolgen und Misserfolgen gezogen. In Kapitel 6 werden Grenzen und Risiken erörtert. Kapitel 7 formuliert Empfehlungen für beide Anlegertypen. Schließlich fasst Kapitel 8 die Ergebnisse zusammen und gibt einen Ausblick.

2.1 Differenzierung: Der Privatanleger und der professionelle Anleger

Unter dem Begriff des Privatanlegers wird in dieser Untersuchung ein Anleger verstanden, der über fundierte, jedoch autodidaktisch erworbene Kenntnisse und Erfahrungen verfügt. Er verwaltet eigenes Kapital ohne institutionelle Bindung, schuldet niemandem Rechenschaft und agiert ohne schriftliches Mandat oder Anlageausschuss. Die Bezeichnung

³ Einen Überblick über den Stand des maschinellen Lernens in der Vermögensverwaltung aus Sicht der Praxis geben Bartram et al. (2020); die aufsichtliche Sicht fassen OECD (2021) und IMF (2024) zusammen.

„Privat“ referiert hierbei nicht auf einen Mangel an Wissen, sondern auf die Abwesenheit eines formalisierten, institutionellen Entscheidungsprozesses. In der Literatur zur Haushaltsfinanzliteratur entspricht dies dem aktiven, selbstbestimmten Privatanleger (Gomes et al. 2021).

Der professionelle Anleger hingegen ist als Asset- oder Fondsmanager definiert, der fremdes Kapital auf Basis eines Mandats verwaltet, welches Ziele, Restriktionen und Benchmarks festlegt. Sein Handeln ist in einen Prozess eingebettet, der Research, Risikomanagement und eine systematische Berichterstattung umfasst. Während seine Informationsquellen – von Datenterminals bis zu Unternehmensbesuchen – breiter gefächert sind, unterliegt er spezifischen institutionellen Anreizen: Karriererisiken (Chevalier und Ellison 1999), mittelflussabhängige Performance-Bewertungen (Berk und Green 2004) sowie der Druck zur Konformität mit dem Marktkonsens (Scharfstein und Stein 1990).⁴

Beide Typen teilen die fundamentale Eigenschaft menschlicher Kognition. Die Verhaltensforschung belegt, dass weder Ausbildung noch Erfahrung alle kognitiven Verzerrungen eliminieren. Professionelle Anleger weisen ebenfalls den Dispositionseffekt (Frazzini 2006), Überkonfidenz (Puetz und Ruenzi 2011) und Herdenverhalten (Wermers 1999)⁵ auf. Aktuelle Daten bestätigen zudem, dass institutionelle Portfoliomanager systematisch suboptimalere Verkaufsentscheidungen treffen als Kaufentscheidungen (Akepanidaworn et al. 2023). Der entscheidende Unterschied liegt daher weniger in der Fehlerfreiheit als in der Implementierung von Prozessvorkehrungen zur Fehlerminimierung.

2.2 Informationsquellen und Aufmerksamkeitssteuerung

Anlageentscheidungen werden häufig durch externe Reize initiiert. Beim Privatanleger erfolgt dies selten systematisch, sondern oft reaktiv auf Schlagzeilen, soziale Medien oder kurzfristige Kursbewegungen. Barber und Odean (2008) zeigen, dass Privatanleger eine Präferenz für Titel mit hoher Aufmerksamkeit aufweisen – insbesondere solche mit extremen Tagesrenditen oder hohem Handelsvolumen. Da et al. (2011) bestätigen diesen Mechanismus anhand von Internet-Suchanfragen. Aufmerksamkeit fungiert hier als Filter, der jedoch nicht auf die erwartete Rendite, sondern auf die Auffälligkeit des Titels optimiert ist.

Finanzmedien üben einen messbaren Einfluss auf die Kursentwicklung und das Anlegerverhalten aus. Tetlock (2007) belegt, dass eine pessimistische Tonalität in der Wirtschaftspresse kurzfristig druckend wirkt; Engelberg und Parsons (2011) weisen nach, dass lokale Berichterstattung das Handelsvolumen kausal steigert. Besonders wirksam sind

⁴ Der Begriff „professioneller Anleger“ wird hier funktional verwendet und ist weiter als die aufsichtsrechtliche Kundenkategorie der MiFID II; gemeint ist, wer beruflich fremdes Vermögen nach einem Mandat verwaltet.

⁵ Wermers (1999) misst Herdenverhalten als Gleichlauf der Handelsrichtung vieler Fonds im selben Titel und Quartal, bereinigt um den Zufall; bei kleinen Titeln und Wachstumsfonds ist das Maß am höchsten.

Ranglisten: Kaniel und Parham (2017) zeigen, dass die Erwähnung eines Fonds in einer Rangliste des Wall Street Journal zu erheblichen Zuflüssen führt, ohne dass dies mit einer verbesserten künftigen Performance korreliert. Medien lenken somit Kapital durch die Steuerung von Aufmerksamkeit.⁶

Soziale Medien haben diese Dynamik beschleunigt. Barber et al. (2022) belegen anhand von Robinhood-Nutzern, dass aufmerksamkeitsgetriebene Herdenepisoden zu negativen Folgerenditen führen; Cookson et al. (2023) identifizieren Bestätigungsfehler (Confirmation Bias) in Finanzforen. Besonders kritisch ist die Rolle von „Finfluencern“: Kakhbod et al. (2023) stellen fest, dass ein Großteil dieser Akteure keine wertvollen Hinweise liefert, sondern ihre Empfehlungen systematisch schlechter als der Zufall sind, während sie dennoch Anhänger gewinnen, da sie bestehende Vorurteile bestätigen.

Auch die persönliche Beratung garantiert keine Fehlerfreiheit. Bhattacharya et al. (2012) zeigen, dass die Inanspruchnahme professioneller Beratung oft korrelativ mit einem Mangel an Notwendigkeit einhergeht; Foerster et al. (2017) belegen, dass Portfolios von Beratungskunden oft stärker von den Präferenzen des Beraters als von den Bedürfnissen des Kunden geprägt sind. Linnainmaa et al. (2021) weisen nach, dass Berater in ihren eigenen Depots dieselben Fehler begehen, die sie Kunden empfehlen. Gennaioli et al. (2015) führen den Erfolg der Beratung primär auf das Vertrauensverhältnis zurück, welches Anleger dazu bewegt, überhaupt zu investieren.

Der professionelle Anleger nutzt zwar andere Quellen, ist jedoch ebenfalls anfällig für Verzerrungen. Sell-Side-Research folgt oft eigenen Interessen, und die Beratung durch externe Berater liefert nach Jenkinson et al. (2016) keinen messbaren Mehrwert. Hong et al. (2005) zeigen zudem, dass lokale Netzwerke unter Fondsmanagern zu einer Homogenisierung der Portfolios führen. Der Vorteil des Profis liegt somit nicht in der Reinheit der Informationen, sondern in der Einbettung der Informationsverarbeitung in einen kontrollierten Prozess.⁷

2.3 Kognitive Architektur: Rationalität versus Emotion

Die Dichotomie zwischen rationalen und emotionalen Entscheidungen ist theoretisch unzureichend. Simon (1955) führte das Konzept der begrenzten Rationalität (Bounded Rationality) ein: Menschen optimieren nicht, sondern suchen nach einer befriedigenden Lösung (Satisficing), da Zeit, Information und Rechenkapazität limitiert sind. Tversky und Kahneman (1974) zeigten, dass dieser Prozess auf Heuristiken (Verfügbarkeit, Repräsentativität, Verankerung) basiert, die zwar effizient sind, jedoch systematische Fehler induzieren. Kahneman (2011) differenzierte dies in System 1 (schnell, intuitiv,

⁶ Der Autor hat selbst über viele Jahre in Zeitungsbeiträgen und Telefonaktionen Anlegerfragen beantwortet; die Erfahrung deckt sich mit der Empirie: Gefragt wird nach dem, was gerade in den Schlagzeilen steht.

⁷ Sell-Side-Research ist Research, das Wertpapierhäuser für ihre Kunden erstellen; es finanziert sich über Handelsaufträge und Emissionsgeschäft und ist deshalb strukturell zu Kaufempfehlungen geneigt.

assoziativ) und System 2 (langsam, analytisch, regelgeleitet). Während Anlageentscheidungen des Privatanlegers primär durch System 1 gesteuert werden, versucht der institutionelle Anlageprozess, System 2 zu operationalisieren.

Die Verlässlichkeit intuitiver Expertise ist in der Geldanlage fragwürdig. Kahneman und Klein (2009) belegen, dass Intuition nur in Umgebungen mit hoher Regularität und unmittelbarem Feedback funktioniert – nicht jedoch an Kapitalmärkten, wo Rückmeldungen verzögert und verrauscht sind. In solchen Umgebungen führt Erfahrung oft zu einer Fehlwahrnehmung der eigenen Kompetenz.

Demgegenüber betonen Gigerenzer und Brighton (2009), dass einfache Faustregeln in unsicheren Umgebungen komplexe Optimierungen schlagen können. DeMiguel et al. (2009) bestätigen dies für die Portfoliotheorie: Die naive Gleichgewichtung ($1/N$) ist außerhalb der Stichprobe oft überlegen, da Optimierungsverfahren die Fehler ihrer Eingabedaten verstärken (Michaud 1989). Emotionen und Heuristiken sind somit nicht per se irrational, sondern an spezifische Kontextbedingungen gebunden.⁸

Der professionelle Prozess reduziert zwar Fehler des intuitiven Denkens, führt aber zu neuen Verzerrungen. Kahneman et al. (2021) beschreiben dies als „Rauschen“ (Noise): Experten kommen bei identischen Fakten zu unterschiedlichen Urteilen. Zudem führen institutionelle Anreize dazu, dass Manager eher mit dem Konsens falsch liegen als allein richtig (Scharfstein und Stein 1990; Chevalier und Ellison 1999).

2.4 Vom Research zur Allokation: Der Prozess der Verdichtung

Die Allokation determiniert den wesentlichen Teil der Ergebnisschwankungen eines Portfolios (Brinson et al. 1986; Ibbotson und Kaplan 2000). Die Herleitung dieser Entscheidung unterscheidet sich fundamental zwischen den Anlegertypen.

Der Privatanleger agiert oft additiv statt synthetisch. Sein Depot ist das Resultat punktueller Entscheidungen, die zu verschiedenen Zeiten aus diversen Anlässen getroffen wurden. Benartzi und Thaler (2001) belegen eine Tendenz zur naiven Diversifikation (Gleichverteilung auf verfügbare Optionen); Goetzmann und Kumar (2008) weisen auf eine starke Konzentration auf wenige, korrelierte Titel hin. Calvet et al. (2007) beziffern die Wohlfahrtskosten dieser Unterdiversifikation. Die Allokation resultiert hier oft aus Zufall, Gewohnheit oder räumlicher Nähe.

Der professionelle Anleger verfolgt einen mehrstufigen Verdichtungsprozess. Auf Basis von Kapitalmarktannahmen (Renditen, Volatilitäten, Korrelationen) wird eine strategische Allokation definiert – etwa mittels Markowitz-Optimierung (1952) oder dem Black-Litterman-Modell (1992). Um die Instabilität optimierter Portfolios zu mindern, werden Gewichte begrenzt (Jagannathan und Ma 2003), Kovarianzen geglättet (Ledoit und Wolf

⁸ Knight (1921) unterschied zwischen Risiko, das sich in Wahrscheinlichkeiten fassen lässt, und Unsicherheit, für die das nicht gilt. Faustregeln bewähren sich vor allem unter Unsicherheit; Optimierung und maschinelles Lernen setzen Risiko voraus.

2004) oder Datenreihen verlängert (Kritzman et al. 2010). Auf diese folgt die taktische Steuerung innerhalb definierter Bandbreiten. Jede Stufe ist im Anlageausschuss dokumentiert und verantwortet.⁹

Der Weg des Privatanlegers ist kurz, reaktiv und endet in Einzelentscheidungen. Der Weg des Profis ist zirkulär, beginnt bei der Anlagepolitik und führt über systematisches Research zur Allokation und Selektion.

2.5 Titelselektion: Anleihen und globale Aktienanlagen

Innerhalb der Allokation erfolgt die Auswahl der konkreten Titel. Bei Staatsanleihen fokussiert sich die Entscheidung auf Laufzeit, Emittent und Währung; bei Unternehmensanleihen kommen Bonität und Sektor hinzu. Der Privatanleger nutzt für Anleihen primär Fonds oder ETFs, da Einzelinvestitionen aufgrund von Stückelung und Handelskosten ineffizient sind. Bei Aktien herrscht oft eine Präferenz für bekannte Titel vor – Vertrautheit ersetzt hier die Analyse (Barber und Odean 2008; Goetzmann und Kumar 2008).

Der professionelle Anleger selektiert methodisch. Bei Anleihen bestimmen Zinskurven und Kreditanalysen das Ergebnis.¹⁰ Bei Aktien wird zwischen fundamentaler Analyse (Tiefenprüfung weniger Unternehmen) und quantitativen Verfahren (Faktor-Ranking Tausender Titel nach Bewertung, Momentum, Qualität und Größe) unterschieden (Grinold und Kahn 2000). Abis (2022) zeigt, dass quantitative Fonds eine höhere Diversifikation aufweisen und sich auf die Selektion spezialisieren, während diskretionäre Manager flexibler zwischen Selektion und Timing wechseln.

Für die Auswahl globaler Aktienfonds und ETFs gelten eigene Kriterien: Kosten, Nachbildungsart, Fondsvolumen, Abweichung vom Index und steuerliche Behandlung. Hier ist die Empirie eindeutig und für beide Anlegertypen gleichermaßen gültig. Nach Kosten schlägt die Mehrheit der aktiv verwalteten Fonds ihren Index nicht (Jensen 1968; Carhart 1997; Fama und French 2010). Die SPIVA-Daten bestätigen, dass über zwanzig Jahre rund 93 % der US-Standardwertefonds hinter dem S&P 500 zurückblieben (S&P Dow Jones Indices 2026). Die Auswahl eines Fonds ist somit primär eine Entscheidung über Kosten, Streuung und Disziplin, nicht über Prognosekunst.¹¹

⁹ Ein Beispiel für eine solche transparente Ableitung – die Emerging-Markets-Quote eines globalen Portfolios nach Markowitz und Black-Litterman – findet sich in Rupprechter (2026b).

¹⁰ Ratingmigration bezeichnet die Wanderung eines Emittenten zwischen Bonitätsstufen; ihre Prognose ist bei Unternehmensanleihen ein wesentlicher Teil des Ertrags.

¹¹ Die Grenze von zwanzig Titeln ist eine Untergrenze sinnvoller Streuung, keine Empfehlung: Das unsystematische Risiko sinkt mit der Titelzahl zunächst steil und dann flach, und globale Indexfonds streuen über mehr als tausend Titel.

2.6 Die zeitliche Dimension des Depots

Eine Allokation ist keine Entscheidung, sondern eine Verpflichtung über Jahre. Während der professionelle Anleger durch Regeln (Bandbreiten, Rebalancing, Attribution) gegenzusteuern versucht, driftet das Depot des Privatanlegers oft ungesteuert mit den Märkten.

Die Kosten dieses Verhaltens sind messbar. Die Anlegerrenditelücke – die Differenz zwischen der Fondsrendite und der tatsächlichen Rendite des Anlegers – resultiert aus suboptimalem Timing. Friesen und Sapp (2007) beziffern diese Lücke für US-Aktienfonds auf rund 1,6 Prozentpunkte p.a. Morningstar (2025b) errechnet für den Zeitraum bis Ende 2024 eine Lücke von 1,2 Prozentpunkten jährlich. DALBAR (2025) belegt für 2024, dass Anleger durch suboptimales Timing über 8 Prozentpunkte Rendite preisgaben.¹²

Abbildung 1 zeigt, dass die Lücke bei Aktien-Sektorfonds am größten ist, da diese zu prozyklischem Verhalten einladen. Die Lücke korreliert zudem positiv mit der Volatilität der Mittelflüsse (Morningstar 2025b). Zentral für die weitere Analyse ist: Der Teil der Rendite, der durch Verhalten verloren geht, ist vergleichbar mit den Kosten eines aktiven Managements und könnte theoretisch durch reine Prozessdisziplin – ohne Prognosefähigkeit – eingespart werden.




Abbildung 1: Vergleich der Anleger- und Fondsrenditen nach Anlageklassen in den USA für die zehn Jahre bis zum 31. Dezember 2024. Eigene Darstellung nach Daten von Morningstar (2025b).

¹² DALBAR und Morningstar verwenden unterschiedliche Methoden; die Größenordnung der Lücke ist jedoch über Jahrzehnte und Datenanbieter hinweg stabil: zwischen einem und zwei Prozentpunkten pro Jahr.

3 Systematische Schwächen menschlichen Anlageverhaltens

3.1 Ungeduld und mangelnde Strategietreue

Die erste signifikante Schwäche ist die mangelnde zeitliche Disziplin. Odean (1999) belegt an Brokerdaten, dass Privatanleger ein übermäßiges Handelsvolumen aufweisen, das nicht durch Liquiditätsbedarf oder Rebalancing erklärbar ist, wobei die gekauften Titel tendenziell schlechter abschneiden. Barber und Odean (2000) quantifizieren diesen Effekt: Die aktivsten Haushalte erzielten signifikant geringere Nettorenditen als der Markt. Bogle (2012) konstatiert eine allgemeine Verkürzung der Haltedauern im Zeitverlauf.

Ursächlich hierfür ist die kurzsichtige Verlustaversion (Benartzi und Thaler 1995): Die häufige Überprüfung des Depots führt dazu, dass Verluste überproportional stark gewichtet werden (Kahneman und Tversky 1979). Dies resultiert in einem verkürzten realen Anlagehorizont, unabhängig von der ursprünglichen Zielsetzung.¹³

Auch professionelle Anleger sind hiervon betroffen. Goyal und Wahal (2008) zeigen, dass Vermögensverwalter oft nach einer Phase kurzfristiger Outperformance eingestellt und nach einer Phase von Unterperformance entlassen werden, wobei die entlassenen Manager anschließend oft wieder besser abschnitten. Strategiewechsel erfolgen hier oft nicht aufgrund fundamentaler Fehler, sondern aufgrund temporärer Performance-Schwankungen.

3.2 Prozyklisches Verhalten: Kauf im Hoch, Verkauf im Tief

Eine weitere Schwäche ist die systematische Verspätung der Erwartungsbildung. Anleger extrapolieren die jüngste Vergangenheit in die Zukunft (Greenwood und Shleifer 2014). Malmendier und Nagel (2011) belegen, dass makroökonomische Erfahrungen (z. B. Depressionen) die Risikobereitschaft lebenslang prägen. De Bondt und Thaler (1985) zeigten bereits die Tendenz zur Überreaktion, wodurch Verlierer von gestern oft zu Gewinnern von morgen werden.

Die Mittelflüsse in Fonds spiegeln diese Tendenz wider: Kapital strömt zu, wenn Renditen bereits hoch sind, und fließt ab, wenn Kurse bereits gefallen sind (Frazzini und Lamont 2008). Abbildung 2 illustriert diesen Mechanismus. Das Jahr 2024 verdeutlicht dies: Anleger reduzierten ihre Aktienquote unmittelbar vor dem stärksten Kursschub des Jahres (DALBAR 2025).

¹³ Benartzi und Thaler (1995) schätzen, dass die beobachtete Aktienrisikoprämie mit einem Bewertungsintervall von rund einem Jahr vereinbar ist; wer täglich bewertet, verlangt eine höhere Prämie und hält weniger Aktien.




Abbildung 2: Prozyklisches Anlageverhalten – Eine modellhafte Verknüpfung von Marktphase und Liquiditätsströmen. Quelle: Eigene Darstellung (konzeptionell, ohne reale Marktdaten).

Professionelle Anleger agieren in diesem Kontext langsamer, aber nicht immun. Die Mandatswechsel bei Goyal und Wahal (2008) stellen eine institutionelle Form dieses Verhaltens dar. Brunnermeier und Nagel (2004) sowie Greenwood und Nagel (2009) zeigen, dass insbesondere unerfahrene Manager während Blasenphasen die Positionen in überbewerteten Titeln ausweiteten.¹⁴

3.3 Modetrends und Herdenverhalten

Die Anfälligkeit für Moden ist eine weitere Schwäche. Cooper et al. (2001) belegen, dass bereits die Änderung eines Firmennamens hin zu einem Modethema (z. B. „.com“) zu kurzfristigen Kursgewinnen führte. Cooper et al. (2005) weisen nach, dass Fonds, die ihren Namen an aktuelle Trends anpassen, Zuflüsse generieren, ohne die Strategie oder Performance zu ändern. Themenfonds werden typischerweise am Peak der Popularität aufgelegt und liefern anschließend unterdurchschnittliche Ergebnisse.¹⁵

Herdenverhalten ist bei professionellen Anlegern oft eine rationale Antwort auf institutionelle Anreize. Scharfstein und Stein (1990) zeigen, dass das Risiko eines Alleingangs bei Fehlentscheidungen höher gewichtet wird als der potenzielle Gewinn. Lakonishok et al. (1992) und Wermers (1999) messen dieses Verhalten empirisch. Cremers und Petajisto (2009) identifizieren zudem das „Closet Indexing“, bei dem aktive Manager

¹⁴ Der Autor hat seit 1985 alle Krisen vom Crash 1987 bis zur KI-Euphorie live erlebt; die wichtigste Lehre ist nicht, die nächste Krise vorherzusehen, sondern eine Allokation zu halten, die man in der Krise nicht aufgeben muss.

¹⁵ Rupprechter (2026a) behandelt die Anlage in KI-Unternehmen als Megatrend; die vorliegende Arbeit betont, dass „in KI investieren“ und „mit KI investieren“ zwei verschiedene Fragen sind – und dass die erste den Modezyklen unterliegt, die hier beschrieben werden.

aus Angst vor Abweichungen faktisch den Index nachbilden. Soziale Medien haben diese Zyklen beschleunigt (Barber et al. 2022). Welch (2022) relativiert dies jedoch: In der Summe war das Portfolio von Robinhood-Nutzern nicht schlechter als der Markt, wenngleich die Einzelverteilung stark variierte.

3.4 Überkonfidenz, Dispositionseffekt und Verlustaversion

Die Neigung, Gewinne vorzeitig zu realisieren und Verluste zu lange zu halten (Dispositionseffekt), ist weit verbreitet. Shefrin und Statman (1985) sowie Odean (1998) belegen, dass Privatanleger Gewinne signifikant häufiger realisieren als Verluste. Dies resultiert aus der asymmetrischen Wertfunktion von Kahneman und Tversky (1979): Risikoscheu im Gewinnbereich, Risikofreudigkeit im Verlustbereich.

Überkonfidenz führt insbesondere bei männlichen Anlegern zu einem erhöhten Handelsvolumen und damit zu geringeren Renditen (Barber und Odean 2001). Professionelle Anleger sind ebenfalls betroffen: Frazzini (2006) zeigt eine verzögerte Reaktion auf neue Informationen; Puetz und Ruenzi (2011) belegen, dass gute Ergebnisse zu einem riskanteren und letztlich schlechteren Handelsverhalten führen. Chevalier und Ellison (1997) dokumentieren zudem prozyklische Risikoanpassungen zum Jahresende. Akepanidaworn et al. (2023) zeigen, dass institutionelle Manager zwar exzellente Kaufentscheidungen treffen, ihre Verkaufsentscheidungen jedoch oft schlechter als der Zufall sind, da sie auf suboptimalen Heuristiken basieren.¹⁶

3.5 Komparative Analyse: Professioneller Anleger vs. Privatanleger

Trotz gemeinsamer kognitiver Schwächen ist der professionelle Anleger in systemischen Dimensionen überlegen. Er erzielt eine höhere Diversifikation (Goetzmann und Kumar 2008; Calvet et al. 2007), hat Zugang zu komplexeren Anlageklassen und agiert innerhalb eines reglementierten Prozesses mit Rebalancing-Pflichten. Dadurch vermeidet er die extremsten Ausprägungen der Verhaltenslücke.

In Bezug auf die Alpha-Generierung (Marktschlag) gibt es jedoch keinen signifikanten Vorteil. Jensen (1968), Carhart (1997) und Fama und French (2010) finden kaum Anhaltspunkte für dauerhaftes Können. SPIVA-Daten bestätigen, dass die Mehrheit der professionellen Vermögensmanager langfristig hinter dem Index zurückbleibt. Berk und Green (2004) erklären, warum das nicht ein Widerspruch zu vorhandenem Können ist: Gute Manager ziehen so lange Mittel an, bis ihr Vorsprung an der Größe zerrinnt.

Der Vorteil des Profis liegt somit nicht in der Prognose, sondern in der Prozessqualität (Vermeidung von Fehlern).

¹⁶ Akepanidaworn et al. (2023) schätzen, dass die Verkäufe der untersuchten Manager gegenüber einer zufälligen Verkaufsregel rund 0,8 Prozentpunkte Rendite pro Jahr kosteten – bei Käufen, die den Markt schlugen.

3.6 Strategien zur Optimierung menschlicher Entscheidungen

Die Reduktion kognitiver Fehler erfolgt primär durch die Verlagerung der Entscheidung aus dem Affekt in einen strukturierten Prozess. Zentral ist die schriftlich formulierte Anlagestrategie (Ziel, Horizont, Allokation, Bandbreiten). Dies transformiert die Entscheidung von einer intuitiven Frage in einen Abgleich mit einer definierten Norm.¹⁷

Weiterhin ist die Selbstbindung (Commitment) effektiv. Thaler und Benartzi (2004) zeigen mit „Save More Tomorrow“, dass künftige Verpflichtungen leichter akzeptiert werden als heutige. Automatisierte Sparpläne und Rebalancing reduzieren die Reibung und die Fehlerquote. Die Reduktion der Prüfungsfrequenz verhindert die durch kurzsichtige Verlustaversion induzierte Panik.

Zusätzlich können methodische Werkzeuge die Qualität steigern: Checklisten (Gawande 2009), Prämortems (Klein 2007), die Nutzung von Basisraten (Tetlock und Gardner 2015) sowie Entscheidungstagebücher. Für Gremien wird eine strikte Entscheidungshygiene empfohlen, die unabhängige Urteile vor der Diskussion vorsieht (Kahneman et al. 2021).

Der Mehrwert dieser Maßnahmen ist quantifizierbar. Kinniry et al. (2019) schätzen den Beitrag von Verhaltenscoaching auf rund 1,5 Prozentpunkte p.a.; Blanchett und Kaplan (2013) beziffern den Gewinn aus Allokations- und Steuerdisziplin auf rund 1,6 Prozentpunkte. Institutionelle Verbesserungen umfassen getrennte Kauf-/Verkaufsregeln (Akepanidaworn et al. 2023) und die Anonymisierung von Meinungsabfragen im Anlageausschuss.

4 Die Implementierung Künstlicher Intelligenz in Allokation und Titelselektion

4.1 Taxonomie der Automatisierungsstufen

Innerhalb der Vermögensanlage ist eine Differenzierung zwischen drei Stufen der Automatisierung essenziell. Die erste Stufe umfasst die regelbasierte Automatisierung: Hier führt ein System vordefinierte Regeln (z. B. Zielallokation mit Bandbreiten) aus, ohne aus den Daten zu lernen. Digitale Vermögensverwalter, Sparpläne und Indexnachbildungen fallen in diese Kategorie. Die zweite Stufe ist das maschinelle Lernen (ML): Algorithmen leiten Regeln autonom aus Daten ab, indem sie Zusammenhänge zwischen Prädiktoren (z. B. Bewertungskennzahlen, Kursmustern) und Zielgrößen (künftigen Renditen) schätzen (Mullainathan und Spiess 2017). Gu et al. (2020) belegen, dass insbesondere neuronale Netze und Entscheidungsbäume die Prognosegüte gegenüber linearen Modellen steigern.

¹⁷ Die Zieldefinition sollte in Beträgen und Zeitpunkten formuliert sein („Betrag X im Jahr Y für Zweck Z“), nicht in Renditen; Renditeziele verleiten zum Vergleich mit Nachbarn und Schlagzeilen.

Die dritte Stufe umfasst die generative KI: Große Sprachmodelle (LLMs), die Texte analysieren, zusammenfassen und – wie Kim et al. (2024) zeigen – aus Bilanzen logische Schlüsse ziehen.¹⁸

Die drei Stufen unterscheiden sich in ihrem Versprechen und ihren Risiken: Regelbasierte Systeme bieten Disziplin, sind aber auf die Korrektheit der Regel angewiesen.¹⁹ ML-Systeme bieten Prognosekraft, sind jedoch anfällig für Überanpassung (Overfitting) an historische Daten (Bailey et al. 2014; Harvey et al. 2016) und versagen bei Strukturbrüchen. Generative KI bietet Verständnis und Synthesekapazität, neigt jedoch zu Halluzinationen.

4.2 Datenanalyse und Sentiment-Messung

Ein primärer Mehrwert der KI liegt in der Verarbeitung unstrukturierter Textdaten. Moderne Systeme analysieren Millionen von Dokumenten – Nachrichten, Berichte, Analystengespräche, soziale Medien – in einer Geschwindigkeit, die menschliche Kapazitäten übersteigt. Die Entwicklung reicht von der einfachen Zählung negativer Wörter (Tetlock 2007) über spezialisierte Finanzwörterbücher (Loughran und McDonald 2011) bis hin zu Modellen, die relevante Merkmale autonom identifizieren (Ke et al. 2019). Lopez-Lira und Tang (2023) zeigen, dass LLMs die kurzfristige Kursreaktion präziser vorhersagen können. Jiang et al. (2023) belegen zudem, dass neuronale Netze aus Kurscharts Renditemuster gewinnen, die klassischen Momentum-Signalen überlegen sind.²⁰

Zusätzlich erschließt die KI alternative Datenquellen (Satellitenbilder, Kreditkartendaten, Stellenanzeigen), was laut Zhu (2019) die Informationseffizienz steigert. Professionelle Anleger nutzen diese Stimmungsindikatoren in Echtzeit; für Privatanleger sind diese Quellen oft unzugänglich oder – im Falle sozialer Medien – ohne Aufbereitung riskant.²¹

Zwei systemische Einschränkungen sind zu beachten: Erstens führt die ubiquitäre Nutzung von Signalen zu einer schnellen Arbitrage, wodurch der Vorteil erodiert. Zweitens besteht bei LLMs ein Vorwissensproblem (Look-ahead Bias): Modelle „prognostizieren“ in Backtests Ereignisse, die bereits in ihren Trainingsdaten enthalten waren (Glasserman und Lin 2023; Lopez-Lira et al. 2025). Avramov et al. (2023) zeigen zudem, dass Prognosegewinne oft in illiquiden Titeln liegen und nach Handelskosten schrumpfen.²²

¹⁸ Für die Finanzwirtschaft wurden eigene Sprachmodelle trainiert, etwa BloombergGPT (Wu et al. 2023); in der Praxis dominieren jedoch allgemeine Modelle, die mit firmeneigenen Daten ergänzt werden.

¹⁹ Regelbasierte Systeme werden im Vertrieb häufig als „KI“ bezeichnet; für die Bewertung ist allein entscheidend, ob ein System aus Daten lernt oder nur vorgegebene Regeln ausführt.

²⁰ Jiang et al. (2023) trainieren ein Faltungsnetz auf Bildern von Kurscharts; das Verfahren stammt aus der Bilderkennung und überträgt sich ohne Änderung auf Finanzzeitreihen.

²¹ Zu den Anbietern zählen RavenPack für Nachrichten-Sentiment und Bloomberg für Terminaldaten; die Kosten liegen im Bereich professioneller Datenabonnements.

²² Das Vorwissensproblem betrifft nur Rückrechnungen. Im Echtbetrieb kennt ein Modell die Zukunft nicht – es kann sie aber auch nicht besser prognostizieren, als die Rückrechnung vorgaukelt.

4.3 Maschinelle Allokationsbildung: Vom Optimierer zum Robo-Advisor

Die maschinelle Allokation basiert auf der mathematischen Formulierung der Portfolioauswahl (Markowitz 1952). Moderne Ansätze verbessern die Stabilität der Eingabedaten: Black und Litterman (1992) kombinieren Gleichgewichtsrenditen mit subjektiven Sichten; Ledoit und Wolf (2004) schätzen Kovarianzen robuster; López de Prado (2016) nutzt hierarchische Zuteilungen. Chen et al. (2024) setzen tiefe neuronale Netze zur Schätzung von Risikoprämien ein. Die Maschine rechnet präzise, bleibt jedoch von der Qualität der Schätzwerte abhängig.²³

Für den Privatanleger manifestiert sich dies im Robo-Advisor. Dieser nutzt einen standardisierten Prozess (Fragebogen -> Risikoklasse -> Indexportfolio), ergänzt durch automatisches Rebalancing. Es handelt sich primär um regelbasierte Automatisierung; Morningstar (2025a) hält fest, dass aus Risikogründen auf generative KI bei der Empfehlungsgenerierung verzichtet wird. Der Mehrwert liegt in der Kostenreduktion und der Prozessdisziplin. Vanguard, Betterment und Wealthfront bieten hier hocheffiziente Lösungen an, wobei Morningstar die hohe Cash-Quote bei einigen Anbietern als versteckte Kosten kritisiert.

Empirisch wirken Robo-Advisor insbesondere bei Anlegern mit suboptimalem Vorverhalten positiv. D'Acunto et al. (2019) zeigen eine Steigerung der Diversifikation und eine Reduktion von Dispositionseffekten. Rossi und Utkus (2020) belegen eine Verbesserung des risikobereinigten Ergebnisses durch Risikosenkung. Reher und Sokolinski (2024) weisen auf die Demokratisierung des Zugangs zu professioneller Vermögensverwaltung hin. D'Acunto und Rossi (2023) fassen zusammen, dass Robo-Advice die Anlageentscheidungen näher an die Portfoliotheorie rückt.²⁴

Die Grenzen der Regelhaftigkeit zeigte der Fall Scalable Capital: Ein dynamisches Risikomodell verkaufte im Corona-Crash 2020 massiv Aktien und verpasste die Erholung, was zu einer signifikanten Underperformance gegenüber dem MSCI World führte (FinanceFWD 2024). Die Maschine setzte die Regel präzise um, doch die Regel war für diese Extremsituation suboptimal.²⁵

Der Echtgeldtest von Brokervergleich.de (2026) zeigt, dass Robo-Advisor zwar oft einfache Mischportfolios schlagen, aber langfristig hinter einem optimal gewichteten

²³ López de Prado (2016) nennt sein Verfahren Hierarchical Risk Parity; es kommt ohne Invertierung der Kovarianzmatrix aus, die der Hauptgrund für die Instabilität klassischer Optimierer ist.

²⁴ D'Acunto et al. (2019) untersuchten den Robo-Advisor eines großen indischen Brokers; Rossi und Utkus (2020) nutzten Daten eines großen US-Anbieters mit hybrider Beratung.

²⁵ Der Fall ist lehrreich, weil das Modell nicht versagte, sondern funktionierte: Es senkte das gemessene Risiko. Der Fehler lag in der Regel, die Risiko mit Volatilität gleichsetzte, und nicht in ihrer Ausführung.

globalen Portfolio zurückbleiben. Die KI liefert Disziplin, ersetzt jedoch keine fundierte strategische Aktienquote.²⁶

4.4 Maschinelle Titelselektion: Anleihen und Aktien

In datenreichen Universen spielt die lernende Maschine ihre Stärke aus. Bei Anleihen verbessern neuronale Netze die Prognose von Risikoprämien (Bianchi et al. 2021) und ermöglichen die systematische Bewertung Zehntausender Einzeltitel (Kelly et al. 2023), was für institutionelle Investoren eine notwendige Infrastruktur darstellt.²⁷

Bei Aktien ist die Evidenz heterogen. Gu et al. (2020) und Leippold et al. (2022) belegen die Überlegenheit neuronaler Netze gegenüber linearen Modellen bei der Renditeprognose. Avramov et al. (2023) schränken dies auf illiquide Titel ein.²⁸ Cao et al. (2024) zeigen, dass KI-Modelle in 54,5 % der Fälle menschliche Analysten schlagen, während Menschen bei immateriellen Werten und Sondersituationen überlegen bleiben. Kim et al. (2024) belegen eine Treffquote von 60 % bei der Gewinnrichtung von Unternehmen mittels LLMs.²⁹

Reale Produkte wie der AI Powered Equity ETF (AIEQ)³⁰ oder der Social Sentiment ETF (BUZZ)³¹ zeigen jedoch, dass die Übersetzung von Signalen in Rendite schwierig ist. Beide blieben langfristig hinter dem S&P 500 zurück (Amplify ETFs 2026; VanEck 2026).³² Erfolgreiche Anwendungen finden sich primär in geschlossenen Systemen (Medallion) oder bei Häusern mit tiefem quantitativen Know-how (Bridgewater, Two Sigma).³³ Frei verfügbare KI-Fonds für Privatanleger haben bisher kaum das versprochene Alpha geliefert (Stiftung Warentest 2025).

²⁶ Der Echtgeldtest legt seit Mai 2015 echtes Geld bei den Anbietern an; als Maßstäbe dienen ein 50/50-Portfolio aus Weltaktien und globalen Anleihen sowie ein breit gestreutes globales Portfolio (Brokervergleich.de 2026).

²⁷ Weltweit sind mehrere Zehntausend Unternehmensanleihen ausstehend; die meisten werden selten gehandelt, weshalb Liquidität in jedem Ranking als eigene Größe zu berücksichtigen ist.

²⁸ Das Sharpe-Maß setzt die Überrendite ins Verhältnis zur Schwankung; Gu et al. (2020) berichten für ihr bestes Long-Short-Portfolio Werte, die jene klassischer Faktorportfolios etwa verdoppeln.

²⁹ Kim et al. (2024) anonymisierten die Bilanzen und entfernten Firmennamen und Jahreszahlen, damit das Modell die Antwort nicht aus seinem Trainingswissen abrufen.

³⁰ Die Rendite des S&P 500 für den Zeitraum des AIEQ ergibt sich aus dem Kursindex (2.559 Punkte am 17. Oktober 2017, 7.499 Punkte am 30. Juni 2026, entsprechend 13,2 % p. a.) zuzüglich einer Dividendenrendite von rund 1,5 % p. a.

³¹ Volumen und Kosten nach Anbieterangaben (Amplify ETFs 2026; VanEck 2026); Renditen jeweils nach Kosten auf Basis des Nettoinventarwerts.

³² Die Angaben in Tabelle 7 beruhen auf Anbieterdaten und den genannten Quellen; Gesamtrenditen der Vergleichsindizes sind angegeben, soweit die Anbieter sie ausweisen.

³³ Two Sigma und Man Group setzen maschinelles Lernen seit mehr als einem Jahrzehnt ein; ihre Ergebnisse sind nicht nach Verfahren aufgeschlüsselt veröffentlicht und werden hier deshalb nicht als Beleg herangezogen.

4.5 Algorithmischer Handel und Signalgeber

Die algorithmische Ausführung ist Industriestandard. Sie reduziert Handelskosten und Marktwirkung (Kirilenko und Lo 2013), birgt jedoch systemische Risiken, wie der Flash Crash 2010 oder der Knight Capital Vorfall 2012 belegen (Kirilenko et al. 2017).³⁴

Kritisch zu betrachten sind KI-Signalgeber für Privatanleger (z. B. Tickeron, Stoic AI). Diese leiden oft unter Überanpassung (Backtest Overfitting) und fördern ein häufiges Handeln, das laut Barber und Odean (2000) die Rendite schmälert. Zudem bergen Hebelprodukte in diesen Systemen ein signifikantes Totalverlustrisiko.³⁵

4.6 Interaktive Beratung und generative KI

LLMs transformieren den Zugang zu Finanzwissen. Sie ermöglichen die effiziente Analyse komplexer Dokumente und die Erklärung von Finanzkonzepten auf individuellem Niveau. Niszczoła und Abbas (2023) belegen eine hohe Kompetenz in standardisierten Finanztests. Fieberg et al. (2023) zeigen, dass LLM-Vorschläge risikobereinigt mit professionellen Portfolios konkurrieren können, jedoch oft einen Heimatfokus aufweisen.

Institutionen nutzen LLMs primär als interne Analysewerkzeuge (Morgan Stanley, J.P. Morgan, BlackRock). Extern werden sie zur Erstberatung und Wissensvermittlung eingesetzt (z. B. „Susi“ von WhoFinance).³⁶ Die Aufsicht (ESMA 2024, EU 2024) betont, dass die Verantwortung für die Empfehlung beim Anbieter verbleibt und Transparenzpflichten gelten. Die Maschine übernimmt die Aufbereitung, der Mensch die finale Entscheidung und Verantwortung.³⁷

4.7 Synthese der KI-Anwendungen

Tabelle 1 systematisiert die Anwendungen.³⁸ Die KI eröffnet Möglichkeiten, die zuvor nur Großinstitutionen vorbehalten waren: globale Textanalyse, systematische Anleihen-Rankings, messbare Stimmungslagen, kostengünstige Disziplin, breite Personalisierung und Bildung on demand. Zudem optimiert sie die Analystenarbeit, indem sie Routineaufgaben übernimmt (Cao et al. 2024).

³⁴ Kirilenko et al. (2017) zeigen, dass Hochfrequenzhändler den Flash Crash nicht auslösten, seine Dynamik aber verstärkten, indem sie Positionen in schneller Folge untereinander weiterreichten.

³⁵ Die Handelsplattform Robinhood und der Broker eToro bieten seit 2025 beziehungsweise 2026 eigene KI-Assistenten an; auch sie liefern Erklärungen und Hinweise, keine geprüften Prognosen.

³⁶ Die genannten Anwendungen sind nach Unternehmensangaben beschrieben; unabhängige Wirkungsmessungen liegen für sie bislang nicht vor.

³⁷ Zu den Grenzen der Sprachmodelle bei Zahlen siehe Abschnitt 5.2: In einem Test mit Fragen zu Geschäftsberichten beantwortete ein führendes Modell auch mit Dokumentenzugriff vier von fünf Fragen falsch oder gar nicht (Islam et al. 2023).

³⁸ Die Übersicht erhebt keinen Anspruch auf Vollständigkeit; die Zahl der Anbieter wächst monatlich, und viele Produkte verschwinden ebenso schnell (Stiftung Warentest 2025).

Tabelle 1: Übersicht der KI-Anwendungen in der Vermögensanlage

Anwendungsfeld	Funktion	Reale Beispiele	Nutzer	Evidenz für Mehrwert
Text- und Stimmungsanalyse	Nachrichten, Berichte, soziale Medien in Signale verdichten	RavenPack, Bloomberg-Sentiment, BloombergGPT; BUZZ, AIEQ	Profi	Kurzfristig belegt (Tetlock 2007; Lopez-Lira und Tang 2023); Produkte hinter dem Markt
Mustererkennung in Kursen	Historische Muster mit aktueller Lage vergleichen	Tickeron, Trade-Ideas-Systeme; CNN-Modelle (Jiang et al. 2023)	Beide	Akademisch belegt, in Produkten für Privatanleger ungeprüft
Renditeprognose mit maschinellem Lernen	Nichtlineare Faktormodelle für Aktien und Anleihen	Quantitative Häuser (Two Sigma, Man AHL, Bridgewater AIA); QRFT	Profi	Belegt (Gu et al. 2020; Bianchi et al. 2021; Kelly et al. 2023); nach Kosten kleiner
Risikoprofilierung und Allokation	Fragebogen zu Risikoklasse und ETF-Portfolio; automatisches Rebalancing	Vanguard Digital Advisor, Betterment, Wealthfront, Quirion, Scalable Capital	Privat-anleger	Belegt für vorher schlecht diversifizierte Anleger (D'Acunto et al. 2019; Rossi und Utkus 2020)
Titelselektion Anleihen	Ranking Zehntausender Anleihen nach erwarteter Rendite und Risiko	Interne Systeme großer Anleihehäuser	Profi	Belegt (Kelly et al. 2023); ohne Maschine nicht mehr darstellbar
Titelselektion Aktien und Fonds	Faktorrating, Bilanzanalyse, Analystenersatz	AIEQ, ACATIS AI, LIVR; Robo-Analysten	Beide	Gemischt: Studien positiv (Kim et al. 2024; Cao et al. 2024), Fonds hinter dem Markt
Handelssignale und Handelsroboter	Kauf- und Verkaufssignale, automatischer Handel	Tickeron, Stoic AI	Privat-anleger	Nicht belegt; fördert Umschlag; Totalverlustrisiko bei Hebel
Algorithmische Ausführung	Aufträge zerlegen, Liquidität suchen, Marktwirkung senken	Ausführungsalgorithmen der Broker und Banken	Profi	Belegt; Standard (Kirilenko und Lo 2013)
Risikoüberwachung	Limits, Anomalien, Stresstests, Betrugserkennung	Aladdin, hauseigene Systeme	Profi	Belegt im Betrieb; Modellrisiko bei Strukturbruch
Erklär- und Recherche-Assistenten	Berichte zusammenfassen, Begriffe erklären, Fragen beantworten	ChatGPT, Gemini, Claude; Morgan Stanley, J.P. Morgan intern	Beide	Produktivität belegt (Sheng et al. 2025); Halluzinationsrisiko (Islam et al. 2023)
Chat-Erstberatung	Basiswissen, Bedarfsklärung, Übergabe an Berater	WhoFinance „Susi“, Broker-Assistenten	Privat-anleger	Nutzen als Zugang; keine Empfehlung ohne Haftung (ESMA 2024)
Berichterstattung und Compliance	Kundenberichte, Protokolle, Eignungsdokumentation	Interne Systeme	Profi	Effizienz belegt (Mercer 2026: 69 % der Häuser)

Quelle: Eigene Darstellung.

5 Empirische Bilanz: Erfolge und Fehlschläge der KI

5.1 Nachgewiesene Mehrwerte

Die Evidenz für einen maschinellen Mehrwert konzentriert sich auf vier Bereiche. Erstens: die Prognose von Risikoprämien in großen Querschnitten. Gu et al. (2020) sowie Bianchi et al. (2021) und Kelly et al. (2023) belegen, dass neuronale Netze die Prognosegüte gegenüber linearen Modellen steigern.

Zweitens: die Analyse von Unternehmensinformationen. Kim et al. (2024), Cao et al. (2024) und Coleman et al. (2022) zeigen, dass die Maschine bei der Auswertung von Finanzdaten dem durchschnittlichen Analysten überlegen ist. Sheng et al. (2025) belegen eine risikobereinigte Mehrrendite bei Hedgefonds, die generative KI strategisch integrieren.³⁹

Drittens: die regelbasierte Allokationsdisziplin. D'Acunto et al. (2019) und Rossi und Utkus (2020) zeigen, dass Robo-Advisor verhaltensbedingte Fehler reduzieren. Die fast vollständige Eliminierung der Anlegerrenditelücke bei Mischfonds (Morningstar 2025b) unterstreicht diesen Effekt.

Viertens: die systematische Umsetzung im institutionellen Maßstab. Harvey et al. (2017) zeigen, dass systematische Ansätze eine geringere Ergebnisstreuung aufweisen. Die außergewöhnliche Performance von Medallion (Zuckerman 2019) belegt das Potenzial hochfrequenter, statistischer Mustererkennung unter strikter Kapazitätsbegrenzung.⁴⁰

5.2 Dokumentierte Versagen

Die Fehlschläge der KI verdeutlichen ihre Grenzen. Abbildung 3 zeigt die Underperformance prominenter KI-Strategien wie AIEQ und BUZZ gegenüber dem S&P 500. Die Erosion von Vorteilen durch die ubiquitäre Nutzung derselben Technologie führt zu einer Verringerung der Alpha-Quellen (Tint / IG 2024).

Einzelfälle illustrieren spezifische Versagensmuster: Die Liquidation von Sentient Investment Management (Bloomberg 2018) zeigt das Risiko des Overfittings in Backtests. Der Rechtsstreit um den Superrechner K1 (Bloomberg 2019) verdeutlicht die Gefahren einer ungeprüften algorithmischen Ausführung.⁴¹

³⁹ Sheng et al. (2025) messen die KI-Nutzung indirekt über den Erklärungsgehalt von ChatGPT-Signalen für die Positionsänderungen der Fonds; die Nutzungsquote stieg danach von 21 % Ende 2022 auf rund 60 % im Jahr 2024.

⁴⁰ Bridgewater's KI-Strategie AIA erzielte 2025 rund 11 % und im ersten Halbjahr 2026 8,1 % – exakt so viel wie die Flaggschiffstrategie Pure Alpha im selben Halbjahr (Institutional Investor 2026); 2025 hatte Pure Alpha mit 34 % noch weit vorn gelegen.

⁴¹ Der Investor hatte 250 Millionen US-Dollar eigenes Kapital eingebracht, das mit Krediten auf 2,5 Milliarden gehebelt werden sollte; der Tagesverlust entstand an einer Stop-Loss-Schwelle von 1,4 Prozent (Bloomberg 2019).

Das Versagen von Scalable Capital (FinanceFWD 2024) und die Ergebnisse von Stiftung Warentest (2025) zeigen, dass weder starre Risikomodelle noch kommerzielle KI-Fonds per se einen Mehrwert garantieren. Die Fehler von Knight Capital erinnern an die systemischen Risiken unkontrollierter Geschwindigkeit.⁴²

Besonders kritisch sind die Halluzinationen von LLMs. Islam et al. (2023) belegen eine hohe Fehlerquote bei faktenbasierten Fragen zu Geschäftsberichten. Anekdotische Erfolge kurzer Chatbot-Experimente entbehren oft einer statistischen Basis.⁴³




Abbildung 3: KI-gestützte Strategien und ihr Vergleichsindex: annualisierte Rendite seit Auflage beziehungsweise Indexbeginn. Quellen: Amplify ETFs (2026), VanEck (2026), IG (2024), Federal Reserve Bank of St. Louis (2026); eigene Berechnung und Darstellung.

5.3 Synthese: Komparative Vorteile von Mensch und Maschine

Die Analyse der Erfolge und Fehlschläge offenbart ein Muster, das an die Erkenntnisse von Meehl (1954) und Grove et al. (2000) anknüpft: Mechanische Regeln schlagen klinische Experten dort, wo die Umgebung stabil ist und ausreichend Daten vorliegen. In der Vermögensanlage betrifft dies das Ranking, die Textauswertung und das Rebalancing.⁴⁴

Der Mensch ist überlegen, wenn diese Bedingungen nicht erfüllt sind. Abis (2022) zeigt die Überlegenheit diskretionärer Fonds in Rezessionen; Cao et al. (2024) identifizieren den

⁴² Knight Capital überlebte den Verlust nur dank einer Notfinanzierung und ging 2013 in der Fusion mit Getco auf; Ursache war ein veralteter Programmteil, der auf einem von acht Servern nicht ersetzt worden war.

⁴³ Ein Sprachmodell ohne Werkzeuganbindung rechnet nicht, es formuliert. Aktuelle Modelle greifen deshalb auf Rechenwerkzeuge und Datenbanken zu; die Pflicht zur Prüfung des Ergebnisses bleibt beim Nutzer.

⁴⁴ Dawes et al. (1989) zeigen zudem, dass selbst grobe lineare Modelle mit gleichen Gewichten Experten schlagen – ein Ergebnis, das an DeMiguel et al. (2009) und die 1/N-Regel erinnert.

menschlichen Vorteil bei immateriellen Werten und Sondersituationen. Dies korrespondiert mit der Unterscheidung zwischen Risiko (messbar) und Unsicherheit (nicht messbar) nach Knight (1921) und Taleb (2007).

Abbildung 4 synthetisiert dieses Muster. Die optimale Konfiguration ist eine synergetische Zusammenarbeit, bei der die KI Hypothesen liefert und der Mensch diese prüft, oder die Maschine eine vom Menschen definierte Strategie präzise umsetzt. Agrawal et al. (2018) argumentieren ökonomisch: Da KI den Preis der Prognose senkt, steigt der relative Wert des menschlichen Urteils.




Abbildung 4: Vergleichende Entscheidungsanalyse: Menschliche vs. maschinelle Stärken in Abhängigkeit von Kontext und Aufgabenstellung. Quelle: Eigene Auswertung.

6 Grenzen und Risiken der Künstlichen Intelligenz in der Vermögensanlage

Die Implementierung von KI-Systemen ist mit fundamentalen Grenzen verbunden. Die erste betrifft die epistemische Limitation: Lernende Systeme basieren auf historischen Daten. Völlig neue Ereignisse – sogenannte „Schwarze Schwäne“ (Taleb 2007) – können nicht prognostiziert werden. Der Mensch teilt zwar die Unkenntnis, besitzt jedoch die Fähigkeit, die Validität bestehender Modelle bei einem Regimewechsel grundsätzlich in Frage zu stellen (Knight 1921; Kahneman und Klein 2009). Modelle, die in stabilen Phasen exzellente Ergebnisse liefern, versagen oft genau dann, wenn die Volatilität zunimmt (Abis 2022).⁴⁵

⁴⁵ Der Zollschock vom April 2025 und die Eskalation im Nahen Osten im Juni 2025 sind jüngere Beispiele für Ereignisse, die in den Trainingsdaten der meisten Modelle kein Vorbild hatten.

Die zweite Grenze ist die Tendenz zu Halluzinationen in generativen Modellen. Die Ergebnisse von Islam et al. (2023) zeigen, dass LLMs faktisch falsche Informationen mit hoher sprachlicher Sicherheit präsentieren. Zudem besteht das Problem des Look-ahead Bias (Glasserman und Lin 2023), bei dem Modelle in Rückrechnungen Informationen nutzen, die zum Zeitpunkt der Entscheidung nicht verfügbar waren.

Die dritte Grenze ist das Fehlen von Kontextverständnis und Common Sense. Während die Maschine Zahlen und Texte verarbeitet, fehlen ihr Einsichten in immaterielle Werte, Managementqualität oder emotionale Kundenbedürfnisse. Cao et al. (2024) identifizieren genau hier die Domäne menschlicher Überlegenheit.⁴⁶

Die vierte Grenze ist die Überanpassung. Die Erzeugung von Rendite-Faktoren durch massives Testen von Regeln führt oft zu Pseudomathematik (Bailey et al. 2014; Harvey et al. 2016). Ein striktes Protokoll zur Trennung von Test- und Validierungsdaten ist daher unerlässlich (Arnott et al. 2019; López de Prado 2018).⁴⁷

Systemisch führt die Verbreitung ähnlicher Modelle zu einer Synchronisation des Marktverhaltens. Der IWF (2024), der Finanzstabilitätsrat (FSB 2024) und die BIZ (2024) warnen vor erhöhter Volatilität und Herdenrisiken in Stressphasen. Der Eurekahedge-Index (IG 2024) illustriert die Erosion von Alpha durch die ubiquitäre Nutzung identischer Signalgeber.⁴⁸

Abschließend bestehen praktische Hürden: Datenqualität, regulatorische Anforderungen (ESMA 2024) und Kosten. KI-gesteuerte Produkte für Privatanleger sind oft signifikant teurer als passive Alternativen. Zudem bleibt die Haftungsfrage bei algorithmischen Fehlentscheidungen ein rechtliches Risiko (Fall Tyndaris).

7 Handlungsempfehlungen zur nutzbringenden Integration von KI

7.1 Empfehlungen für den Privatanleger

Für den Privatanleger ergibt sich eine klare Arbeitsteilung: Die Maschine substituiert die suboptimalen Verhaltensweisen des Menschen – insbesondere in den Bereichen Disziplin, Diversifikation und Ausführung –, während die Zieldefinition und die Verantwortung menschlich bleiben. Tabelle 2 bietet eine Übersicht der Empfehlungen, die in den folgenden Absätzen näher begründet werden.

⁴⁶ Der Hinweis auf Managementqualität gilt für Aktien; bei Staats- und Unternehmensanleihen ist der Anteil maschinell erfassbarer Größen höher, weshalb die Maschine dort vergleichsweise stärker ist.

⁴⁷ Harvey et al. (2016) zählen mehr als 300 in Fachzeitschriften veröffentlichte Renditefaktoren und verlangen für neue Faktoren eine t-Statistik von mindestens drei statt der üblichen zwei.

⁴⁸ Der IMF (2024) weist zudem auf die Abhängigkeit von wenigen Anbietern von Rechenleistung, Daten und Modellen hin, deren Ausfall viele Marktteilnehmer gleichzeitig träfe.

Fundament ist eine schriftlich fixierte Anlagestrategie. Zielsetzung, Anlagehorizont und Risikotragfähigkeit müssen vorab definiert werden. Die Umsetzung sollte maximal automatisiert erfolgen: ein kostengünstiges globales Portfolio aus ETFs, bespart via Sparplan und rebalanciert nach festen Regeln. Wer die notwendige Disziplin nicht aufbringt, findet in kostengünstigen Robo-Advisorn eine effektive Lösung, da diese – wie D'Acunto et al. (2019) und Rossi und Utkus (2020) belegen – systemische Fehler reduzieren. Bei der Anbieterwahl sollten Kosten und eine angemessene Aktienquote priorisiert werden; dynamische Risikomodelle, die in Crash-Phasen verkaufen, sind kritisch zu bewerten (FinanceFWD 2024).⁴⁹

Generative KI sollte als Wissenswerkzeug (Erklärer), nicht als Orakel eingesetzt werden. Sie eignet sich zur Analyse von Berichten und zur Klärung von Fachbegriffen, jedoch nicht zur Abfrage von Kennzahlen ohne Quellenprüfung (Islam et al. 2023). Von KI-basierten Signalgebern, Handelsrobotern und Hebelprodukten ist aufgrund des Risikos von Overfitting, hoher Handelsfrequenzen (Barber und Odean 2000) und Totalverlusten abzuraten. KI-Fonds sind aufgrund ihrer Kosten und der empirischen Bilanz (Stiftung Warentest 2025) eher als Experimente denn als Kerninvestment zu betrachten.⁵⁰

⁴⁹ Ein weltweit investiertes Portfolio aus einem globalen Aktien-ETF und einem globalen Anleihe-ETF kostet heute weniger als 0,2 Prozent pro Jahr; jeder Mehrwert eines Anbieters ist an diesem Maßstab zu messen.

⁵⁰ Eine nützliche Übung ist, das Sprachmodell zu bitten, die eigene Anlagestrategie zu kritisieren und die drei häufigsten Fehler zu nennen, die Anleger mit dieser Strategie machen; die Antworten sind meist treffender als die Kursprognosen.

Tabelle 2: Empfehlungen für den Privatanleger: Aufgabenteilung zwischen Mensch und Maschine

Aufgabe	Der Maschine überlassen	Beim Menschen belassen	Begründung
Ziele, Anlagehorizont, Risikotragfähigkeit	Fragen stellen, Begriffe erklären, Strategie auf Lücken prüfen	Antworten geben, Strategie schriftlich festlegen	Nur der Anleger kennt seine Lage; Schrift schützt vor Affekt (Abschnitt 3.6)
Strategische Allokation	Umsetzung über Globale Portfolio-ETFs oder kostengünstigen Robo-Advisor	Wahl der Aktienquote nach Anlagehorizont; Wahl des Anbieters	Robo verkleinert Diversifikations- und Handelsfehler (D'Acunto et al. 2019)
Rebalancing und Sparplan	Vollständig automatisieren	Regel einmal festlegen	Vermeidet Verspätung und Drift (Morningstar 2025b)
Titelselektion Anleihen	Breite Anleihe-ETFs oder -Fonds; keine Einzelanleihen	Wahl von Laufzeitsegment und Bonität	Streuung und Kosten nur über Fonds darstellbar
Titelselektion Aktien	Globale Aktien-ETFs und -Fonds; ab zwanzig Titeln bei Einzelaktien	Verzicht auf Modethemen und KI-Fonds mit kurzer Bilanz	Aktive Auswahl schlägt Index selten (S&P Dow Jones Indices 2026)
Information und Recherche	Berichte zusammenfassen, Produkte erklären, Gegenargumente sammeln	Jede Zahl an der Quelle prüfen	Halluzinationsrisiko (Islam et al. 2023)
Handel und Signale	Nichts – keine Handelsroboter, keine Signaldienste, kein Hebel	Seltene, geplante Transaktionen	Umschlag kostet Rendite (Barber und Odean 2000); Totalverlustrisiko
Verhaltenskontrolle	Entscheidungstagebuch führen und auswerten lassen	Vier-Augen-Prinzip vor außerplanmäßigen Eingriffen	Macht Muster sichtbar (Tetlock und Gardner 2015)

Quelle: Eigene Darstellung.

7.2 Empfehlungen für den professionellen Anleger

Für Asset- und Fondsmanager ist die synergetische Kombination („Mensch + Maschine“) die effektivste Konfiguration (Cao et al. 2024). Die Maschine wird dort eingesetzt, wo Aufgaben datenintensiv und regelhaft sind: Textanalyse, Ranking von Anleihen, Schätzung von Risikoprämien, Limitüberwachung und Reporting. Der Mensch behält die Entscheidungshoheit bei der Definition der Anlagepolitik, der Bewertung von Sondersituationen und der Übernahme der Verantwortung gegenüber Kunden und Aufsicht. Mercer (2026) bestätigt, dass die Branche diesen Weg der analytischen Partnerschaft bereits einschlägt.⁵¹

Konkrete Implementierungsregeln: Erstens sollte jedes Modell als Hypothese behandelt werden und muss ökonomisch begründet sowie außerhalb der Stichprobe validiert werden

⁵¹ Die Umfrage wurde im Februar 2026 unter 131 Vermögensverwaltern weltweit durchgeführt; 69 % berichten messbare Effizienzgewinne, aber nur 8 % messbar bessere Anlagerenditen (Mercer 2026).

(Arnott et al. 2019). Dokumentation aller Versuche ist Pflicht (López de Prado 2018). Zweitens sollten Entscheidungsprozesse getrennt verlaufen: Unabhängige Urteile von Mensch und Maschine sollten vor der Synthese erhoben werden, um komplementäre Fehlerquellen zu minimieren (Kahneman et al. 2021). Drittens müssen Modelle über definierte Abschaltregeln verfügen, um systemische Fehlsteuerungen zu vermeiden.

Viertens sollte die Überfüllung von Signalen (Crowding) überwacht werden. Ein Wettbewerbsvorteil entsteht primär aus proprietären Daten und der Integration der KI in einen proprietären Prozess.⁵² Fünftens sollte generative KI zur Vorbereitung von Research und Dokumentation genutzt werden, wobei eine menschliche Endprüfung und Quellenanbindung zwingend erforderlich sind (ESMA 2024). Sechstens sollte die Maschine zur Steigerung der eigenen Disziplin eingesetzt werden, etwa durch die automatisierte Protokollierung von Entscheidungen.

7.3 Bereiche für die vollständige Automatisierung

Es existieren spezifische Aufgaben, bei denen die vollständige Delegation an die Maschine empirisch überlegen ist, da menschliches Eingreifen hier systematisch schadet. Dazu gehören: die Allokation und das Rebalancing des Kernvermögens bei verhaltensanfälligen Privatanlegern (Morningstar 2025b), die Indexnachbildung sowie die algorithmische Orderausführung (Kirilenko und Lo 2013), das systematische Ranking von Unternehmensanleihen (Kelly et al. 2023) und die breit angelegte Textverarbeitung (Sheng et al. 2025).⁵³ Die Titelselektion bei Aktien und die taktische Allokation hingegen bleiben Bereiche, in denen eine rein maschinelle Lösung bisher keinen nachhaltigen Mehrwert gegenüber dem Markt belegen konnte.⁵⁴

7.4 Die Transformation der Anlageberatung

Die KI macht die Anlageberatung nicht obsolet, transformiert sie jedoch grundlegend. Technische Aufgaben wie Rechnen, Erklären und Dokumentieren werden automatisiert. Der Wert des Beraters verschiebt sich hin zu Vertrauensbildung, Verhaltensführung in Krisen (Kinniry et al. 2019) und der individuellen Zieldefinition.⁵⁵ Die „Turing-Falle“ (Brynjolfsson 2022) – die bloße Nachahmung menschlichen Verhaltens durch KI – wird

⁵² Die Konzentration der KI-Gewinne auf große Häuser (Sheng et al. 2025) legt nahe, dass kleinere Vermögensverwalter eher von zugekauften Werkzeugen für Research und Dokumentation profitieren als von eigenen Prognosemodellen.

⁵³ Bei Staatsanleihen ist das Universum kleiner, doch die Zinsstrukturdaten sind reichhaltig; Bianchi et al. (2021) zeigen, dass gerade die Breite makroökonomischer Daten den Vorteil neuronaler Netze begründet.

⁵⁴ Harvey et al. (2017) untersuchen Hedgefonds-Daten der Jahre 1996 bis 2014; nach Bereinigung um Faktorrisiken liegen systematische Makrofonds vorn, bei Aktienstrategien besteht kein Unterschied.

⁵⁵ Dietvorst et al. (2018) zeigen auch den Ausweg aus der Algorithmusaversion: Wer den Algorithmus geringfügig anpassen darf, vertraut ihm deutlich mehr – ein Argument für hybride Modelle, in denen der Mensch das letzte Wort behält.

durch eine Ergänzung ersetzt, bei der der Berater die Maschine als analytischen Partner nutzt.

Die Zukunft liegt in hybriden Modellen, die eine hocheffiziente maschinelle Basis mit menschlicher Empathie und Verantwortung verbinden. Verlieren wird nicht die Beratung, sondern die Beratung, die nur Rechnen und Erklären war.

8 Fazit und Ausblick

Die Untersuchung hat analysiert, an welchen Stellen der Künstlichen Intelligenz in der Vermögensanlage ein komparativer Vorteil gegenüber dem menschlichen Urteil zukommt. Das Ergebnis ist konsistent für Privatanleger und professionelle Manager: Der Mensch ist anfällig für systematische Fehler – Ungeduld, prozyklisches Timing, Herdenverhalten und eine fehlerhafte Verkaufsdisziplin. Diese Verhaltenslücke führt zu einer messbaren Renditeminderung von etwa einem bis zwei Prozentpunkten pro Jahr.

Der professionelle Anleger ist dem Privatanleger nicht durch bessere Prognosekunst überlegen, sondern durch eine überlegene Prozessstruktur (Diversifikation, Kostenkontrolle, Rebalancing). Die KI liefert einen belegbaren Mehrwert genau dort, wo diese menschlichen Schwächen wirken und die Aufgabe zugleich datenintensiv, repetitiv und regelhaft ist: bei der Textanalyse, dem Ranking großer Universen, der Allokationsdisziplin und der Handelsausführung. In diesen Bereichen ist sie nach aktuellem Forschungsstand nicht nur gleichwertig, sondern überlegen.

Sie versagt hingegen in Umgebungen mit hoher Unsicherheit, bei Regimewechseln, Sondersituationen oder der Bewertung immaterieller Werte. Die Bilanz kommerzieller KI-Fonds und die dokumentierten Fehlschläge algorithmischer Systeme unterstreichen diese Grenzen.

Daraus folgt für den Privatanleger: Ziele und Strategie schriftlich definieren, die Umsetzung maximal automatisieren (ggf. via Robo-Advisor), LLMs als Wissenswerkzeug nutzen, aber jede Zahl prüfen und von Signalgebern Abstand nehmen.⁵⁶ Für den professionellen Vermögensverwalter folgt: die KI als analytischen Partner integrieren, die finale Entscheidung bei komplexen Kontexten menschlich steuern, Modelle als dokumentierte Hypothesen behandeln und die Überfüllung von Signalen überwachen.

KI ersetzt nicht den Anleger, sondern substituiert dessen suboptimalste Gewohnheiten. Zieldefinition und Verantwortung bleiben genuin menschliche Domänen.

Der Ausblick ist eine hybride Architektur. Die Anlageberatung transformiert sich: Technische Analyse und Dokumentation wandern zur Maschine; Empathie, Verhaltensführung und Verantwortung bleiben beim Menschen. Die Maschine wird leistungsfähiger, doch dauerhafte Überrenditen bleiben selten, da jeder ubiquitäre Vorteil

⁵⁶ Die Empfehlungen beruhen auf der zitierten Evidenz und ersetzen keine individuelle Eignungsprüfung im Sinne der MiFID II.

im Kapitalmarkt schnell weggehandelt wird.⁵⁷ Offen bleiben die Frage nach der Verteilung der Gewinne generativer KI, die systemischen Risiken synchronisierter Modelle und die psychologische Reaktion von Anlegern auf sichtbare Fehlentscheidungen der Maschine.⁵⁸ Die Verhaltensökonomik legt nahe, dass die letzte Antwort erneut beim Menschen liegt.

⁵⁷ Die Überfüllung bekannter Signale spricht nicht gegen den Einsatz der KI, sondern gegen die Erwartung, mit ihr systematisch Überrenditen zu erzielen; ihr Nutzen liegt in Kosten, Disziplin und Breite, nicht im Alpha.

⁵⁸ Zu den drei offenen Fragen vgl. die Forschungsagenden bei Kelly und Xiu (2023) sowie D'Acunto und Rossi (2023).

Literaturverzeichnis

- Abis, S. (2022). Man vs. machine: Quantitative and discretionary equity management. Working Paper, Columbia Business School.
- Agrawal, A., Gans, J., & Goldfarb, A. (2018). Prediction Machines: The Simple Economics of Artificial Intelligence. Boston: Harvard Business Review Press.
- Akepanidaworn, K., Di Mascio, R., Imas, A., & Schmidt, L. (2023). Selling fast and buying slow: Heuristics and trading performance of institutional investors. *Journal of Finance*, 78(6), 3055–3098.
- Amplify ETFs (2026). Amplify AI Powered Equity ETF (AIEQ): Fund performance as of 30 June 2026 and fund facts as of 24 September 2026. Wheaton, IL: Amplify Investments.
- Arnott, R., Harvey, C. R., & Markowitz, H. (2019). A backtesting protocol in the era of machine learning. *Journal of Financial Data Science*, 1(1), 64–74.
- Avramov, D., Cheng, S., & Metzker, L. (2023). Machine learning vs. economic restrictions: Evidence from stock return predictability. *Management Science*, 69(5), 2587–2619.
- Bailey, D. H., Borwein, J. M., López de Prado, M., & Zhu, Q. J. (2014). Pseudo-mathematics and financial charlatanism: The effects of backtest overfitting on out-of-sample performance. *Notices of the American Mathematical Society*, 61(5), 458–471.
- Bank for International Settlements (BIS) (2024). Artificial intelligence and the economy: Implications for central banks. BIS Annual Economic Report 2024, Chapter III. Basel: BIS.
- Barber, B. M., & Odean, T. (2000). Trading is hazardous to your wealth: The common stock investment performance of individual investors. *Journal of Finance*, 55(2), 773–806.
- Barber, B. M., & Odean, T. (2001). Boys will be boys: Gender, overconfidence, and common stock investment. *Quarterly Journal of Economics*, 116(1), 261–292.
- Barber, B. M., & Odean, T. (2008). All that glitters: The effect of attention and news on the buying behavior of individual and institutional investors. *Review of Financial Studies*, 21(2), 785–818.
- Barber, B. M., Huang, X., Odean, T., & Schwarz, C. (2022). Attention-induced trading and returns: Evidence from Robinhood users. *Journal of Finance*, 77(6), 3141–3190.
- Bartram, S. M., Branke, J., & Motahari, M. (2020). Artificial Intelligence in Asset Management. Charlottesville: CFA Institute Research Foundation.
- Benartzi, S., & Thaler, R. H. (1995). Myopic loss aversion and the equity premium puzzle. *Quarterly Journal of Economics*, 110(1), 73–92.
- Benartzi, S., & Thaler, R. H. (2001). Naive diversification strategies in defined contribution saving plans. *American Economic Review*, 91(1), 79–98.
- Berk, J. B., & Green, R. C. (2004). Mutual fund flows and performance in rational markets. *Journal of Political Economy*, 112(6), 1269–1295.

- Bhattacharya, U., Hackethal, A., Kaesler, S., Loos, B., & Meyer, S. (2012). Is unbiased financial advice to retail investors sufficient? Answers from a large field study. *Review of Financial Studies*, 25(4), 975–1032.
- Bianchi, D., Büchner, M., & Tamoni, A. (2021). Bond risk premiums with machine learning. *Review of Financial Studies*, 34(2), 1046–1089.
- Black, F., & Litterman, R. (1992). Global portfolio optimization. *Financial Analysts Journal*, 48(5), 28–43.
- Blanchett, D., & Kaplan, P. (2013). Alpha, beta, and now... gamma. *Journal of Retirement*, 1(2), 29–45.
- Bloomberg (2018). AI hedge fund Sentient is said to shut after less than two years. *Bloomberg News*, 7 September 2018.
- Bloomberg (2019). Who to sue when a robot loses your fortune. *Bloomberg News*, 6 May 2019.
- Bogle, J. C. (2012). *The Clash of the Cultures: Investment vs. Speculation*. Hoboken: Wiley.
- Brinson, G. P., Hood, L. R., & Beebower, G. L. (1986). Determinants of portfolio performance. *Financial Analysts Journal*, 42(4), 39–44.
- Brokervergleich.de (2026). Robo-Advisor im Echtgeld-Test: Performance-Vergleich seit 2015, Stand 31. Juli 2026. Hamburg: Brokervergleich.de.
- Brunnermeier, M. K., & Nagel, S. (2004). Hedge funds and the technology bubble. *Journal of Finance*, 59(5), 2013–2040.
- Brynjolfsson, E. (2022). The Turing trap: The promise and peril of human-like artificial intelligence. *Daedalus*, 151(2), 272–287.
- Calvet, L. E., Campbell, J. Y., & Sodini, P. (2007). Down or out: Assessing the welfare costs of household investment mistakes. *Journal of Political Economy*, 115(5), 707–747.
- Cao, S., Jiang, W., Wang, J., & Yang, B. (2024). From man vs. machine to man + machine: The art and AI of stock analyses. *Journal of Financial Economics*, 160, 103910.
- Carhart, M. M. (1997). On persistence in mutual fund performance. *Journal of Finance*, 52(1), 57–82.
- Chen, L., Pelger, M., & Zhu, J. (2024). Deep learning in asset pricing. *Management Science*, 70(2), 714–750.
- Chevalier, J., & Ellison, G. (1997). Risk taking by mutual funds as a response to incentives. *Journal of Political Economy*, 105(6), 1167–1200.
- Chevalier, J., & Ellison, G. (1999). Career concerns of mutual fund managers. *Quarterly Journal of Economics*, 114(2), 389–432.
- Coleman, B., Merkley, K., & Pacelli, J. (2022). Human versus machine: A comparison of robo-analyst and traditional research analyst investment recommendations. *The Accounting Review*, 97(5), 221–244.

- Cookson, J. A., Engelberg, J. E., & Mullins, W. (2023). Echo chambers. *Review of Financial Studies*, 36(2), 450–500.
- Cooper, M. J., Dimitrov, O., & Rau, P. R. (2001). A rose.com by any other name. *Journal of Finance*, 56(6), 2371–2388.
- Cooper, M. J., Gulen, H., & Rau, P. R. (2005). Changing names with style: Mutual fund name changes and their effects on fund flows. *Journal of Finance*, 60(6), 2825–2858.
- Cremers, K. J. M., & Petajisto, A. (2009). How active is your fund manager? A new measure that predicts performance. *Review of Financial Studies*, 22(9), 3329–3365.
- Da, Z., Engelberg, J., & Gao, P. (2011). In search of attention. *Journal of Finance*, 66(5), 1461–1499.
- D'Acunto, F., & Rossi, A. G. (2023). Robo-advice: Transforming households into rational economic agents. *Annual Review of Financial Economics*, 15, 543–563.
- D'Acunto, F., Prabhala, N., & Rossi, A. G. (2019). The promises and pitfalls of robo-advising. *Review of Financial Studies*, 32(5), 1983–2020.
- DALBAR (2025). Investors missed the best of 2024's market gains, latest DALBAR Investor Behavior Report finds. *Quantitative Analysis of Investor Behavior (QAIB)*, press release, 31 March 2025. Marlborough, MA: DALBAR, Inc.
- Dawes, R. M., Faust, D., & Meehl, P. E. (1989). Clinical versus actuarial judgment. *Science*, 243(4899), 1668–1674.
- De Bondt, W. F. M., & Thaler, R. (1985). Does the stock market overreact? *Journal of Finance*, 40(3), 793–805.
- DeMiguel, V., Garlappi, L., & Uppal, R. (2009). Optimal versus naive diversification: How inefficient is the 1/N portfolio strategy? *Review of Financial Studies*, 22(5), 1915–1953.
- Dietvorst, B. J., Simmons, J. P., & Massey, C. (2018). Overcoming algorithm aversion: People will use imperfect algorithms if they can (even slightly) modify them. *Management Science*, 64(3), 1155–1170.
- Engelberg, J. E., & Parsons, C. A. (2011). The causal impact of media in financial markets. *Journal of Finance*, 66(1), 67–97.
- European Securities and Markets Authority (ESMA) (2024). Public statement on the use of artificial intelligence (AI) in the provision of retail investment services. ESMA35-335435667-5924, 30 May 2024. Paris: ESMA.
- European Union (EU) (2024). Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). *Official Journal of the European Union*, L, 12 July 2024.
- Fama, E. F., & French, K. R. (2010). Luck versus skill in the cross-section of mutual fund returns. *Journal of Finance*, 65(5), 1915–1947.
- Federal Reserve Bank of St. Louis (2026). S&P 500 index (SP500), daily closing values. FRED database (accessed 26 September 2026).

- Fieberg, C., Hornuf, L., & Streich, D. (2023). Using GPT-4 for financial advice. CESifo Working Paper No. 10529.
- FinanceFWD (2024). Scalable Capital stoppt ursprüngliche Robo-Anlagestrategie. FinanceFWD, 24. Juni 2024.
- Financial Stability Board (FSB) (2024). The Financial Stability Implications of Artificial Intelligence. Basel: FSB, 14 November 2024.
- Foerster, S., Linnainmaa, J. T., Melzer, B. T., & Previtero, A. (2017). Retail financial advice: Does one size fit all? *Journal of Finance*, 72(4), 1441–1482.
- Frazzini, A. (2006). The disposition effect and underreaction to news. *Journal of Finance*, 61(4), 2017–2046.
- Frazzini, A., & Lamont, O. A. (2008). Dumb money: Mutual fund flows and the cross-section of stock returns. *Journal of Financial Economics*, 88(2), 299–322.
- Friesen, G. C., & Sapp, T. R. A. (2007). Mutual fund flows and investor returns: An empirical examination of fund investor timing ability. *Journal of Banking & Finance*, 31(9), 2796–2816.
- Gawande, A. (2009). *The Checklist Manifesto: How to Get Things Right*. New York: Metropolitan Books.
- Gennaioli, N., Shleifer, A., & Vishny, R. (2015). Money doctors. *Journal of Finance*, 70(1), 91–114.
- Gigerenzer, G., & Brighton, H. (2009). Homo heuristics: Why biased minds make better inferences. *Topics in Cognitive Science*, 1(1), 107–143.
- Glasserman, P., & Lin, C. (2023). Assessing look-ahead bias in stock return predictions generated by GPT sentiment analysis. arXiv:2309.17322.
- Goetzmann, W. N., & Kumar, A. (2008). Equity portfolio diversification. *Review of Finance*, 12(3), 433–463.
- Gomes, F., Haliassos, M., & Ramadorai, T. (2021). Household finance. *Journal of Economic Literature*, 59(3), 919–1000.
- Goyal, A., & Wahal, S. (2008). The selection and termination of investment management firms by plan sponsors. *Journal of Finance*, 63(4), 1805–1843.
- Greenwood, R., & Nagel, S. (2009). Inexperienced investors and bubbles. *Journal of Financial Economics*, 93(2), 239–258.
- Greenwood, R., & Shleifer, A. (2014). Expectations of returns and expected returns. *Review of Financial Studies*, 27(3), 714–746.
- Grinold, R. C., & Kahn, R. N. (2000). *Active Portfolio Management: A Quantitative Approach for Producing Superior Returns and Controlling Risk* (2nd ed.). New York: McGraw-Hill.
- Grossman, S. J., & Stiglitz, J. E. (1980). On the impossibility of informationally efficient markets. *American Economic Review*, 70(3), 393–408.

- Grove, W. M., Zald, D. H., Lebow, B. S., Snitz, B. E., & Nelson, C. (2000). Clinical versus mechanical prediction: A meta-analysis. *Psychological Assessment*, 12(1), 19–30.
- Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *Review of Financial Studies*, 33(5), 2223–2273.
- Harvey, C. R., Liu, Y., & Zhu, H. (2016). ... and the cross-section of expected returns. *Review of Financial Studies*, 29(1), 5–68.
- Harvey, C. R., Rattray, S., Sinclair, A., & Van Hemert, O. (2017). Man vs. machine: Comparing discretionary and systematic hedge fund performance. *Journal of Portfolio Management*, 43(4), 55–69.
- Hong, H., Kubik, J. D., & Stein, J. C. (2005). Thy neighbor's portfolio: Word-of-mouth effects in the holdings and trades of money managers. *Journal of Finance*, 60(6), 2801–2824.
- Ibbotson, R. G., & Kaplan, P. D. (2000). Does asset allocation policy explain 40, 90, or 100 percent of performance? *Financial Analysts Journal*, 56(1), 26–33.
- IG (2024). Is the impact of AI on hedge funds overhyped? IG Prime Insights, 26 November 2024.
- Institutional Investor (2026). Behind Bridgewater's surge. *Institutional Investor*, 8 January 2026.
- International Monetary Fund (IMF) (2024). Advances in artificial intelligence: Implications for capital market activities. *Global Financial Stability Report*, October 2024, Chapter 3. Washington, DC: IMF.
- Islam, P., Kannappan, A., Kiela, D., Qian, R., Scherrer, N., & Vidgen, B. (2023). FinanceBench: A new benchmark for financial question answering. *arXiv:2311.11944*.
- Jagannathan, R., & Ma, T. (2003). Risk reduction in large portfolios: Why imposing the wrong constraints helps. *Journal of Finance*, 58(4), 1651–1683.
- Jenkinson, T., Jones, H., & Martinez, J. V. (2016). Picking winners? Investment consultants' recommendations of fund managers. *Journal of Finance*, 71(5), 2333–2370.
- Jensen, M. C. (1968). The performance of mutual funds in the period 1945–1964. *Journal of Finance*, 23(2), 389–416.
- Jiang, J., Kelly, B., & Xiu, D. (2023). (Re-)Imag(in)ing price trends. *Journal of Finance*, 78(6), 3193–3249.
- Kahneman, D. (2011). *Thinking, Fast and Slow*. New York: Farrar, Straus and Giroux.
- Kahneman, D., & Klein, G. (2009). Conditions for intuitive expertise: A failure to disagree. *American Psychologist*, 64(6), 515–526.
- Kahneman, D., & Tversky, A. (1979). Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2), 263–291.
- Kahneman, D., Sibony, O., & Sunstein, C. R. (2021). *Noise: A Flaw in Human Judgment*. New York: Little, Brown Spark.

- Kakhbod, A., Kazempour, S. M., Livdan, D., & Schürhoff, N. (2023). Finfluencers. Swiss Finance Institute Research Paper No. 23-30.
- Kaniel, R., & Parham, R. (2017). WSJ Category Kings – The impact of media attention on consumer and mutual fund investment decisions. *Journal of Financial Economics*, 123(2), 337–356.
- Ke, Z. T., Kelly, B. T., & Xiu, D. (2019). Predicting returns with text data. NBER Working Paper No. 26186.
- Kelly, B. T., & Xiu, D. (2023). Financial machine learning. *Foundations and Trends in Finance*, 13(3–4), 205–363.
- Kelly, B. T., Palhares, D., & Pruitt, S. (2023). Modeling corporate bond returns. *Journal of Finance*, 78(4), 1967–2008.
- Kim, A. G., Muhn, M., & Nikolaev, V. V. (2024). Financial statement analysis with large language models. Chicago Booth Research Paper No. 24-06 / arXiv:2407.17866.
- Kinniry, F. M., Jaconetti, C. M., DiJoseph, M. A., Zilbering, Y., & Bennyhoff, D. G. (2019). Putting a value on your value: Quantifying Vanguard Advisor's Alpha. Valley Forge: Vanguard Research.
- Kirilenko, A. A., & Lo, A. W. (2013). Moore's law versus Murphy's law: Algorithmic trading and its discontents. *Journal of Economic Perspectives*, 27(2), 51–72.
- Kirilenko, A., Kyle, A. S., Samadi, M., & Tuzun, T. (2017). The flash crash: High-frequency trading in an electronic market. *Journal of Finance*, 72(3), 967–998.
- Klein, G. (2007). Performing a project premortem. *Harvard Business Review*, 85(9), 18–19.
- Knight, F. H. (1921). *Risk, Uncertainty and Profit*. Boston: Houghton Mifflin.
- Kritzman, M., Page, S., & Turkington, D. (2010). In defense of optimization: The fallacy of $1/N$. *Financial Analysts Journal*, 66(2), 31–39.
- Lakonishok, J., Shleifer, A., & Vishny, R. W. (1992). The impact of institutional trading on stock prices. *Journal of Financial Economics*, 32(1), 23–43.
- Ledoit, O., & Wolf, M. (2004). Honey, I shrunk the sample covariance matrix. *Journal of Portfolio Management*, 30(4), 110–119.
- Leippold, M., Wang, Q., & Zhou, W. (2022). Machine learning in the Chinese stock market. *Journal of Financial Economics*, 145(1), 64–82.
- Linnainmaa, J. T., Melzer, B. T., & Previtero, A. (2021). The misguided beliefs of financial advisors. *Journal of Finance*, 76(2), 587–621.
- López de Prado, M. (2016). Building diversified portfolios that outperform out of sample. *Journal of Portfolio Management*, 42(4), 59–69.
- López de Prado, M. (2018). *Advances in Financial Machine Learning*. Hoboken: Wiley.
- Lopez-Lira, A., & Tang, Y. (2023). Can ChatGPT forecast stock price movements? Return predictability and large language models. SSRN Working Paper No. 4412788.

- Lopez-Lira, A., Tang, Y., & Zhu, M. (2025). The memorization problem: Can we trust LLMs' economic forecasts? arXiv:2504.14765.
- Loughran, T., & McDonald, B. (2011). When is a liability not a liability? Textual analysis, dictionaries, and 10-Ks. *Journal of Finance*, 66(1), 35–65.
- Malmendier, U., & Nagel, S. (2011). Depression babies: Do macroeconomic experiences affect risk taking? *Quarterly Journal of Economics*, 126(1), 373–416.
- Markowitz, H. (1952). Portfolio selection. *Journal of Finance*, 7(1), 77–91.
- Meehl, P. E. (1954). *Clinical versus Statistical Prediction: A Theoretical Analysis and a Review of the Evidence*. Minneapolis: University of Minnesota Press.
- Mercer (2026). AI in investment management: Moving beyond the pitch – Asset managers' use of AI. Global survey of 131 asset managers, May 2026. New York: Mercer.
- Michaud, R. O. (1989). The Markowitz optimization enigma: Is 'optimized' optimal? *Financial Analysts Journal*, 45(1), 31–42.
- Morningstar (2025a). Robo-Advisor Landscape 2025 (L. A. Tran, D. Culloton, & D. Carter). Chicago: Morningstar Manager Research, 30 January 2025.
- Morningstar (2025b). Mind the Gap 2025: A report on investor returns in the United States. Chicago: Morningstar Research Services (J. Ptak et al.), 13 August 2025.
- Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87–106.
- Niszczoła, P., & Abbas, S. (2023). GPT has become financially literate: Insights from financial literacy tests of GPT and a preliminary test of how people use it as a source of advice. *Finance Research Letters*, 58, 104333.
- Odean, T. (1998). Are investors reluctant to realize their losses? *Journal of Finance*, 53(5), 1775–1798.
- Odean, T. (1999). Do investors trade too much? *American Economic Review*, 89(5), 1279–1298.
- OECD (2021). *Artificial Intelligence, Machine Learning and Big Data in Finance: Opportunities, Challenges and Implications for Policy Makers*. Paris: OECD.
- Puetz, A., & Ruenzi, S. (2011). Overconfidence among professional investors: Evidence from mutual fund managers. *Journal of Business Finance & Accounting*, 38(5–6), 684–712.
- Reher, M., & Sokolinski, S. (2024). Robo advisors and access to wealth management. *Journal of Financial Economics*, 155, 103829.
- Rossi, A. G., & Utkus, S. P. (2020). Who benefits from robo-advising? Evidence from machine learning. SSRN Working Paper No. 3552671.
- Rupprechter, R. (2026a). Investieren in Künstliche Intelligenz: Vom Chip bis zur Anwendung. R&B Wealth Management Working Paper No. 25. Dornbirn: R&B Wealth Management.

- Rupprechter, R. (2026b). Wie viel Schwellenland verträgt ein globales Portfolio? Eine empirische Ableitung der Emerging-Markets-Beimischung nach Markowitz und Black-Litterman. R&B Wealth Management Working Paper No. 30. Dornbirn: R&B Wealth Management.
- Scharfstein, D. S., & Stein, J. C. (1990). Herd behavior and investment. *American Economic Review*, 80(3), 465–479.
- Sharpe, W. F. (1991). The arithmetic of active management. *Financial Analysts Journal*, 47(1), 7–9.
- Shefrin, H., & Statman, M. (1985). The disposition to sell winners too early and ride losers too long: Theory and evidence. *Journal of Finance*, 40(3), 777–790.
- Sheng, J., Sun, Z., Yang, B., & Zhang, A. L. (2025). Generative AI and asset management. Working Paper, May 2025 (ABFER Annual Conference).
- Simon, H. A. (1955). A behavioral model of rational choice. *Quarterly Journal of Economics*, 69(1), 99–118.
- S&P Dow Jones Indices (2026). SPIVA U.S. Scorecard: Year-End 2025 (A. R. Ganti, D. Di Gioia, N. Didio, & L. Flaherty). New York: S&P Global.
- Stiftung Warentest (2025). Geldanlage: Kann KI bessere Renditen erzielen? *Finanztest*, test.de, 4. Dezember 2025.
- Stoic AI (2026). About Stoic AI: Hybrid intelligence for crypto trading since 2015. Company information, stoic.ai (accessed 25 September 2026).
- Taleb, N. N. (2007). *The Black Swan: The Impact of the Highly Improbable*. New York: Random House.
- Tetlock, P. C. (2007). Giving content to investor sentiment: The role of media in the stock market. *Journal of Finance*, 62(3), 1139–1168.
- Tetlock, P. E., & Gardner, D. (2015). *Superforecasting: The Art and Science of Prediction*. New York: Crown.
- Thaler, R. H., & Benartzi, S. (2004). Save More Tomorrow: Using behavioral economics to increase employee saving. *Journal of Political Economy*, 112(S1), 164–187.
- Tversky, A., & Kahneman, D. (1974). Judgment under uncertainty: Heuristics and biases. *Science*, 185(4157), 1124–1131.
- VanEck (2026). VanEck Social Sentiment ETF (BUZZ): Performance as of 31 August 2026. New York: VanEck.
- Welch, I. (2022). The wisdom of the Robinhood crowd. *Journal of Finance*, 77(3), 1489–1527.
- Wermers, R. (1999). Mutual fund herding and the impact on stock prices. *Journal of Finance*, 54(2), 581–622.
- Wu, S., Irsoy, O., Lu, S., Dabrowski, V., Dredze, M., Gehrmann, S., Kambadur, P., Rosenberg, D., & Mann, G. (2023). BloombergGPT: A large language model for finance. arXiv:2303.17564.

- Zhu, C. (2019). Big data as a governance mechanism. *Review of Financial Studies*, 32(5), 2021–2061.
- Zuckerman, G. (2019). *The Man Who Solved the Market: How Jim Simons Launched the Quant Revolution*. New York: Portfolio/Penguin.