

Modernes Asset Management

Wie sich das Asset Management mit Technologie, neuen Datenquellen und künstlicher Intelligenz weiterentwickelt

April 2021



Christian Maschner, CFA
Executive Partner
HQ Asset Management
christian.maschner@hqam.com



Dr. Benjamin Moritz
Executive Partner
HQ Asset Management
benjamin.moritz@hqam.com



Martin Schmitz, CFDS
Executive Partner
HQ Asset Management
martin.schmitz@hqam.com

Dieses Informationsangebot richtet sich ausschließlich an professionelle Anleger im Sinne des § 67 Absatz 2 WpHG.

April 2021

Einleitung

In diesem Artikel beschreiben wir den aktuellen Stand der Asset-Management-Branche, was einen modernen Asset Manager ausmacht und welche Voraussetzungen er benötigt, um erfolgreich zu sein. Schließlich steht die Asset-Management-Branche seit Jahren vor grundlegenden Herausforderungen, welche wir im Detail erklären. Dabei lösen wir uns von den „klassischen“ Fragen und zeigen auf, um welche Punkte es wirklich geht.

Technologie, neue Datenquellen und künstliche Intelligenz verändern die Asset-Management-Branche zum Positiven. Weitere Erfolgsfaktoren für die Zukunft sind eine moderne Arbeitskultur und eine klare und einfache Kommunikation. Wir erläutern die fünf Punkte ausführlich. Sie bieten die optimale Chance für ein Start-Up die Modernisierung der Asset-Management-Branche anzuführen.

Vier Säulen sind die Voraussetzung für eine erfolgreiche Umsetzung: eine Kombination von Finanz-Knowhow, statistischem und Informatik-Knowhow sowie mehrjähriger Branchenerfahrung. Die Gründe erklären wir an einem Beispiel.

Die Asset-Management-Branche – vom Verkäufermarkt zum Käufermarkt

Viele Jahrzehnte war die Geldanlage in Aktien und Anleihen derart gewinnbringend, dass die hohen Kosten der Branche bei den Anlegern nur eine untergeordnete Rolle spielten. Das hat sich heute geändert, unter anderem aufgrund der anhaltend niedrigen Zinsen, aber auch weil viele Anleger heute besser informiert sind. Sie schauen bei vielen Punkten wie etwa den Gebühren genauer hin als je zuvor. Dabei sind drei Themen wichtig:

1. Bessere Performance: aktiv oder passiv?

Anleger schauen immer genauer auf den Mehrwert von Anlagestrategen und Fondsmanagern. Daraus hat sich in den letzten Jahren ein großer Trend zum passiven Investieren entwickelt. Hier werden nach festen Regeln Anlagestrategien entwickelt und meist durch börsengehandelte Exchange Traded Funds (ETFs) investierbar gemacht. Indexanbieter werden zunehmend zu quantitativen Asset Managern. Also Fondsmanager, welche nach strukturierten und transparenten Anlageprozessen investieren.

Der amerikanische Finanzprofessor Campbell Harvey schreibt in einer aktuellen Studie¹, dass alle Anleger in irgendeiner Form „Quants“ seien, weil jeder auf irgendwelche Zahlen schaue. Der Unterschied liege nur darin, ob die Zahlen systematisch ausgewertet würden oder nicht.

Die Schlüsselfrage ist demnach nicht „aktiv oder passiv“, sondern „wer kann am besten die Zahlen systematisch auswerten?“.

2. Günstigere Investmentprozesse: Asset Manager oder Indexanbieter?

Häufig liegen die Produkte der Asset Manager hinter ihrem selbst gesteckten Anlageziel, meist in Form einer Benchmark, weil die Gebühren der Produkte zu hoch sind. Zu dem Schluss kommt unter anderem die Europäische Wertpapier- und Marktaufsichtsbehörde in ihrer im Jahr 2019 veröffentlichten Studie.² Vor Kosten schlagen aktive Fonds im Durchschnitt ihre Benchmarks sowie

¹ Harvey (2021)

² Derenzis (2019)

passive Produkte. Nach Kosten nicht mehr. Die Produktgebühren sind also nach wie vor zu hoch. Und das obwohl die Analysten von Morningstar, einem unabhängiges Beratungsunternehmen im Bereich Geldanlage, zeigen, dass die Produktgebühren, und damit die Einnahmen der Asset Manager, seit Jahren stetig fallen.³ Das führt bei europäischen Asset Managern in der Breite zu einem dauerhaften Margendruck, denn die Ausgaben sind nach wie vor hoch und steigen sogar kontinuierlich an, wie die Analysten von McKinsey in ihrer Studie schreiben.⁴

Da die Nachfrage nach unterschiedlichen, systematischen Anlagestrategien weiterhin hoch ist, greifen Anleger zunehmend zu günstigeren ETFs von Indexanbietern. Es gibt Stand Oktober 2020 mehr als 3 Millionen Finanzindizes weltweit laut der jährlichen Erhebung der Index Industry Association (IIA).⁵ Zudem zeigen Wissenschaftler in einer aktuellen Studie, dass ETFs zunehmend „aktiv“ werden.⁶

Allerdings muss das für den Investor nicht in jedem Fall ein Vorteil sein. Unter diese Kategorie fallen auch die „Smart Beta“ Strategien der Indexanbieter, welche zum Beispiel eine Value-Strategie verfolgen. Diese Smart-Beta-Indizes liefern im Durchschnitt in der historischen Rückrechnung einen Mehrwert, jedoch nicht mehr ab dem Zeitpunkt der Indexveröffentlichung, wie ein Team an Wissenschaftlern zeigt.⁷ Zusätzlich leiden Indexstrategien unter hohen versteckten Kosten, wie der Wirtschaftswissenschaftler Lasse Heje Pedersen aufzeigt.⁸ Darunter fallen beispielsweise implizite Kosten aus der Indexaufnahme oder -ausschlüsse einzelner Aktien oder Anleihen aus dem Index.

Die Schlüsselfrage ist demnach nicht „Asset Manager oder Indexanbieter“, sondern „wer kann gleichzeitig einen erstklassigen Investmentprozess anbieten und dabei die Kosten niedrig halten?“

3. Individuellere Kundenlösungen: produktzentriert oder kundenzentriert?

Die Bedürfnisse der Anleger sind sehr unterschiedlich. Asset Manager müssen umdenken, vom Fokus auf das Produkt zum Fokus auf den individuellen Investor, schrieb Professor Lionel Martellini bereits im Jahr 2016.⁹ In der Fachsprache nennt man das: „mass customization“. Laut Professor Martellini stellt dabei die Skalierbarkeit von Investmentprozessen eine technische Herausforderung dar.

Skalierung war schon immer das Ziel von Plattformlösungen. Analysten von Gartner, einem Anbieter von Marktforschungsanalysen, schreiben in ihrem aktuellen Report, wie sich die weltweit führenden Data Science Plattformen entwickeln und immer weiter die Skalierbarkeit verbessern.¹⁰

Die Schlüsselfrage ist nicht „produktzentriert oder kundenzentriert“, sondern „Wer bietet einen erstklassigen Investmentprozess, bei niedrigen Kosten und vor allem individuell an?“

³ Boyadzhiev and Garcia-Zarate (2020)

⁴ Azed et al (2019)

⁵ <http://www.indexindustry.org/2020/10/28/fourth-annual-ii-a-benchmark-survey-reveals-significant-growth-in-esg-amid-continued-multi-asset-innovation-heightened-competition/>

⁶ Easley et al (2021)

⁷ Huang, Song, Xiang (2020)

⁸ Pedersen (2018)

⁹ Martellini (2016)

¹⁰ Idoine et al. (2020)

Die besonderen Chancen eines Start-Ups

Der große Vorteil eines Start-Ups ist, dass es direkt und ohne Barrieren neue Wege gehen kann. Wir haben bei der Gründung von HQ Asset Management im Jahr 2018 die zu der Zeit bestmöglichen Lösungen für die drei Kernherausforderungen angestrebt und im Detail den Fokus auf die Verbesserung / die Einführung von 5 Punkten gelegt:

1. Arbeitskultur: mehr Kollaboration, weniger Silo-Organisation
2. Technologie: höhere Skalierbarkeit, maximale Flexibilität und niedrigere Kosten
3. Alternative Daten: neue Daten für neue Informationen
4. Künstliche Intelligenz (KI): komplexere Methoden zur Datenauswertung
5. Kommunikation: klare und einfache Kommunikation

Der Einsatz von Technologie und KI benötigt jahrelange Asset Management-Expertise

Professor Campbell Harvey schreibt in seinem aktuellen wissenschaftlichen Beitrag¹¹: “Technology alone, however, does not increase the probability of outperformance: outperformance depends on the skills of the team who are applying the technology to the investment problem.”.

Das CFA Institute schreibt im Jahr 2019 in einem Artikel mit dem Titel „Investment professional of the future“ wie sich die Skills und Teamstruktur im Asset Management in der Zukunft ändern werden.¹² Sehr ähnlich zu unserer Sichtweise betonen die Autoren die zunehmende Wichtigkeit eines Teamansatzes und den zunehmenden Einfluss von Statistik- und Informatik-Knowhow in der Branche.

Man benötigt vier Säulen, um erfolgreich zu sein:

1. Finanz-Knowhow
2. Statistik-Knowhow
3. Informatik-Knowhow
4. Mehrjährige Branchenerfahrung

Die erste Säule ist wichtig, um das Problem zu kennen, die zweite, um die Lösung zu kennen, die dritte, um die Dinge zum Laufen zu bringen, und die vierte, um „realitätsnahe“ Produkte zu entwickeln.

Um das Beste aus Technologie und KI herauszuholen, benötigt es demnach ein sehr hohes Fachwissen gepaart mit langjähriger Praxiserfahrung. Aufgrund unserer mehr als 10-jährigen Asset-Management-Historie im Research und beim Management von Publikums- und Spezialfonds im Bereich Einzelaktienselektion und Asset Allocation bringen wir die nötige Erfahrung mit. Unsere heterogene Ausbildung in den Bereichen Wirtschaft, Informatik und Statistik bildet eine optimale Kombination an Fachwissen.

Bei der Frage, wie man nun am besten die Ideen umsetzt, kommt man immer wieder zur gleichen Lösung: eine Plattform. Das bedeutet konkret, dass alle zusammen an und auf einer gemeinsamen Lösung arbeiten und entwickeln – unabhängig von den Aufgaben in einem Unternehmen.

¹¹ Harvey (2021)

¹² Cao, Fender, Stammers, Urwin (2019)

Modernes Asset Management – die Punkte im Detail

1. Arbeitskultur

Der Organisationswissenschaftler und Harvard-Professor Ranjay Gulati schreibt 2007 in einem Artikel mit dem Titel „Silo Busting“: „Unternehmen behaupten, Kundenlösungen anzubieten, aber die meisten sind nicht darauf ausgelegt, diese ohne spezifische Änderungen in der Organisationsstruktur, den Anreizen und den Beziehungen bereitzustellen.“¹³ Übertragen auf das Asset Management bedeutet das, man sollte Teams nicht nach verschiedenen Investmentprozessen einteilen, wie es traditionell gelebt wird. Das hat sonst zur Folge, dass unzählige Aufgaben doppelt erledigt werden müssen, egal ob es nur eine Performancerechnung oder ein KI-Algorithmus ist. Eine Plattform für alle Prozesse ist vor allem auch kosteneffizient und skalierbar. Das bedeutet aber auch, dass es weiterhin Spezialisten für Aktien oder Anleihen gibt. Nur arbeiten beide auf einer Plattform.

Der US-amerikanische Wirtschaftswissenschaftler Henry William Chesbrough schrieb bereits 2003 in seinem Buch „Open Innovation“¹⁴: „Not all the smart people work for us. We need to work with smart people inside and outside our company.“ Früher wurde Forschung und Entwicklung fast ausschließlich intern betrieben. Zusätzlicher Innovationstreiber ist heutzutage die Nutzung externer Informationen.

Wir nutzen beispielsweise Programmierstandards der großen Tech-Unternehmen (Open Standards), die Programmiersprachen R und Python (Open Source), Ideen aus der Forschung (Open Innovation) und frei verfügbare Daten (Open Data). Ein aktuelles Beispiel aus dem Asset Management ist die wissenschaftliche Arbeit von Andrew Chen und Tom Zimmermann.¹⁵ Die beiden Autoren haben ihren gesamten Programmcode zur Berechnung von Faktoren zur Einzelaktienselektion veröffentlicht.

„Silo Busting“ und „Open Innovation“ sind zwei prägende Einflüsse für den Erfolg der Silicon-Valley-Unternehmen. Wir machen uns diese Philosophien zu Nutze.

2. Technologie

Rob Arnott, Campbell Harvey sowie der Nobelpreisträger und Begründer der modernen Portfoliotheorie Harry Markowitz schrieben 2019 sieben Punkte auf, die als Best-Practice im Research dienen sollten.¹⁶ Beim Lesen wird schnell klar: Die Anforderungen sind nur mit moderner Technologie schnell und einfach zu erreichen. Ein Kernpunkt ist, dass die Analysen im Asset Management möglichst robust sein sollen. Oder anders formuliert: Analysten sollen die verschiedenen Stellschrauben im Investmentprozess im Griff haben, mehrere Varianten rechnen und vergleichen.

Der Einsatz moderner Technologien ist nicht nur für die Anwendung von Verfahren aus dem Bereich der künstlichen Intelligenz wichtig, sondern generell. Die Forscher Yun und Zheng konstruieren in ihrer wissenschaftlichen Arbeit aus traditionellen Kennziffern, die sie Geschäftsberichten entnehmen, tausende Fundamentalsignale.¹⁷ Die Autoren wenden 76 verschiedene Änderungsraten und relative Vergleichsgrößen auf jede der 240 Kennziffern an und kommen somit auf 18.240

¹³ Gulati (2007)

¹⁴ Chesbrough (2003)

¹⁵ Chen, Zimmermann (2020)

¹⁶ Arnott, Harvey, Markowitz (2019)

¹⁷ Yan, Zheng (2017)

Fundamentalsignale. Selbst zur monatlichen Berechnung einfacher Investmentstrategien auf Basis der 18.240 Fundamentalsignale reichen einfache Rechnerkapazitäten nicht mehr aus.

Ein Beispiel einer modernen Technologie ist das Cloud Computing. Cloud Computing ist mehr als die Verlagerung von „Investitionskosten“ in „Betriebskosten“. Es ist mehr ein „pay as you go“ System, bei dem man nur das bezahlt, was man nutzt. Man muss nicht die ganze Zeit eine Computerkapazität von 1000 Computern vorhalten, sondern kann diese in wenigen Minuten starten, nutzen und wieder beenden. Das ist nicht nur ökonomisch, sondern auch ökologisch sinnvoll. Mehrere Wissenschaftler der Universität Berkeley veröffentlichten 2009 eine wegweisende Studie dazu.¹⁸

Eine weitere grundlegende Studie war die Arbeit von mehreren Google-Mitarbeitern in 2015.¹⁹ Die Autoren teilen ihre Erfahrungen aus der langjährigen Arbeit bei Google und schreiben, dass für die Anwendung von künstlicher Intelligenz, der Programmcode für KI eigentlich nur einen sehr kleinen Teil einnimmt. Die größte Arbeit liegt in der gesamten IT-Infrastruktur drumherum, welche riesig und komplex ist.

Seit Jahren liegt ein großer Entwicklungsschwerpunkt der Data Science Plattformen auf der Automatisierung des gesamten Datenanalyseprozesses, indem Techniken des automatisierten maschinellen Lernens (AutoML) genutzt werden.²⁰

Wir nutzen keine externe Data-Science-Plattform, sondern haben eine eigene Plattform entwickelt. Die Gründe dafür sind unter anderem, dass somit eine höhere Flexibilität und Individualität gegeben ist. Ein weiterer wesentlicher Grund liegt in der Tatsache, dass die Plattform genau auf die Problemstellungen im Asset Management zugeschnitten ist. Die Forscher Gordon Leitch und J. Ernest Tanner schreiben in ihrer Studie im Jahr 1991, dass das optimale Auswahlkriterium für das passende Prognoseverfahren individuell nach Anwendungsfall gewählt werden sollte.²¹

Es gibt nicht das eine Auswahlkriterium zur Auswahl von Prognoseverfahren, das anwendungsübergreifend funktioniert. Es gibt nicht das eine Auswahlkriterium, welches für Wetterprognosen, Umsatzprognosen oder Aktienmarktprognosen gleichermaßen eingesetzt werden kann. Es gibt keine allgemeine Lösung, die für alle Industrien gleichermaßen funktioniert. Auch hier ist meist Individualität gefragt. Aus diesem Grund ist es wichtig, eine Plattform individuell für das Asset Management zu entwickeln.

3. Neue Datenquellen

Mit neuen Datenquellen lassen sich Informationen gewinnen, die so bisher nicht einsehbar waren. Die Autoren Denev und Amen geben in ihrem Buch eine aktuelle Übersicht über die große Menge an Daten, welche nützlich sein könnten im Asset Management.²²

Ein Beispiel sind Texte. Textdaten bieten eine zusätzliche Information im Vergleich zu den traditionellen Daten, wie etwa Inflation, Zinsen oder das Kurs-Gewinn-Verhältnis. Texte liefern auch eine Meinung bzw. eine Interpretation. Zeitungsartikel beinhalten die Meinung des Autors in dem jeweiligen Moment.

¹⁸ Fox et al (2009)

¹⁹ Sculley et al (2015)

²⁰ Hutter, Kotthoff, Vanschoren (2019)

²¹ Leitch, Tanner (1991)

²² Denev, Amen (2020)

Die New York Times ist einer der Vorreiter in der Digitalisierung der Texte und hat bereits alle Artikel bis 1850 zurück digitalisiert. Viele andere Texte werden gerade erst noch digitalisiert. Es ist nun möglich, diese Daten maschinell einfach auszuwerten. Eine Möglichkeit bietet der sehr bekannte Wörterbuch-Ansatz, entwickelt von den Professoren Timothy Loughran und Bill McDonald.²³ Auf Basis der Daten aus der New York Times können interessante Erkenntnisse gewonnen werden. Beispielsweise um den Zusammenhang zwischen Rendite und Risiko im Aktienmarkt zu analysieren.²⁴

Die Textdatenanalyse gewinnt zunehmend an Bedeutung. Die Wissenschaftler Gentzkow, Kelly und Taddy schreiben in ihrem Übersichtsartikel in 2020: „Both the availability of text data and the frontier of methods are expanding rapidly, and we expect the importance of text in empirical economics to grow“.²⁵ Aktuelle Studien liefern Erklärungen und zeigen Prognoseansätze auf, die so vorher nicht möglich waren. Die Autoren Bybee, Kelly, Manela und Xiu messen den Zustand der US-amerikanischen Volkswirtschaft auf Basis von Textanalysen von Wirtschaftsnachrichten von 1984 bis 2017.²⁶ In einer weiteren aktuellen Studie zeigen die Wissenschaftler Ke, Kelly Xiu, wie man mit Textanalyse erfolgreiche Investmentstrategien in der Einzelaktienselektion konstruieren kann.²⁷

4. Künstliche Intelligenz

Bruce Jacobs and Kenneth Levy gehören zu den Pionieren im quantitativen Asset Management. Im Jahr 1989 schreiben Sie in einem wissenschaftlichen Artikel, dass der Aktienmarkt ein komplexes System sei und einfache Regeln wie „Kaufe nur Aktien mit kleiner Marktkapitalisierung“ nicht ausreichend seien.²⁸ Sie schreiben, dass der Aktienmarkt aus einem Netz vieler miteinander verbundener Effekte bestehe und dass substanzielle Rechenpower benötigt werde, um die Effekte zu entwirren.

Der US-amerikanische Wissenschaftler John Cochrane stellte 2011 entscheidende Fragen zu den Faktoren im Aktienmarkt.²⁹ Ist Value ein wichtiger Faktor? Oder ist Momentum ein Faktor? Sind die beiden unabhängig voneinander? Wie viele Faktoren gibt es? Kenneth French und der Nobelpreisträger Eugene Fama kamen in ihrem Fünf-Faktor-Modell im Jahr 2015 ebenfalls an die Grenze.³⁰ Sie konnten mit den bestehenden statistischen Verfahren aus den 1970er Jahren³¹ nur schwer die Effekte der fünf Faktoren voneinander trennen. Das Problem war, dass Wissenschaftler mittlerweile über 300 Faktoren identifiziert hatten³². Neue Methoden wurden benötigt.

Etwa 25 Jahre nach der Arbeit von Bruce Jacobs and Kenneth Levy und drei Jahre nach der Arbeit von John Cochrane waren Benjamin Moritz (heute: HQ Asset Management) und Tom Zimmermann (heute: Professor an der Universität zu Köln) 2013 die ersten, die den Nutzen von Künstlicher Intelligenz in der Aktienselektion in einer umfangreichen Studie untersucht haben.³³ Die Ergebnisse waren sehr gut, mit Blick auf das Rendite-Risiko-Profil der Strategie. Seitdem wurde die Arbeit regelmäßig international auf Konferenzen und bei Unternehmen vorgestellt und diskutiert. Die Arbeit

²³ Loughran, McDonald (2011)

²⁴ Moritz (2018)

²⁵ Gentzkow, Kelly, Taddy (2019)

²⁶ Bybee et al (2020)

²⁷ Ke, Kelly, Xiu (2019)

²⁸ Jacobs, Levy (1989)

²⁹ Cochrane (2011)

³⁰ Fama, French (2015)

³¹ Fama, MacBeth (1973)

³² Harvey, Liu, Zhu (2016)

³³ Moritz, Zimmermann (2014)

wurde 2015 mit dem Best Paper Award auf der Jahreskonferenz der Deutschen Gesellschaft für Finanzwirtschaft ausgezeichnet. Bis heute wurde die Studie über 70-mal zitiert.³⁴

Die Methode „Random Forest“ wurde bereits im Jahr 2001 von Leo Breiman entwickelt.³⁵ Der Random Forest selber basiert auf Entscheidungsbäumen, welche das erste Mal sogar schon 1963 publiziert wurden.³⁶

Im Bereich Einzelaktienselektion gibt es heute immer mehr Studien, die den Methoden der künstlichen Intelligenz eine Überlegenheit in der Kursprognose bescheinigen³⁷. Ebenso in der Unternehmensanleihseselektion³⁸, Staatsanleihenallokation³⁹, Asset Allocation⁴⁰ und Volatilitätsprognose⁴¹. Künstliche Intelligenz wird weiterhin zunehmend bei vielen weiteren Prozessschritten, wie auch der Portfoliooptimierung, eingesetzt.⁴²

Methoden der klassische Finanzökonomie werden in Zukunft aber nicht komplett von Methoden der künstlichen Intelligenz verdrängt. Insbesondere bei der Datenanalyse, der Überprüfung von ökonomischen Hypothesen und bei einfachen Zusammenhängen wird die Finanzökonomie weiterhin genutzt. Eine Übersicht zum Vergleich der beiden Ansätze liefern die Wissenschaftler Cerniglia und Fabozzi.⁴³

Wir bei HQAM nutzen Verfahren der künstlichen Intelligenz und haben diese zur Marktreife entwickelt. Wir setzen dabei unter anderem auch die sieben Anforderungen aus dem bereits zitierten Artikel von Rob Arnott, Campbell Harvey und Harry Markowitz aus 2019 um.⁴⁴ Wir investieren viel Zeit in die Datenarbeit (in der Aktienselektion sind es mehr als 200 Faktoren für jede Aktie der Welt) und Investierbarkeit (niedriger Turnover, niedriger Transaktionskosten). Wir kontrollieren die Komplexität der KI und dokumentieren jeden einzelnen Backtest, um ein vollumfängliches Bild zu erhalten. Wir berechnen unsere Strategien über viele verschiedene Regionen und Länder, um die Robustheit zu prüfen.

5. Kommunikation

Die Wissenschaftler Burns, O'Connor und Stocklmayer definieren in 2003:⁴⁵ "Science communication is defined as the use of appropriate skills, media, activities, and dialogue to produce one or more of the following personal responses to science: Awareness, Enjoyment, Interest, Opinion-forming, and Understanding."

Gute und einfache Kommunikation ist mehr denn je der Schlüssel zum Erfolg. Große Veränderungen, wie wir sie hier beschreiben, müssen einfach und an Beispielen erklärt werden.

³⁴ Siehe u.a. Cerniglia, Fabozzi, Kolm (2016) und Mullainathan, Spiess (2017)

³⁵ Breiman (2001)

³⁶ Morgan, Sonquist (1963)

³⁷ Rasekhschaffe, Jones (2019), Gu, Kelly, Xiu (2020)

³⁸ Bali et al (2020)

³⁹ Bianchi, Büchner, Tamoni (2021)

⁴⁰ Rapach, Zhou (2020)

⁴¹ Christensen, Siggard, Veliyev (2021)

⁴² de Prado (2018), Guida (2019), de Prado (2020)

⁴³ Cerniglia, Fabozzi (2020)

⁴⁴ Arnott, Harvey, Markowitz (2019)

⁴⁵ Burns, O'Connor, Stocklmayer (2003)

Die Forscherinnen Finale Doshi-Velez und Been Kim schreiben im Jahr 2017 einen Übersichtsartikel über die Interpretierbarkeit von Methoden der künstlichen Intelligenz.⁴⁶ Ein Forschungsfeld, welches aktuell sehr stark vorangetrieben wird. Selbst komplexere Verfahren aus dem Bereich der künstlichen Intelligenz lassen sich mittlerweile interpretieren, wie einfache lineare Regressionen. Das von Friedman im Jahr 2001 entwickelte Verfahren gibt beispielsweise einen sehr guten Einblick über den Effekt von einzelnen Daten auf die Prognose.⁴⁷

Wie Leo Breiman in seiner Arbeit „Statistical Modeling: The two cultures“ im Jahr 2001 zeigt, ist aber nicht nur die Kommunikation zwischen Wissenschaftler und Laie wichtig, sondern auch unter den Wissenschaftlern selbst.⁴⁸ Zur internen und externen Kommunikation haben wir eine umfangreiche Reporting-Pipeline entwickelt, um in jeden Arbeitsschritt der Prozesskette vollen Einblick zu erhalten.

Zusammenfassung

Die Asset-Management-Branche hat sich vom Verkäufermarkt zum Käufermarkt entwickelt.

Um den Anforderungen der Anleger gerecht zu werden, sollte ein moderner Asset Manager drei Aufgaben erfüllen:

1. Bessere Performance
2. Günstigere Prozesse
3. Individuellere Kundenlösungen

Die Chance eines Start-Ups sind:

1. Arbeitskultur
2. Technologie
3. Alternative Daten
4. Künstliche Intelligenz (K)
5. Kommunikation

Man benötigt vier Säulen, um erfolgreich zu sein:

1. Finanz-Knowhow
2. Statistik-Knowhow
3. Informatik-Knowhow
4. Mehrjährige Branchenerfahrung

Literaturverzeichnis

- Arnott, Rob, Campbell R. Harvey, and Harry Markowitz "A backtesting protocol in the era of machine learning" The Journal of Financial Data Science 1.1 (2019): 64-74.
- Azad, Sid, et al. "State of the European asset management industry: Adapting to a new normal" McKinsey & Company (2019).
- Bali, Turan G., et al. "The cross-sectional pricing of corporate bonds using big data and machine learning" Available at SSRN 3686164 (2020).
- Bianchi, Daniele, Matthias Büchner, and Andrea Tamoni "Bond risk premiums with machine learning" The Review of Financial Studies 34.2 (2021): 1046-1089.

⁴⁶ Doshi-Velez, Kim (2017)

⁴⁷ Friedman (2001)

⁴⁸ Breiman (2001)

- Boyadzhiev, Dimitar and Jose Garcia-Zarate "European Fee Study" Morningstar Manager Research (2020)
- Breiman, Leo "Random forests" Machine learning 45.1 (2001): 5-32.
- Breiman, Leo "Statistical modeling: The two cultures (with comments and a rejoinder by the author)" Statistical science 16.3 (2001): 199-231.
- Burns, Terry W., D. John O'Connor, and Susan M. Stockmayer "Science communication: a contemporary definition" Public understanding of science 12.2 (2003): 183-202.
- Bybee, Leland, et al. "The structure of economic news" No. w26648. National Bureau of Economic Research, 2020.
- Cao, Larry, Rebecca Fender, Robert Stammers and Roger Urwin. "Investment professional of the future" CFA Institute (2019).
- Cerniglia, Joseph A., and Frank J. Fabozzi "Selecting Computational Models for Asset Management: Financial Econometrics versus Machine Learning - Is There a Conflict?" The Journal of Portfolio Management 47.1 (2020): 107-118.
- Cerniglia, Joseph A., Frank J. Fabozzi, and Petter N. Kolm "Best practices in research for quantitative equity strategies." The Journal of Portfolio Management 42.5 (2016): 135-143.
- Chen, Andrew Y., and Tom Zimmermann "Open source cross-sectional asset pricing" Available at SSRN (2020).
- Chesbrough, Henry William "Open innovation: The new imperative for creating and profiting from technology" Harvard Business Press (2003).
- Christensen, Kim, Mathias Siggaard, and Bezirgen Veliyev. "A machine learning approach to volatility forecasting" No. 2021-03. Department of Economics and Business Economics, Aarhus University, (2021).
- Cochrane, John H. "Presidential address: Discount rates" The Journal of finance 66.4 (2011): 1047-1108.
- Denev, Alexander, and Saeed Amen "The Book of Alternative Data: A Guide for Investors, Traders and Risk Managers" John Wiley & Sons, (2020).
- Doshi-Velez, Finale, and Been Kim "Towards a rigorous science of interpretable machine learning" arXiv preprint arXiv:1702.08608 (2017).
- de Prado, Marcos M. López. "Advances in financial machine learning" John Wiley & Sons, (2018).
- de Prado, Marcos M. López. "Machine learning for asset managers" Cambridge University Press, (2020).
- Easley, David, et al. "The active world of passive investing" Available at SSRN 3220842 (2021).
- Derenzis "Net performance of active and passive equity UCITS" European Securities and Markets Authority (ESMA): Report on Trends, Risks and Vulnerabilities, No.2, 2019 (2019).
- Fama, Eugene F., and Kenneth R. French "A five-factor asset pricing model" Journal of financial economics 116.1 (2015): 1-22.
- Fama, Eugene F., and James D. MacBeth "Risk, return, and equilibrium: Empirical tests" Journal of political economy 81.3 (1973): 607-636.
- Fox, Armando, et al. "Above the clouds: A Berkeley view of cloud computing" Dept. Electrical Eng. and Comput. Sciences, University of California, Berkeley, Rep. UCB/EECS 28.13 (2009).
- Friedman, Jerome H. "Greedy function approximation: a gradient boosting machine." Annals of statistics (2001): 1189-1232.
- Gentzkow, Matthew, Bryan Kelly, and Matt Taddy "Text as data." Journal of Economic Literature 57.3 (2019): 535-74.
- Gu, Shihao, Bryan Kelly, and Dacheng Xiu "Empirical asset pricing via machine learning." The Review of Financial Studies 33.5 (2020): 2223-2273.
- Guida, Tony "Big Data and Machine Learning in Quantitative Investment" John Wiley & Sons, (2019).
- Gulati, Ranjay "Silo busting" Harvard business review 85.5 (2007): 98-108.
- Harvey, Campbell R. "Foreword: Why Is Systematic Investing Important?" Journal of Systematic Investing (2021).
- Harvey, Campbell R., Yan Liu, and Heqing Zhu "... and the cross-section of expected returns." The Review of Financial Studies 29.1 (2016): 5-68.
- Huang, Shiyang, Yang Song, and Hong Xiang. "The Smart Beta Mirage." Available at SSRN 3622753 (2020).
- Hutter, Frank, Lars Kotthoff, and Joaquin Vanschoren "Automated machine learning: methods, systems, challenges" Springer Nature, (2019).
- Idoine, Carlie, et al. "Magic Quadrant for data science and machine-learning platforms." Gartner, Inc (2020).

- Jacobs, Bruce I., and Kenneth N. Levy "The complexity of the stock market." *The Journal of Portfolio Management* 16.1 (1989): 19-27.
- Kahn, Ronald N. "The future of investment management" CFA Institute Research Foundation, (2018).
- Ke, Zheng Tracy, Bryan T. Kelly, and Dacheng Xiu. "Predicting returns with text data" No. w26186. National Bureau of Economic Research, (2019).
- Leitch, Gordon, and J. Ernest Tanner "Economic forecast evaluation: profits versus the conventional error measures." *The American Economic Review* (1991): 580-590.
- Loughran, Tim, and Bill McDonald "When is a liability not a liability? Textual analysis, dictionaries, and 10-Ks." *The Journal of finance* 66.1 (2011): 35-65.
- Martellini, Lionel "Mass Customization Versus Mass Production - How an Industrial Revolution is About to Take Place in Money Management and Why It Involves a Shift from Investment Products to Investment Solutions." *Journal of Investment Management* 14.3 (2016): 5-13.
- Morgan, James N., and John A. Sonquist. "Problems in the analysis of survey data, and a proposal." *Journal of the American statistical association* 58.302 (1963): 415-434.
- Moritz, Benjamin, and Tom Zimmermann "Deep conditional portfolio sorts: The relation between past and future stock returns." LMU Munich and Harvard University Working paper (2014).
- Moritz, Benjamin "Applications of textual analysis and machine learning in asset pricing" Dissertation LMU, (2018).
- Pedersen, Lasse Heje. "Sharpening the arithmetic of active management." *Financial Analysts Journal* 74.1 (2018): 21-36.
- Rapach, David E., and Guofu Zhou "Time-series and Cross-sectional Stock Return Forecasting: New Machine Learning Methods." *Machine Learning for Asset Management: New Developments and Financial Applications* (2020): 1-33.
- Rasekhschaffe, Keywan Christian, and Robert C. Jones "Machine learning for stock selection." *Financial Analysts Journal* 75.3 (2019): 70-88.
- Sculley, David, et al. "Hidden technical debt in machine learning systems." *Advances in neural information processing systems* 28 (2015): 2503-2511.
- Yan, Xuemin, and Lingling Zheng "Fundamental analysis and the cross-section of stock returns: A data-mining approach." *The Review of Financial Studies* 30.4 (2017): 1382-1423.