

Absolutreport

Neue Perspektiven
institutionelle Investoren

Die
100.

Ausgabe kostenlos
anfordern!

06 | 2017

Neue Perspektiven im Asset Management | Herausforderungen für **Europa** im Jahr 2018
| Nachhaltigkeit im Finanzsektor – **H4SF** | Finanzmathematische Frühwarnsysteme in der
Aktienallokation | **Factor Investing** in der institutionellen Kapitalanlage | **Risiko managen**
– Innovative Ansätze für institutionelle Investoren | **Nowcasting** statt Forecasting



Finanzmathematische Frühwarnsysteme in der Aktienallokation institutioneller Anleger



DR. OLIVER SCHLICK
Lehrstuhl für Finanzmathematik
Technische Universität München



MARKUS WAHL
Lehrstuhl für Finanzmathematik
Technische Universität München



PROF. DR. RUDI ZAGST
Lehrstuhl für Finanzmathematik
Technische Universität München

Investmententscheidungen erfolgen unter Unsicherheit. Um diese weitestgehend zu verringern, haben Dr. Oliver Schlick, Markus Wahl und Prof. Dr. Rudi Zagst, von der Technischen Universität München einen Kapitalmarktseismografen entwickelt, der Wahrscheinlichkeiten verschiedener Szenarien bewertet. Die Autoren beschreiben, wie die Aktienallokation über Algorithmen gesteuert werden kann.

Einleitung

In zwei Dekaden, die durch zum Teil dramatische Finanzkrisen erschüttert wurden, muss die Frage erlaubt sein, wieso uns eigentlich keines der finanzmathematischen oder ökonomischen Modelle vor diesen Negativentwicklungen gewarnt hat. Ist dies so? Was können solche Modelle leisten und was nicht? In diesem Artikel soll versucht werden, der Antwort auf diese Fragen ein wenig näher zu kommen. Da eine allumfassende Behandlung natürlich nicht möglich ist, soll am Beispiel sogenannter Markov-Switching-Modelle gezeigt werden, wie ein Frühwarnsystem für Marktturbulenzen aussehen könnte und welche Informationen wir daraus ableiten

können. Anschließend wird anhand einer empirischen Fallstudie gezeigt, wie diese Information im Rahmen einer von ihr gesteuerten quantitativen Investmentstrategie genutzt werden kann.

Spätestens seitdem mit dem Platzen der New-Economy-Blase und der Finanzkrise zwei bedeutende Aktienmarktkrisen die Finanzwelt erschüttert haben ist klar, dass die u. a. im Modell von Black und Scholes (1973) verwendeten klassischen Annahmen einer geometrischen Brownschen Bewegung (GBM) zur Modellierung von Aktienkursen in Krisensituationen i. a. nicht zutreffen. Insbesondere die Annahme einer konstanten Volatilität sowie konstanter Korrelationen der Aktienrenditen über die Zeit hat sich als äußerst zweifelhaft erwiesen. So steigen sowohl die Volatilität als auch die Korrelationen in Krisensituationen zum Teil deutlich an und verhindern damit eine Risikosteuerung genau in den Marktsituationen, in denen die risikomindernden Effekte eines gut diversifizierten Portfolios zum Tragen kommen sollten (Correlation Breakdown).

Für ein risikobewusstes und verantwortungsvolles Portfoliomanagement ist es demnach unumgänglich, das Eintreten möglicher Kapitalmarktkrisen im Rahmen der Asset-Allokation mitzuberücksichtigen. Markov-Switching-Modelle erlauben es, zwischen verschiedenen, also z. B. normalen und turbulenten Marktphasen zu unterscheiden. Diese für viele besonders intuitive Methode der Einführung verschiedener Regime stützt sich auf einen sogenannten Markov-Prozess mit endlichem Zustandsraum, wobei jedem Modellzustand idealerweise ein ökonomisches Marktszenario zugeordnet werden kann. Im Wesentlichen beruht die Verwendung von Markov-Prozessen auf der Annahme, dass die Zukunft des Kapitalmarktes nur von der Gegenwart (dem aktuellen Zustand) und nicht von der Vergangenheit abhängt.

Modelle dieser Art wurden in der Ökonometrie erstmals von Hamilton (1989) vorgeschlagen und durch Diebold et al. (1994) auf den Fall erweitert, dass die Wahrscheinlichkeiten für den Übergang von einem Zustand zu einem anderen von erklärenden Variablen abhängen dürfen. Finanzmathematische Anwendungen dieses Konzepts finden sich u. a. in Chen (2009), wo die Prognostizierbarkeit von Aktienmarktabschwüngen mithilfe makroökonomischer Variablen in einem Modell mit zwei Zuständen untersucht wird. Dabei werden Zinsspreads und Inflationsraten als Indikatoren für den S&P 500 identifiziert. Einer der Marktzustände zeichnet sich durch hohe Renditen bei geringer Volatilität aus, der andere durch geringe Renditen bei hoher Volatilität. Ähnliche Ergebnisse finden sich u. a. in Ang und Bekaert (2002), Ernst et al. (2009), Hauptmann et al. (2014), Maheu und McCurdy (2000) sowie Perez-Quiros und Timmermann (2000). In diesem Artikel wird zunächst das Markov-Switching-Modell und dessen Fitting erläutert (vgl. Hauptmann et al. (2014)). Danach werden die Marktvariablen zur Signalisierung des Übergangs zwischen den Zuständen mittels einer logistischen Regression identifiziert. Schließlich wird gezeigt, wie die Berücksichtigung verschiedener Marktphasen in eine Investmentstrategie mündet, die das Verlustpotenzial im Vergleich zu einem vorgegebenen Benchmark-Portfolio wesentlich reduziert.



Standardlösungen sind keine Kunst.
Lösungen nach Maß dagegen schon.

Als Assetmanager der NORD/LB-Gruppe bieten wir Ihnen das gesamte Leistungsspektrum, das Sie von einer großen Kapitalverwaltungsgesellschaft erwarten – mit dem Gestaltungsfreiraum eines mittelständischen Unternehmens: Maßgeschneiderte Reportingpakete, flexible Investmentmöglichkeiten für langfristige Wertschöpfung, eine IT-Ausstattung auf dem neuesten Stand und eine exzellente persönliche Betreuung heben unser Unternehmen vom Durchschnitt ab. Mehr zu unseren individuellen Lösungen finden Sie unter www.nordlb-am.de.

The Art of Asset Management.

2 Das Modell

Markov-Switching-Modelle (MSM) ermöglichen es, charakteristische Eigenschaften von Aktienrenditen wie z. B. Fat Tails, Aurokorrelationen oder Volatilitätscluster zu berücksichtigen (vgl. Perez-Quiros und Timmermann (2000)). In dem hier verwendeten einfachen Modell mit zwei Marktzuständen nehmen wir an, dass der i. a. unbeobachtbare Systemzustand durch den Prozess $S = (S_t)_{t=1, \dots, T}$ beschrieben wird, wobei der Zustand S_t zur Zeit $t = 1, \dots, T$ die Werte 0 oder 1 annehmen kann. Der Prozess $R = (R_t)_{t=1, \dots, T}$ der monatlichen Aktienrenditen (Log>Returns) im Zustand S_t wird als normalverteilt angenommen mit zustandsabhängiger erwarteter Rendite μ_{S_t} und Volatilität $\sigma_{S_t} > 0$, d. h.

$$R_t = \mu_{S_t} + \sigma_{S_t} \cdot \varepsilon_t, \quad t = 1, \dots, T$$

mit standardnormalverteilten, unabhängig und identisch verteilten Störgrößen ε_t . Verallgemeinerungen sind selbstverständlich möglich (vgl. Perez-Quiros und Timmermann (2000)). Wir nehmen an, dass der Zustandsprozess S durch eine zeithomogene Markov-Kette mit Übergangswahrscheinlichkeitsmatrix

$$\begin{pmatrix} p & 1-p \\ 1-q & q \end{pmatrix}, \quad p, q \in [0,1]$$

mit

$$p = P(S_t = 0 | S_{t-1} = 0), \quad q = P(S_t = 1 | S_{t-1} = 1)$$

gegeben ist. Die Startverteilung der Zustände ist

$$(\delta, 1 - \delta), \quad \delta = P(S_1 = 0)$$

Das Modell ist komplett spezifiziert durch seinen Parametervektor

$$\theta = (p, q, \mu_0, \mu_1, \sigma_0, \sigma_1, \delta)$$

der mit dem Expectation-Maximization-(EM-)Algorithmus geschätzt wird (vgl. Baum et al. (1970), Dempster et al. (1977)). Bezeichnet nun $\hat{\theta}_t$ den mithilfe der bis zum Zeitpunkt t verfügbaren Renditezeitreihe r_1, \dots, r_t geschätzten Parametervektor, dann sind die gefilterten Wahrscheinlichkeiten gegeben durch

$$p_t^j = P(S_t = j | r_1, \dots, r_t; \hat{\theta}_t), \quad j \in \{0,1\}$$

Analog zu Chen (2009) erhalten wir einen Zustand mit niedriger Volatilität ($j = 0$) und einen mit hoher Volatilität ($j = 1$) und nennen den Markt im Zustand $j = 0$ dementsprechend „ruhig“ und den im Zustand $j = 1$ „turbulent“. p_t^j ist also die gefilterte Wahrscheinlichkeit zum Zeitpunkt t für einen turbulenten Markt.

Obwohl z. B. Mittnik und Haas (2008) über gute Ergebnisse in einem einstufigen Modell mit drei Zuständen angewandt auf MSCI-Renditen in den USA und Deutschland berichten, waren die Ergebnisse mit S&P-Renditen in einem einstufigen

Modell eher instabil. Aus diesem Grund wurde hier ein zwei-stufiges Verfahren benutzt.

Während in dieser Klassifizierung ruhige Märkte in der Regel einen positiven Trend besitzen, ist dieser Trend im Fall turbulenter Märkte nicht klar. Daher wenden wir ein zweites MSM-Modell ausschließlich auf die turbulenten Märkte an, d. h. auf die Zeitreihe der Renditen in den Zeitpunkten t mit Zustand $S_t = 1$.

Wir bezeichnen die entsprechenden (turbulenten) Zustände, die nun den ursprünglichen turbulenten Zustand $S_t = 1$ unterteilen mit S_t^D . Dabei erhält der jeweils nach einem gewissen Kriterium bessere Zustand (höherer Rendite-Risiko-Trade-off) den Wert $j = 0$ („positiv turbulent“), der schlechtere den Wert $j = 1$ („negativ turbulent“). So liefert uns das zweite MSM die gefilterten (bedingten) Wahrscheinlichkeiten

$$p_t^{D,j} = P(S_t^D = j | S_t = 1, r_1, \dots, r_t; \hat{\theta}_t), \quad j \in \{0,1\}$$

$p_t^{D,1}$ ist also die gefilterte (bedingte) Wahrscheinlichkeit zum Zeitpunkt t für einen „negativ turbulenten“ Markt. Insgesamt erhalten wir also die folgende Aufteilung:

- ▶ Ruhig (R): Zustand $S_t = 0$ mit Wahrscheinlichkeit

$$p_t^R = p_t^0 = 1 - p_t^1$$

- ▶ Turbulent positiv (TP): Zustand $S_t^D = 0$ mit Wahrscheinlichkeit

$$p_t^{TP} = p_t^1 \cdot p_t^{D,0} = p_t^1 \cdot (1 - p_t^{D,1})$$

- ▶ Turbulent negativ (TN): Zustand $S_t^D = 1$ mit Wahrscheinlichkeit

$$p_t^{TN} = p_t^1 \cdot p_t^{D,1}$$

Damit gilt $p_t^R + p_t^{TP} + p_t^{TN} = 1$, d. h. wir erhalten zu jedem Zeitpunkt t eine vollständige Aufteilung in Wahrscheinlichkeiten, mit denen sich der Markt in den Zuständen ruhig, turbulent positiv und turbulent negativ befindet.

Wie man leicht an den Wahrscheinlichkeiten der Zustände erkennt, ist es das Ziel der folgenden Regression, die Wahrscheinlichkeiten p_{t+1}^1 und $p_{t+1}^{D,1}$ zum Zeitpunkt t vorherzusagen. Dazu werden diese über ein logistisches Regressionsmodell mit einem Vektor von Kovariablen x verbunden:

$$\ln\left(\frac{p_{t+1}^1}{1-p_{t+1}^1}\right) = \alpha_p + \beta_p' \cdot x_t + \varepsilon_{p,t}$$

$$\ln\left(\frac{p_{t+1}^{D,1}}{1-p_{t+1}^{D,1}}\right) = \alpha_D + \beta_D' \cdot x_t + \varepsilon_{D,t}$$

wobei $\alpha_p, \beta_p, \alpha_D, \beta_D$ die Koeffizienten und $\varepsilon_{p,t}$ bzw. $\varepsilon_{D,t}$ entsprechende Störgrößen beschreiben. Entscheidend ist dabei, dass die Werte der Kovariablen zum Zeitpunkt t verwendet werden, um die Wahrscheinlichkeiten für den Zustand im Zeitpunkt $t+1$ und damit die Verteilung der Rendite im Zeitintervall $[t, t+1]$ vorherzusagen.

Herzliche
Gratulation
zur
100.
Ausgabe!

+43 505 8686-0
office@spaengler-iqam.at
www.spaengler-iqam.at

Kompromisslose
Ausrichtung auf
Ihre Ziele

Wir denken und handeln
risikokontrolliert, damit
Sie Ihre Anlageziele
mit höchstmöglicher
Sicherheit erreichen.

SPÄNGLER
IQAM invest

Wissen schafft Vermögen

Wichtige Informationen: Marketingmitteilung. Dieses Dokument stellt kein Angebot und keine Empfehlung zum Kauf oder Verkauf von Finanzprodukten dar und enthält auch keine Aufforderung, ein solches Angebot zu stellen. Die Fonds werden nach dem österreichischen Investmentfondsgesetz verwaltet und in Österreich vertrieben. Die jeweiligen Prospekte sowie allfällige Änderungen wurden gem. § 136 InvFG 2011 veröffentlicht. Die geltende Fassung des Prospekts sowie der Wesentlichen Anlegerinformationen (= Kundeninformationsdokument, KID) liegen in deutscher Sprache bei der Spängler IQAM Invest GmbH, der Depotbank des Fonds sowie bei der Bankhaus Carl Spängler & Co. AG auf und sind im Internet auf der Homepage www.spaengler-iqam.at verfügbar. Bei bestehender Zulassung zum öffentlichen Vertrieb in Deutschland sind diese Dokumente bei der Zahl- und Informationsstelle, der State Street Bank GmbH, München, erhältlich. Für Richtigkeit und Vollständigkeit der Inhalte kann trotz sorgfältiger Recherche und Erfassung sowie verlässlicher Quellen keine Haftung übernommen werden.

3 Modellschätzung

Die Modellparameter des MSM werden nun mithilfe eines Maximum-Likelihood-Ansatzes geschätzt. Da die Zustände der Markov-Kette nicht beobachtbar sind, erfolgt dies über den zur Klasse der Expectation-Maximization-Algorithmen gehörenden Baum-Welch-Algorithmus (vgl. Baum et al. (1970)). **ABBILDUNG 1** zeigt die Schätzparameter des MSM auf Basis einer Zeitreihe der monatlichen Renditen des S&P 500 von Januar 1964 bis Juni 2017.

Es ist gut zu erkennen, wie das Modell in einen ruhigen Markt mit niedriger Volatilität und positivem Trend (ruhig), in einen Markt mit hoher Volatilität und positivem Trend (turbulent positiv) und in einen Markt mit hoher Volatilität und negativem Trend (turbulent negativ) separiert.

Die Kovariablen für die Regression der gefilterten Wahrscheinlichkeiten wurden unter Einbezug eines Expertengremiums auf Basis der verfügbaren gemeinsamen Datenbasis für alle Kovariablen von November 1987 bis September 2011 aus 35 Faktoren (Aktienmarktdaten, Zinssätze, makroökonomische Daten, Frühindikatoren, Rohölpreis, Wechselkurse) ausgewählt. Interaktionen zwischen den Kovariablen wurden dabei durch paarweise Produkte der Faktoren berücksichtigt. Die Relevanz der Kovariablen (und ihrer Interaktionen) wurde über ein Forward-Backward-Verfahren entsprechend dem Akaike-Information-Criterion (AIC) verifiziert (vgl. Fahrmeir (2009)). Seit 2011 sind die Kovariablen konstant geblieben und werden regelmäßig auf notwendige Anpassungen überprüft. Anders als die Kovariablen werden die Koeffizienten der Kovariablen monatlich neu geschätzt.

Die **ABBILDUNG 2** und **3** zeigen die Ergebnisse dieser Regressionen anhand der Datenzeitreihen von November 1987 bis Juni 2017. Die wesentlichen Kovariablen sind die beiden Zinsspreads (US Treasury Constant Maturity Rate 10Y – 3M und 5Y – 3M), der Corporate Bond Spread (Moody's Seasoned Baa Corporate Bond Yield – Moody's Seasoned Aaa Corporate Bond Yield), der OECD Composite Leading Indicator (OECD, Brasilien, China, Indien, Indonesien, Russland, Südafrika), die USD 3-month LIBOR Rate und die annualisierte Volatilität des S&P 500 der letzten 22 Handelstage. Der adjustierte R^2 des Modells aus Stufe 1 (Tabelle 2) beträgt 65,68 %, derjenige der Stufe 2 (Tabelle 3) 70,57 %.

Hier ist u. a. zu erkennen, dass die Wahrscheinlichkeit für einen turbulenten Markt durch einen steigenden OECD CLI Index i. a. reduziert, durch einen steigenden Corporate Bond Spread, eine steigende Volatilität oder durch eine steigende Konvexität der Zinskurve (Termspread 10Y – 3M steigt, Termspread 5Y – 3M fällt) aber i. a. erhöht wird. Durch die bestehenden Interaktionen kann der Einfluss der Faktoren in bestimmten Marktsituationen allerdings auch einmal wechseln.

ABBILDUNG 4 zeigt die Vorhersagen des Modells mit den entsprechenden Wahrscheinlichkeiten (ruhig, turbulent positiv und turbulent negativ) und die Entwicklung des S&P 500 Index für den Zeitraum von Januar 2005 bis Juli 2017. Dabei wird der Zeitraum November 1987 bis Dezember 2004 für eine fixe In-sample-Regression (Lernphase) verwendet. Für jeden neuen Zeitpunkt im Zeitraum Januar 2005 bis Juli 2017 werden die Koeffizienten sequenziell neu geschätzt. Die jeweilige

1 Parameterschätzungen (p. a.) für den S&P 500

Januar 1964–Juni 2017

Ruhig		Positiv turbulent		Negativ turbulent		Gesamt	
μ	σ	μ	σ	μ	σ	μ	σ
0,121	0,086	0,140	0,169	-0,245	0,225	0,079	0,159

Quelle: eigene Berechnungen

2 Ergebnisse der logistischen Regression turbulent versus ruhig

Input-Faktor	β	p-Wert
Konstante	-10,75	0,0000
Termspread 10Y-3M	2,51	0,0002
Termspread 5Y-3M	-2,75	0,0005
OECD CLI	-1,09	0,0172
Corporate Bond Spreads	8,52	0,0000
LIBOR	0,85	0,0010
Hist. Volatilität	0,12	0,0000
Termspread 10Y-3M * Termspread 5Y-3M	-0,08	0,5849
Termspread 5Y-3M * OECD CLI	0,33	0,1368
OECD CLI * Corporate Bond Spreads	1,15	0,0000
Corporate Bond Spreads * LIBOR	-1,29	0,0000

Quellen: Federal Reserve Bank of St. Louis, Global-rate.com, OECD, eigene Berechnungen

3 Ergebnisse der logistischen Regression turbulent negativ versus turbulent positiv

Input-Faktor	β	p-Wert
Konstante	-4,56	0,0000
Termspread 5Y-3M	-0,11	0,7936
OECD CLI	0,38	0,1643
LIBOR	2,24	0,0000
Hist. Volatilität	0,10	0,0001
Termspread 5Y-3M * LIBOR	0,42	0,0108
OECD CLI * LIBOR	-0,98	0,0000
Hist. Volatilität * LIBOR	-0,04	0,0005

Quellen: Federal Reserve Bank of St. Louis, Global-rate.com, OECD, eigene Berechnungen

Zeitreihe läuft dabei also von November 1987 bis zum Vorhersagemonat-1. Der erste Vorhersagemonat ist dabei Januar 2005, der letzte Vorhersagemonat Juli 2017. Für den Out-of-sample-Zeitraum (empirische Datenzeitreihe von Januar 2005 bis Juni 2017) soll nun in einer empirischen Fallstudie die Qualität der Vorhersage anhand einer quantitativen Investmentstrategie getestet werden, die von dieser Vorhersage gesteuert wird.

Bevor wir dies näher ausführen, wollen wir zurückkommen auf unsere Ausgangsfrage, ob ein solches Modell in die Zukunft sehen kann.

In **ABBILDUNG 4** ist gut zu sehen, dass die Jahre 2005 bis 2007 überwiegend ruhig eingestuft werden. In der Terminologie einer Wettervorhersage könnten wir hier von einer hohen Wahrscheinlichkeit für eine Schönwetterperiode reden.

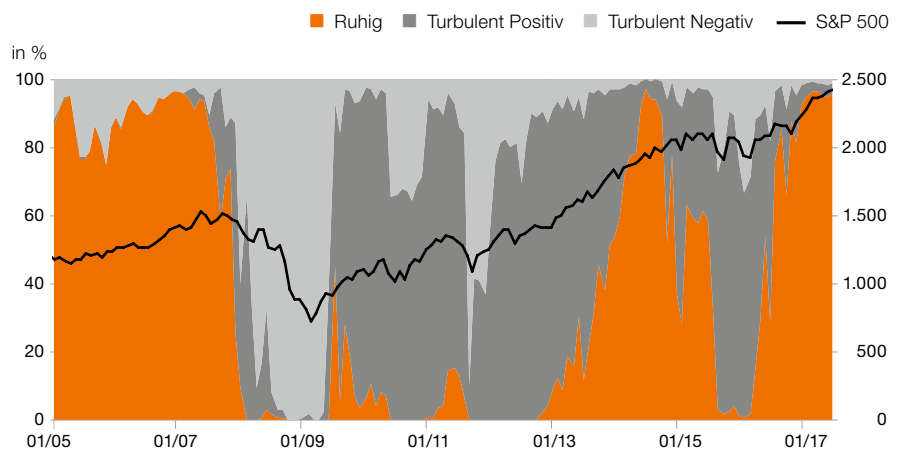
Es bietet sich also an, hinaus an den Kapitalmarkt zu gehen und die Investitionsquote zu erhöhen. Im Gegensatz dazu schlägt die Vorhersage Ende 2007 in eine turbulent negative Phase um. Eine Wettervorhersage, um beim Bild zu bleiben, würde hier also eine hohe Wahrscheinlichkeit für Schlechtwetter angeben. Man sollte sich am Kapitalmarkt also schützen bzw. die Investitionsquote herunterfahren. Ab Mitte 2009 befinden wir uns überwiegend in einem turbulent positiven Markt, das Wetter am Kapitalmarkt ist stürmisch, aber eher trocken. Investieren ist also i. a. gut, man sollte aber den Regenschutz nicht vergessen bzw. nicht zu aggressiv anlegen. In der Folge wechseln sich dann verschiedene Phasen mit Sturmwarnung und schönem Wetter ab.

Die Analogie zur Wettervorhersage wurde ganz bewusst gewählt, da wir von dort Aussagen der Form „die Regenwahrscheinlichkeit beträgt x %“ kennen. So wie dort ist auch am Kapitalmarkt eine exakte Prognose nicht möglich. Auch die Finanzmathematik oder die Ökonometrie kann die Zukunft also nicht mit Sicherheit vorhersagen. All denen, die an dieser Stelle überrascht sind, sei zum Trost eine Aussage des berühmten Ökonomen John Maynard Keynes (1883 – 1946) ans Herz gelegt: „It is better to be roughly right than precisely wrong.“ Interpretieren wir Aussagen mit hoher Wahrscheinlichkeit also als „roughly right“, so können wir uns nun einigermaßen beruhigt der Frage nach einer Investmentstrategie, die diese grob richtigen Aussagen nutzt, widmen.

4 Investmentstrategie

Als Anwendung des MSM wird im Folgenden eine empirische Portfoliostudie durchgeführt. Als Anlagemöglichkeit im Aktienbereich stehen prinzipiell alle Finanzprodukte zur Verfügung, die das Verhalten von Aktienmärkten möglichst exakt nachbilden. Dabei kann grundsätzlich in alle Märkte investiert werden, deren Korrelation zur Leitbörse USA hin-

4 | Vorhersage des Modells



Quelle: eigene Berechnungen

reichend groß ist, und natürlich auch in den US-Aktienmarkt selbst. Als konkrete Anlagemöglichkeit kommen somit ETFs oder sonstige passive Produkte infrage, die beispielsweise den S&P 500, den Stoxx 600 Europe oder den DAX 30 abbilden. Die folgende empirische Untersuchung erfolgte unter der Annahme einer Investition in den europäischen Aktienmarkt (Index: Stoxx 600 Europe).

Die Investmentstrategie setzt nun auf den berechneten Wahrscheinlichkeiten für ruhige, turbulent positive und turbulent negative Märkte auf und achtet dabei sowohl auf die Größen selbst als auch auf ihre Veränderungen. Nach festgelegten Regeln wird anhand dieser Werte die Investitionsquote des Aktienanteils einer Anlage gesteuert. Diese wird ansonsten nur noch durch passive Rentenprodukte ergänzt, die aufgrund von Korrelationseigenschaften europäische Staatsanleihen mit einer maximalen Laufzeit von drei Jahren und der Bonität Investment Grade beinhalten.

Die Steuerung der Investitionsquote erfolgt grundsätzlich anhand der Summe der Wahrscheinlichkeiten für ruhige und turbulent positive Märkte. Dabei wird die maximale Investitionsquote durch diejenige Wahrscheinlichkeitssumme bestimmt, die als hinreichend sicher für einen positiven, zumindest aber neutralen Aktienmarkt erachtet wird. Um zusätzlich dazu noch auf schnelle Veränderungen reagieren zu können, wird eine weitere Regel eingeführt, die bei negativen Änderungen zu einer raschen Desinvestition führt und im positiven Fall für eine etwas zügigere Erhöhung der Aktienquote sorgt.

Um den Erfolg einer solchermaßen ausgestatteten Investmentstrategie messen zu können, bieten sich theoretisch mehrere Möglichkeiten an. Zum einen könnte man als Maßstab ein lineares Ertragsziel angeben, zum anderen eine Benchmark klassischer Prägung. Bei der hier vorgestellten Investmentstrategie handelt es sich allerdings um einen regelgebundenen Ansatz, bei dem nicht vorgesehen ist, sich etwa „neutral“ gegenüber der Benchmark klassischer Prägung zu stellen oder eine vorgegebene Performance am Jahresende zu erzielen. Quasi als Herausforderung in einem eher positiven Markt messen wir hier den Erfolg daran, ob

5 | Empirische Risiko- und Performancemaße

	Messgröße 2005–Juni 2017		Messgröße 2010–Juni 2017	
	Strategie	Benchmark	Strategie	Benchmark
Mittelwert (p. a.)	9,06 %	6,70 %	8,83 %	7,81 %
Standardabweichung (p. a.)	10,67 %	12,97 %	11,81 %	12,71 %
95 %-VaR (10 Tage)	-2,67 %	-3,49 %	-3,02 %	-3,04 %
95 %-CVaR (10 Tage)	-4,04 %	-5,34 %	-4,27 %	-4,71 %
Sharpe Ratio (p. a.)	73,07 %	41,90 %	73,08 %	59,85 %
Maximalverlust (gesamter Zeitraum)	-3,65 %	-42,76 %	-11,87 %	-17,71 %

Quelle: eigene Berechnungen

sich die Performance gegenüber einer Benchmark, die permanent in der maximal zulässigen Aktienquote investiert ist, durch die Wahl des Investmentansatzes verbessern lässt. Darüber hinaus sollen die Risikoeigenschaften verglichen werden.

Grundsätzlich sind mehrere Ausprägungen des Ansatzes möglich, was seinerseits wiederum von der Risikoneigung des Investors abhängt. Im vorgestellten Fallbeispiel wurden die maximal zulässige Aktienquote sowie der in der Benchmark permanent investierte Aktienanteil auf 70% festgelegt. Bei entsprechenden Grün-Signalen kann die Aktienquote temporär auf 80% erhöht werden. **ABBILDUNG 5** zeigt den empirischen Vergleich der Investmentstrategie mit dieser Benchmark im Out-of-sample-Zeitraum Januar 2005 bis Juni 2017.

Es ist leicht zu erkennen, dass die Strategie in allen Kriterien besser abschneidet. Bemerkenswert ist dabei, dass die Strategie auch in den Jahren, die nach der Finanzkrise liegen, in allen Kriterien vorteilhafter ist als die Benchmark (vgl. Zeitraum 2010 – 2017). Es zeigt sich also, dass die vorge-

stellte Investmentstrategie nicht nur krisenhafte Zuspitzungen in ihren Auswirkungen auf die Performance abdämpfen kann, sondern auch Aufwärtsbewegungen des Marktes ausschöpft. Damit unterscheidet sie sich deutlich von Strategien, die ihren Hauptfokus auf Verlustvermeidung gerichtet haben.

Die Möglichkeit, zumindest ein grobes Bild über die Zukunft zu malen, lässt sich also durchaus innerhalb einer quantitativen Investmentstrategie zur Ertragssteigerung bzw. Risikoreduktion nutzen.

Fazit

In diesem Artikel wurde ein zweistufiges Markov-Switching-Modell mit jeweils zwei Zuständen an die Daten des S&P 500 Aktienindex angepasst. Die Übergangswahrscheinlichkeiten zwischen den verschiedenen Marktzuständen wurden durch verschiedene Kovariablen erklärt, die hinsichtlich ihres Erklärungsgehalts getestet und ausgewählt wurden. Eine auf diesem Modell beruhende Investmentstrategie wurde in einer empirischen Fallstudie einer Benchmark gegenübergestellt. Dabei wurde deutlich, dass durch das Markov-Switching-Modell Rendite- und Risikokennzahlen verbessert werden können und bspw. zu einer deutlich höheren Sharpe Ratio führen. Diese Ergebnisse wurden über einen mehr als 10 Jahre umfassenden Testzeitraum erreicht. Die Berücksichtigung der immer häufiger auftretenden Aktienmarktkrisen im Rahmen der Portfoliooptimierung führt so zu einem konservativeren Investmentstil, der besonders in Bärenmärkten überlegen ist, gleichzeitig jedoch auch in der Lage ist, Aufwärtstrends auszuschöpfen.

Literatur

Alexander, C. (2001): *Market Models: A Guide to Financial Data Analysis*. (Wiley & Sons)

Ang, A./Bekaert, G. (2002): International asset allocation with regime shifts. In: *Review of Financial Studies* 15 (4), S. 1137–1187.

Baum, E./Petrie, T./Soules, G./Weiss, N. (1970): A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains. In: *The Annals of Mathematical Statistics* 41 (1), S. 164–171.

Black, F./Scholes, M. S. (1973): The pricing of options and corporate liabilities. In: *Journal of Political Economy* 81 (3), S. 637–654.

Chen, S.-S. (2009): Predicting the bear stock market: Macroeconomic variables as leading indicators. In: *Journal of Banking & Finance* 33 (2), S. 211–223.

Dempster, A./Laird, N./Rubin, D. (1977): Maximum likelihood from incomplete data via the EM algorithm. In: *J.R. Stat. Soc. Ser. B*, 39, S. 1–38.

Diebold, F. X./Lee, J.-H./Weinbach, G. C. (1994): Regime switching with time-varying transition probabilities. In: C. Hargreaves *Nonstationary time series analysis and cointegration*, *Advanced Texts in Econometrics*, S. 283–302. (Oxford University Press)

Ernst, C./Grossmann, M./Höcht, S./Minden, S./Scherer, M./Zagst, R. (2009): Portfolio selection under changing market conditions. In: *Int. J. Financ. Serv. Manag.* 4, S. 48–63.

Fahrmeir, L./Kneib, T./Lang, S. (2009): *Regression – Modelle, Methoden und Anwendungen*. (2. Auflage, Springer Verlag, Berlin)

Hamilton, J. D. (1989): A new approach to the economic analysis of nonstationary time series and the business cycle. In: *Econometrica* 57 (2), S. 357–384

Hauptmann, J./Hoppenkamps, A./Min, A./Ramsauer, F./Zagst, R. (2014): Forecasting market turbulences using regime-switching models. In: *Financ. Mark. Portf. Manag.* 28, S. 139–164.

J.P. Morgan and Reuters (1996): *Riskmetrics – Technical report*. (J.P. Morgan/Reuters)

Maheu, J. M./McCurdy, T. H. (2000): Identifying bull and bear markets in stock returns. In: *Journal of Business and Economic Statistics* 18 (1), S. 100–112.


Markowitz, H. (1952): Portfolio selection. In: *Journal of Finance* 7 (1), S. 77–91.

Mittnik, S./Haas, M. (2008): Mit gemischten Normalverteilungen gegen Bären. In: *Portf. Inst.*, S. 16–19.

Perez-Quiros, G./Timmermann, A. (2000): Firm size and cyclical variations in stock returns. In: *Journal of Finance* 55 (3), S. 1229–1262

Rockafellar, R. T./Uryasev, S. (2000): Optimization of conditional value-at-risk. In: *The Journal of Risk* 2 (3), S. 21–41.

inhalt 06/2017



kommentare

DR. WOLFRAM GERDES Kirchliche Zusatzversorgungskasse Rheinland-Westfalen
DR. JOCHEN KLEEBERG alpha portfolio advisors GmbH, Kronberg im Taunus

artikel

Neue Perspektiven im Asset Management – Märkte im Wandel
MICHAEL BUSACK Absolut Research GmbH

Nachhaltigkeit im Finanzsektor – Hub for Sustainable Finance
PROF. DR. ALEXANDER BASSEN Universität Hamburg
YVONNE ZWICK Rat für Nachhaltige Entwicklung

Herausforderungen für Europa im Jahr 2018
DR. HEINZ-WERNER RAPP FERI Cognitive Finance Institute

Finanzmathematische Frühwarnsysteme in der Aktienallokation
DR. OLIVER SCHLICK, MARKUS WAHL, PROF. DR. RUDI ZAGST
Technische Universität München

Nowcasting statt Forecasting – ein Plädoyer für systematische Entscheidungsfindung
ALEXANDER INEICHEN IR&M

Factor Investing: Implementierung in der institutionellen Kapitalanlage
DR. HUBERT DICHTL, ULF SCHAD dichtl research & consulting GmbH
PROF. DR. WOLFGANG DROBETZ Universität Hamburg

Risiko managen – Innovative Ansätze für institutionelle Investoren
HERWIG KINZLER, CÄCILIA LUGAUER, MICHAEL SAULER Mercer

drei fragen an

DAVID F. SWENSEN Chief Investment Officer Yale University

Ja, ich möchte den Absolutreport 06/2017 als **kostenloses** Printexemplar anfordern.

Bitte ausfüllen, scannen und senden an:
info@absolut-research.de

Oder online ausfüllen:
www.absolut-report.de/anf100



Absolut Research GmbH
Große Elbstraße 277a, 22767 Hamburg

Vorname/Nachname

Bereich/Funktion

Unternehmen

Straße/Nr.

PLZ/Ort

Tel./Fax

E-Mail

Besuchte Veranstaltung