Strategische Assetallokation – robuste Portfolios dank maschinellem Lernen

Von Gregor Weiß, Simon Fritzsch, Sascha Neumann und Thomas Wintermantel

Die Folgen der Corona-Krise haben die Bedeutung der richtigen Portfoliokonstruktion für Kapitalanleger verdeutlicht. Vor diesem Hintergrund haben die Autoren ein Verfahren zur Bestimmung einer Strategischen Assetallokation entwickelt, das unter Einsatz maschinellen Lernens eine optimierte Datenanalyse durchführt. Damit konnte im Testzeitraum eine Outperformance gegenüber der zugrunde liegenden Morningstar-Benchmark erzielt werden. Die Identifikation verschiedener Marktregimes und die Berücksichtigung zeitlich unterschiedlicher Abhängigkeiten sowie Schwankungsbreiten innerhalb der Portfoliooptimierung, erwiesen sich dabei auch im Zusammenhang mit den Marktverwerfungen durch Covid-19 als stabilisierend. Red.

Im derzeitigen Niedrig- beziehungsweise Negativzinsumfeld stehen Investoren mehr denn je vor enormen Herausforderungen. Bei einem hohen Anteil an festverzinslichen Wertpapieren müssen Marktteilnehmer mit einem sicheren Kapitalverlust rechnen, wenn sie diesen bis zur Endfälligkeit halten. Das breite Spektrum möglicher Auswirkungen durch die Covid-19-Pandemie erhöht den Grad der Unsicherheit.

Insbesondere Aktieninvestments unterliegen hohen Schwankungen, was durch den rasanten Absturz von Mitte Februar bis Mitte März dieses Jahres und die darauffolgende partielle Erholung eindrucksvoll dokumentiert wurde. Analog zu vergangenen Krisen zeigten sich auch die Abhängigkeiten zwischen verschiedenen Anlageklassen signifikant erhöht. Darüber hinaus konnte man in den letzten Jahren eine Häufung länger andauernder Phasen der Entkopplung der Risiko-Asset-Bewertungen von den Konjunkturerwartungen beobachten.

Insbesondere vor diesem Hintergrund ist für Kapitalanleger eine effiziente Allokation des vorhandenen Risikobudgets unabdingbar. Zusätzlich wird dieser Risikoetat durch sehr hohe regulatorische Anforderungen belastet. Investoren müssen die Grundsatzfrage beantworten, wie adäquate risikoadjustierte Erträge erwirtschaftet werden können.

Strategische Assetallokation mit hoher Komplexität

Die Strategische Assetallokation (SAA) bietet hierfür die geeignete Basis. Mit effizient ausgerichteten Multi-Asset-Strategien partizipiert der Investor rendite-/risikooptimal an der künftigen Marktentwicklung. Ein hoher Diversifikationsgrad verbessert die Erfolgschancen und kann darüber hinaus höhere Schwankungen an den Finanzmärkten sowie Marktanomalien, wie zum Beispiel Negativzinsen, Entkopplung der Bewertungsmaßstäbe von der Konjunktur und erhöhte Korrelationen zwischen sicheren und Risiko-Assets kompensieren. Die Modellierung sieht sich dadurch mit einer hohen Komplexität konfrontiert. Einerseits soll die er-

Prof. Dr. Gregor Weiß, Inhaber der Professur für Betriebswirtschaftslehre/ Nachhaltige Finanzdienstleistungen, insb. Banken, Universität Leipzig

Simon Fritzsch, Doktorand, Universität Leipzig

Dieser Artikel ist urheberrechtlich geschützt. Die rechtliche Freigabe ist für den Abonnenten oder Erwerber ausschließlich zur eigenen Verwendung.
Fritz Knapp Verlag GmbH

wartete Portfoliorendite maximiert, andererseits aber auch ein gegebenes Risikobudget nicht überschritten werden. Die dafür erforderlichen Optimierungen reagieren jedoch empfindlich auf Schätzfehler. Portfoliogewichtungen auf Basis vereinfachter Optimierungen weisen darüber hinaus häufig hohe Konzentrationen auf.

In diesem Beitrag wird daher ein SAA-Modell beschrieben und analysiert, das bei der Implementierung auf moderne Tools und Algorithmen aus der interdisziplinären Data Science setzt. Dieses Wissenschaftsfeld bezweckt die Extraktion von Wissen aus Daten. Dabei kommen unter anderem maschinelles Lernen, Vine-Copulas und Robustes Sampling zum Einsatz.

Die hier dargestellte Strategische Assetallokation verfolgt die allgemeine Zielstellung, für verschiedene Marktphasen optimal aufgestellt zu sein, um risikoadjustiert eine Überrendite gegenüber Vergleichsmaßstäben zu erwirtschaften. Ein vorgegebenes Risiko darf dabei nicht überschritten werden. Als Risikomaß dient der kohärente historische Expected Shortfall (Conditional Value-at-Risk). Die Unsicherheit bezüglich der Inputparameter wird miteinbezogen, indem die Optimierung nicht im Hinblick auf Punktschätzungen, sondern für Schätzbereiche/Regionen durchgeführt wird. Unterschiedliche Abhängigkeiten zwischen den einzelnen Assets in verschiedenen Marktphasen werden berücksichtigt. Damit wird ausdrücklich erhöhten Abhängigkeiten in krisenhaften Marktphasen Rechnung getragen. Für die univarianten Renditeverteilungen müssen im Rahmen einer nichtparametrischen Modellierung keine Verteilungsannahmen getroffen werden. Die daraus resultierenden Verbesserungen in der zugrunde liegenden Datenanalyse und -verarbeitung bieten einen signifikanten Mehrwert. Schließlich werden die Ergebnisse mit einem Out of Sample Backtesting ausgewertet.

Die Ableitung der robusten Strategischen Assetallokation ist in drei Schritte gegliedert.

– Identifizierung verschiedener Marktregimes im Zeitablauf durch Methoden des maschinellen Lernens.

– Ableitung von Szenarien aus den identifizierten Marktregimes unter Berücksichtigung multivariater Abhängigkeiten.

– Berechnung der robusten Assetallokation unter Einbeziehung eines vorgegebenen Risikoparameters (Optimierungsansatz).

Mit maschinellem Lernen gegen den „Fluch der Dimensionalität"

An den Finanzmärkten herrschen im Zeitablauf verschiedene Regimes vor. Diese sind nicht nur durch Erwartungen an Gewinne und Verluste gekennzeichnet, sondern finden auch in der relativen Preisdynamik ihren Widerhall. Insbesondere ist empirisch gut belegt, dass die Korrelationen zwischen verschiedenen Assets in krisenhaften Marktphasen häufig sprunghaft ansteigen. Da Marktregimes nicht direkt beobachtbar sind, nutzen wir einen Cluster-Algorithmus des maschinellen Lernens, um deren unterschiedliche Ausprägungen sowohl auf Basis realisierter Renditen als auch unter Berücksichtigung der zeitdynamischen Abhängigkeiten zwischen verschiedenen Assets zu identifizieren.

Die Integration von Abhängigkeitsstrukturen in eine Portfoliooptimierung erfolgt häufig auf Basis der Kovarianzmatrix, für welche die Anzahl zu schätzender Parameter quadratisch mit der Anzahl an Assets wächst. Viele Ansätze auf Grundlage der Kovarianzmatrix, wie zum Beispiel die klassische Markowitz-Optimierung oder Gaussian Mixture Models, stoßen deshalb schon bei einer niedrigen zweistelligen Anzahl von Assets an ihre Grenzen.

Dieses Phänomen ist bekannt unter dem Namen „Fluch der Dimensionalität" und ist verantwortlich für eine hohe Varianz der Schätzungen. Um in unserer Strategischen Assetallokation eine hohe zweistellige oder auch dreistellige Anzahl von Anlageobjekten berücksichtigen zu können, greifen wir deshalb auf eine Methodik des maschinellen Lernens zurück. Dabei handelt es sich um den Netzwerk-Filter-Ansatz TMFG-LoGo.[1] Dieser Algorithmus reduziert die Anzahl zu schätzender Parameter signifikant, indem verrauschte Korrelationen herausgefiltert und nur stabile Abhängigkeiten berücksichtigt werden. Als Ergebnis erhält man eine dünn besetzte inverse Kovarianz-Matrix, welche als Parameter in den nachfolgenden Cluster-Prozess eingeht.

Dies führt auf einen Algorithmus des unüberwachten Lernens mit Namen Inverse Covariance Clustering[2] (ICC) zurück. Dieser stellt eine leichte Abwandlung eines Algorithmus für Elektrofahrzeuge auf den Fall von Finanzdaten dar. Eine Zuordnung von multivariaten Renditen zu einzelnen Regimes erfolgt auf Basis der Mahalanobis-Distanz, eines Abstandsmaßes, welches insbesondere die Schwankungsbreite einzelner Assets sowie Abhängigkeiten zwischen verschiedenen Anlageobjekten berücksichtigt. Zudem ist sichergestellt, dass die Einflüsse besonders volatiler Assets auf die Bestimmung der Marktregimes begrenzt sind.

Dem Algorithmus muss vorab die gewünschte Anzahl der verschiedenen Zustände übergeben werden. Basierend auf Voruntersuchungen berücksichtigen wir vier verschiedene Marktregimes. Die Zuordnung der Beobachtungen zu den einzelnen Zuständen wird,

Dr. Sascha Neumann,
LBBW Asset Management
Investmentgesellschaft mbH,
Stuttgart

Thomas Wintermantel,
LBBW Asset Management
Investmentgesellschaft mbH,
Stuttgart

Dieser Artikel ist urheberrechtlich geschützt. Die rechtliche Freigabe ist für den Abonnenten oder Erwerber ausschließlich zur eigenen Verwendung.
Fritz Knapp Verlag GmbH

Abbildung 1: Allokationsergebnisse im Zeitablauf

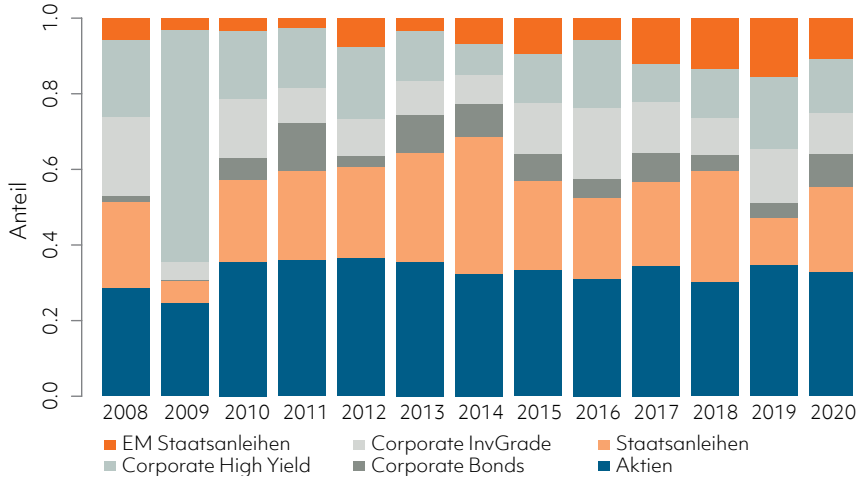

Quelle: Prof. Dr. G. Weiß, S. Fritzsch, Dr. S. Neumann, T. Wintermantel

ausgehend von einer zufälligen Zuteilung, in wiederholten Durchläufen optimiert. Um die Persistenz von Regimes im Markt abzubilden, kann dabei über einen zusätzlichen Parameter Einfluss auf die durchschnittliche Verweildauer innerhalb eines Zustands genommen werden. Als Ergebnis dieses „effizienten Clusterns" ergibt sich eine Zeitreihe von aussagekräftigen Regimes. Darauf aufbauend werden im nächsten Schritt verschiedene Szenarien modelliert.

Ableitung von Szenarien aus den identifizierten Marktregimes

Im Folgenden werden aus der Zeitreihe der identifizierten Marktregimes-Szenarien abgeleitet, indem die multivariate Verteilung rollierender 1-Jahres-Renditen innerhalb eines jeden Regimes modelliert werden. Analog der Identifizierung der Marktregimes wird auch zur Modellierung der Szenarien ein nicht-parametrischer Ansatz gewählt. Dazu bildet man zunächst die multivariate Abhängigkeitsstruktur getrennt von den Randverteilungen der einzelnen Assets über Vine-Copulas ab. Für die univariaten Renditeverteilungen der einzelnen Assets wurden keine Verteilungsannahmen getroffen, sondern diese auf Basis ihrer empirischen Verteilungen modelliert.

Folgende Adjustierung der historischen Erwartungswerte als Inputparameter erweist sich als eine realistische und faire Einschätzung der zukünftigen Performance: Die ex-ante Nettoperformance für Anleihen setzen wir auf deren aktuelle Effektivverzinsung. Im Falle der Aktien wird auf die aktuelle effektive Rendite hochrentierlicher Unternehmensanleihen zuzüglich einer historisch beobachtbaren Risikoprämie von zwei Prozent abgestellt. Die Eintrittswahrscheinlichkeiten der einzelnen Szenarien bestimmen sich nach der relativen Häufigkeit der korrespondierenden Marktregimes.

Berechnung der robusten Assetallokation

Im letzten Schritt soll – ausgehend von den einzelnen Szenarien – eine robuste Assetallokation abgeleitet werden, welche die Einhaltung eines vorgegebenen Risikobudgets sicherstellt. Dazu werden entsprechend den Eintrittswahrscheinlichkeiten aus den einzelnen Szenarien insgesamt 10 000 Erwartungswertvektoren für die Gesamtheit der berücksichtigten Anlageobjekte simuliert. Für jeden dieser Erwartungswertvektoren wird anschließend eine Assetallokation abgeleitet, welche die erwartete Rendite unter der Nebenbedingung maximiert, dass der historische Expected Shortfall (Conditional Value-at-Risk) eine vorab festgelegte Risikoschranke nicht übersteigt.

Das herangezogene Risikolevel wird aus dem historischen Risiko des Vergleichsmaßstabes abgeleitet. Als Vergleichsmaßstab dient im Backtesting die Benchmark der Morningstar-Kategorie „Global Flexible Allocation – Euro", welche globale Anlagen aus der Sicht eines Euro-Investors beinhaltet.[3)] Der Vergleichsmaßstab setzt sich grob aus 50 Prozent globalen Aktieninvestments und 50 Prozent Investments in festverzinsliche Wertpapiere zusammen. Die Strategische Assetallokation ergibt sich nun als Durchschnitt der optimalen Portfoliogewichte für jeden der simulierten Erwartungswertvektoren.

Es ergibt sich mithin eine Allokation, welche nicht nur im Hinblick auf verschiedene Szenarien optimiert ist, sondern auch verschiedene Abhängigkeiten und Schwankungsbreiten innerhalb dieser Szenarien berücksichtigt. Weiterhin ist das beschriebene Vorgehen flexibel genug, um bei Bedarf auch weitere Nebenbedingungen integrieren zu können. Die Ergebnisse stellen sich für variierende Risiken sehr robust dar.

Die Vorgehensweise bei der Ergebnisinterpretation und Resultatseinordnung entspricht einer Modellevaluation mittels eines Out of Sample Backtestings. Das Modell wird mittels eines Trainingsdatensatzes kalibriert und über einen Testdatensatz validiert. Zur Kalibrierung wird der Zeitraum der Jahre 2001 bis 2007 genutzt. Die darauf basierende Ergebnisallokation stellt die Strategische Assetallokation für das Jahr 2008 dar. Das Jahr 2008 ist damit der erste „Test-Zeitraum" und das Modell geht ab diesem Zeitpunkt „live". Es findet ein monatliches Rebalancing statt. Danach wird das Modell in einem jährlichen Turnus neu kalibriert. Dabei wird der Kalibrierungsdatensatz jeweils um ein Jahr verlängert. Das Modellergebnis der Jahre 2001 bis

Abbildung 2: Portfolioeffizienz der SAA im Testzeitraum

	Performance p.a.				Risiko (Basis: Gesamtzeitraum)		
Allokation	1Yr	3Yr	5Yr	Gesamt (12,33 Yr)	Volatilität p.a.	Max Drawdown	Exp. Shortfall 95% Confidence p.a.
Modell	3,0	4,0	4,4	8,6	6,8	17,5	16,3
Benchmark	0,2	3,6	3,6	5,8	8,5	24,7	21,2

in Prozent

Quelle: Prof. Dr. G. Weiß, S. Fritzsch, Dr. S. Neumann, T. Wintermantel

Dieser Artikel ist urheberrechtlich geschützt. Die rechtliche Freigabe ist für den Abonnenten oder Erwerber ausschließlich zur eigenen Verwendung.
Fritz Knapp Verlag GmbH

2008 bietet die Ankerallokation für das Jahr 2009 und so fort.

Höhere Portfolioeffizienz im Testzeitraum

Abbildung 1 zeigt die Allokationsergebnisse im Zeitablauf, jeweils zum Jahresbeginn nach einer Neukalibrierung des Modells, heruntergebrochen auf die angezeigten Hauptassetklassen. Die eigentliche Modellierung ist mit 29 zugrunde liegenden Indizes deutlich granularer.

Die vergleichsweise hohe Quote der High Yield Corporates in 2009 lässt sich gut erklären. Das Verhältnis zwischen Risiko und Rendite war in dieser Assetklasse zum damaligen Zeitpunkt besonders attraktiv.

Der schließlich auf diesen Modellallokationen basierende Wertepfad generiert im Testzeitraum eine deutliche Outperformance gegenüber dem Verlauf der gewählten Morningstar-Benchmark (Abbildung 3). Das ex-post generierte Risikoprofil der Modellallokation weist dabei weniger Risiko als die Benchmark auf. Damit erreicht die Modellallokation eine deutlich höhere Portfolioeffizienz im Testzeitraum. Abbildung 2 beinhaltet die relevanten Kennzahlen.

Die Outperformance baut sich sukzessive auf. Über den gesamten Betrachtungszeitraum liegt die relative Überrendite bei 36,4 Prozent (~durchschnittlich 2,6 Prozent pro Jahr). Das Risikoprofil der Modellallokation generiert maximale Performancechancen und bleibt unterhalb des Benchmarkniveaus. Zudem weist die Strategische Assetalokation in der aktuellen Corona-Krise vergleichsweise robuste Ergebnisse auf. Abbildung 4 zeigt den Verlauf seit Beginn des Jahres im Vergleich zur Benchmark.

Die SAA wurde in dieser Ausarbeitung, zur Gewährleistung der Objektivität, jeweils zu Beginn des Jahres neu berechnet. Bei extremen Veränderungen der Bewertungsniveaus und der relativen Attraktivität der Assetklassen untereinander (insbesondere in Krisen) kann es sinnvoll sein, diese auch ad hoc neu zu berechnen und umzusetzen.

Die Strategische Assetallokation ist als neutraler Ankerpunkt für die optimale Mischung der Assetklassen von zentraler Bedeutung für eine erfolgreiche Portfoliokonstruktion. In diesem Beitrag wird ein neues Verfahren zur Bestimmung einer Strategischen Assetallokation vorgestellt. Basierend auf modernen Methoden der Datenwissenschaften wurde eine optimierte Datenanalyse durchgeführt, die robuste Ergebnisse erzielt. Damit wird eine Performance im Testzeitraum erreicht, die der zugrunde liegenden Morningstar-Benchmark deutlich überlegen ist. Die Outperformance wird passiv erzeugt und baut sich sukzessive über die Zeit auf.

Die Identifikation verschiedener Marktregimes und die Berücksichtigung zeitlich unterschiedlicher Abhängigkeiten sowie Schwankungsbreiten innerhalb der Portfoliooptimierung, erwiesen sich auch im Zusammenhang mit den globalen Marktverwerfungen aufgrund der Covid-19-Pandemie als stabilisierend. Auf diese Weise konnten einerseits Portfolioverluste begrenzt und andererseits eine Partizipation an der darauffolgenden Erholung ermöglicht werden. Weiterhin ist das Modell sehr flexibel bezüglich des zugrunde liegenden Anlageuniversums und einfach erweiterbar um Nebenbedingungen.

Abbildung 3: Ergebnisse der SAA seit März 2008 im Vergleich zur Benchmark, indexiert auf 100 per 31. Dezember 2007

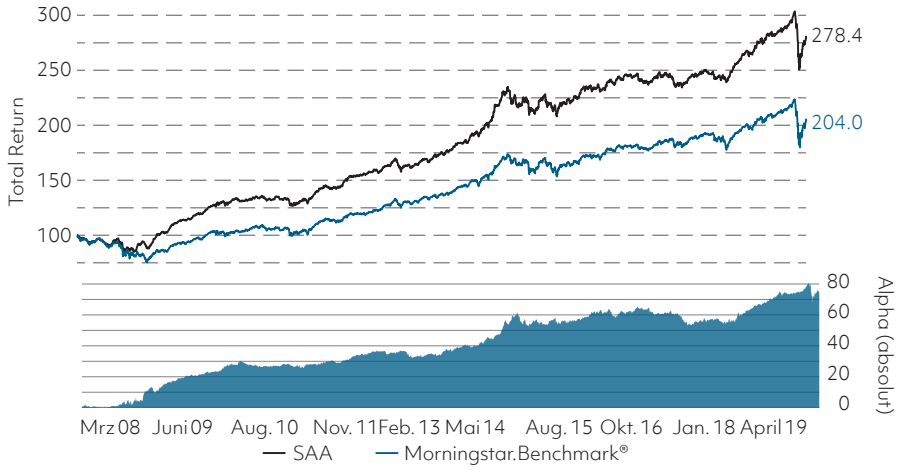

Quelle: Prof. Dr. G. Weiß, S. Fritzsch, Dr. S. Neumann, T. Wintermantel

Abbildung 4: Ergebnisse der SAA seit Januar 2020 im Vergleich zur Benchmark, indexiert auf 100 per 31. Dezember 2019

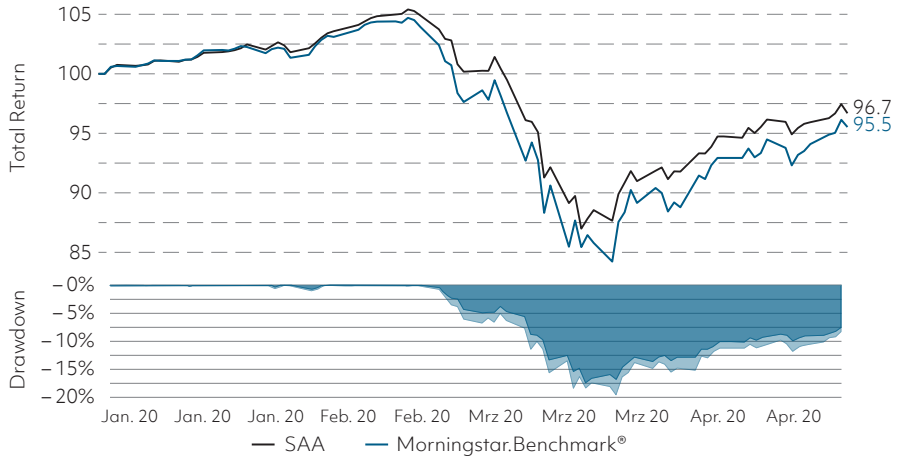

Quelle: Prof. Dr. G. Weiß, S. Fritzsch, Dr. S. Neumann, T. Wintermantel

Fußnoten

1) Massara et al., „Network Filtering for Big Data: Triangulated Maximally Filtered Graph", Journal of Complex Networks, 2016
2) Procacci et al., „Forecasting Market States", Quantitative Finance, 2019
3) Sämtliche der in diesem Beitrag enthaltenen Analysen erfolgen daher ebenfalls aus der Sicht von Euro-Investoren

Dieser Artikel ist urheberrechtlich geschützt. Die rechtliche Freigabe ist für den Abonnenten oder Erwerber ausschließlich zur eigenen Verwendung.
Fritz Knapp Verlag GmbH