

Absolutreport

Neue Perspektiven für
institutionelle Investoren



Beitrag in Ausgabe 01|2026

TOBIAS LAUSSER, JOAO EDUARDO VUOLO, PROF. DR. RUDI ZAGST Technische Universität München
UND **PROF. DR. OLIVER SCHLICK** SECARO GmbH/Hochschule der Bayerischen Wirtschaft

Data-Driven Duration Management



Data-Driven Duration Management

Verbesserung von Zinsstrukturprognosen zur
Durationsteuerung durch Machine Learning


TOBIAS LAUSSER

Research Associate am Lehrstuhl
für Finanzmathematik
Technische Universität München
München


PROF. DR. OLIVER SCHLICK

SECARO GmbH
Hochschule der
Bayerischen Wirtschaft
München


JOAO EDUARDO VUOLO

Research Assistant am Lehrstuhl
für Finanzmathematik
Technische Universität München
München


PROF. DR. RUDI ZAGST

Lehrstuhl für Finanzmathematik
Technische Universität München
München

Techniken des maschinellen Lernens gelten als universell einsetzbare Technologie der Zukunft. Institutionelle Anleger stehen in der praktischen Umsetzung jedoch vor Herausforderungen hinsichtlich der Stabilität und Erklärbarkeit solcher Modelle. Am Beispiel der Durationssteuerung zeigt ein Autorenteam der TUM und Hochschule der Bayerischen Wirtschaft, wie eine Verbesserung von Zinsstrukturprognosen durch Machine Learning erfolgen kann.

Einleitung

Wer ein Fixed-Income-Portfolio verantwortet, weiß: Veränderungen in der Zinslandschaft ziehen eine Reihe nicht vernachlässigbarer Konsequenzen nach sich. Schon geringe Verschiebungen der Renditekurve wirken sich unmittelbar und gleichzeitig auf mehrere Aspekte des Portfolios aus: die Bewertung des Bestands, die zugehörigen Risikokennzahlen und – bei aktiver Steuerung – natürlich auch auf die Performance.

Die zentrale Steuerungsgröße der für die Performance wichtigen Zinssensitivität ist die Duration, die sich durch gezielte Anpassungen im Portfolio steuern lässt. Diese Anpassungen folgen grundsätzlich einer einfachen Regel: Wer fallende Renditen erwartet und damit steigende Kurse, erhöht die Duration, um stärker zu profitieren. Wer steigende Renditen erwartet und damit fallende Kurse, reduziert die Duration, um das Verlustpotenzial zu begrenzen. Dabei ist allerdings für die Umsetzung nicht nur die Anpassungsregel selbst relevant, sondern vor allem die Verlässlichkeit des zugrunde liegenden Signals.

Die Konstruktion eines solchen verlässlichen Signals mit erklärbarem Verhalten ist Ziel unseres Forschungsbeitrags „Data-Driven Duration Management: Term Structure Forecasting Using Machine Learning“.

Die Qualität und Robustheit des Signals werden dabei nicht nur daran gemessen, ob sich die Zinsstrukturkurve statistisch gut vorhersagen lässt, sondern auch daran, ob die

Prognose in eine belastbare Durationssteuerung übersetzt werden kann. Entsprechend wird die Prognoseleistung im Beitrag konsequent im Anwendungskontext bewertet.

Modelle können in Fehlermaßen stabil erscheinen, ohne in einer implementierten Strategie belastbare Ergebnisse zu liefern. Dies gilt insbesondere dann, wenn Trendwechsel nicht rechtzeitig erfasst werden oder in Stressphasen einzelne große Fehlsignale auftreten. Ein Modell, das im Durchschnitt kleine Fehler macht, kann in genau den wenigen Wochen, die für die Gesamtperformance entscheidend sind, das falsche Signal geben. Für institutionelle Anwendungen sind daher neben der durchschnittlichen Prognoseabweichung auch Richtungstreue, Robustheit und die risikoadjustierte Wirkung im Portfolio maßgeblich.

Im Folgenden wird dargestellt, wie sich dieser Ansatz in der Praxis umsetzen lässt: welche Daten verlässliche Ergebnisse liefern, wie sich die Komplexität der Zinskurve auf relevante Faktoren reduzieren lässt, wie sich zukünftige Entwicklungen effizient vorhersagen lassen und wie aus diesen Vorhersagen eine robuste Duration-Entscheidung gewonnen wird. Dabei werden auch die Umsetzungsschritte beachtet, die typischerweise organisatorische Anforderungen umfassen – von Datenrevisionen bis hin zu Governance und Monitoring. Ziel ist ein Praxistext, der sich als arbeitsfähige Grundlage für kommende Projekte eignet.

Von der Zinskurve zur Datenpipeline

Eine belastbare Anwendung datengetriebener Modelle setzt eine konsistente Datenbasis und klar definierte Aufbereitungsschritte voraus. In dem hier vorgestellten Ansatz werden wöchentliche Zero Rates für sieben Standardlaufzeiten verwendet: 3M, 6M, 1Y, 2Y, 3Y, 5Y und 10Y. Die Entscheidung dafür ist darin begründet, dass die wöchentliche Frequenz das sogenannte „weiße Rauschen“ verhindert und das Modell dadurch statt nur kurzfristiger Marktmechanik nachhaltige Dynamiken lernt. Gleichzeitig bleibt das System reaktionsfähig, weil wöchentlich neue Informationen einfließen. Zudem vermeidet man dadurch in der resultierenden Anlagestrategie zu häufige Anpassungen der Allokation, verliert jedoch bei größeren Trendbewegungen nicht die Kontrolle.

Für die Anwendung auf dem europäischen Markt zeigt sich hier bereits die erste Hürde: lange, konsistente Zinskurvenhistorien sind nicht immer verfügbar. Die offizielle Zero-Rate-Kurve für ECB-AAA-Euro-Government-Bonds beginnt erst im Jahr 2004.

Für viele Modelle des maschinellen Lernens, insbesondere solche mit einer großen Anzahl an Parametern wie etwa neuronale Netze, ist die Datenbasis zu kurz – erst recht, wenn man Regimewechsel wie die Niedrigzinsphase, die Negativzinsjahre und die jüngste Zinswende abdecken will.

Wir schlagen daher vor, die ECB-AAA-Kurve über die länger zurückreichende Zinskurve deutscher Staatsanleihen anzunähern und so fortzuschreiben. Im Detail gehen wir folgendermaßen vor: Wir ergänzen zunächst die Zinskurve deutscher Staatsanleihen zu jedem Zeitpunkt anhand des dynamischen Nelson-Siegel-Modells um fehlende Laufzeiten über den gesamten Betrachtungszeitraum und führen anschließend eine lineare Regression der ECB-AAA-Kurve auf deutsche Staatsanleihen in der Überlappungsperiode durch.

Anhand dieses Modells lässt sich anschließend die ECB-AAA-Kurve im Zeitraum vor 2004 approximativ fortschreiben. Damit zeigt sich, dass auch begrenzte Datenhistorien durch Annäherungen und konsistente Imputation fehlender Laufzeiten für die Anwendung datenintensiver Methoden genutzt werden können. Voraussetzungen sind eine transparente Dokumentation der Vorgehensweise sowie ein laufendes Monitoring potenzieller Strukturbrüche.

Neben der Zinskurve selbst können auch makroökonomische Faktoren eine wichtige Rolle spielen, insbesondere in Märkten, in denen Zinsen stark auf Konjunktur- und Inflationsinformationen reagieren. Unser Ansatz betrachtet Makrodaten, die die realökonomische Aktivität und die Inflation beschreiben, wobei explizit auch die Publikationsverzögerung der Daten berücksichtigt wird. Dies ist insbesondere für die spätere operative Nutzung entscheidend. Andernfalls würde das Modell im Backtest auf Daten zugreifen, die in der Realität nicht verfügbar sind, und die Performance wäre dadurch nachhaltig verfälscht.

Daher ist festzuhalten, dass die Modelle, wie sie im Verlauf des Artikels im Backtest verglichen werden, ausschließlich auf Daten zugreifen, die zu den jeweiligen Zeitpunkten in der Vergangenheit tatsächlich verfügbar waren. Die

Modellperformance aus dem Backtest kann somit als gute Annäherung der zu erwartenden Performance bei operativer Nutzung verwendet werden.

Zusammenfassend empfiehlt sich eine datenbezogene Dokumentation, die Definitionen, Quellen, Stichtagslogik, Lags und Bereinigungsregeln nachvollziehbar festlegt und methodisch sicherstellt, dass nur zum Zeitpunkt der Investitionsentscheidung verfügbare Daten einbezogen werden.

Ableitung von Faktoren und Erklärbarkeit

Die Zinskurve ist hochdimensional, folgt in ihrer Dynamik jedoch weitgehend wenigen dominanten Treibern. Ein Großteil der Variation lässt sich typischerweise durch drei Faktoren beschreiben: Niveau (Level), Steilheit (Slope) und Krümmung (Curvature).


Klassische Modelle wie Dynamic Nelson-Siegel (DNS) nutzen diese Erkenntnis, indem sie die Kurve parametrisch beschreiben und zu jedem Zeitpunkt die drei zugehörigen Gewichte der Treiber schätzen. Die Hauptkomponentenanalyse (engl. Principal Component Analysis, PCA) ist eine statistische Standardmethode, die darauf abzielt, die Zinskurve anhand der drei Hauptkomponenten zu beschreiben, die den Großteil der Varianz erklären. Diese entsprechen auch hier dem Level, der Slope und der Curvature. In der Anwendung haben diese Repräsentationen zwei Vorteile: eine deutliche Reduktion der Dimension, was Prognosen stabilisieren kann, sowie eine bessere Erklärbarkeit der Änderungen der Zinskurve, was für Investmentkomitees, das Risikomanagement und das Reporting wichtige Punkte sind.

Einen Schritt weiter geht der Arbitrage-Free Nelson-Siegel-Ansatz (AFNS), der die Nelson-Siegel-Idee in einen No-Arbitrage-Rahmen einbettet und üblicherweise mithilfe eines Kalman-Filters im Kontext eines Zustandsraums geschätzt wird. Damit werden ökonomische Konsistenz und empirische Flexibilität verbunden. Zu beachten ist, dass diese Methode bei der Implementierung aufwändiger ist als DNS oder PCA. Der Einsatz hängt daher auch davon ab, welche Komplexität im jeweiligen institutionellen Umfeld akzeptabel ist. Wo auf Vorwissen im Bereich der State-Space-Modelle zurückgegriffen werden kann, kann AFNS eine sinnvolle Erweiterung darstellen. Für eine robuste Basis sind DNS oder PCA meist ausreichend.

Als alternative Form der Dimensionsreduktion können Autoencoder herangezogen werden. Diese können als nicht-lineare Verallgemeinerung der PCA verstanden werden: Ein Autoencoder mit linearen Aktivierungsfunktionen entspricht im Wesentlichen einer PCA. Zusätzliche Flexibilität entsteht durch nichtlineare Aktivierungsfunktionen. In dem Fall kann ein Autoencoder hochdimensionale Strukturen besser komprimieren, die durch Linearität nur begrenzt erfasst werden können. Die Zeitreihen der Faktorengewichte der verschiedenen Kompressionsmethoden für U.S.-Marktdaten finden sich in **ABBILDUNG 1**.

In unserem Ansatz zeigt sich ein Nutzen insbesondere dann, wenn man versucht statt der Zinskurve die Makrodaten zu komprimieren. Diese sind oft hochdimensional, redundant

1 Zeitreihen der Faktorengewichte verschiedener Kompressionsmethoden für U.S.-Marktdaten



und stark verrauscht. Werden zahlreiche makroökonomische Kennzahlen zur Vorhersage als Eingangsgröße verwendet, steigt das Risiko von Überanpassungen und instabilen Schätzbeziehungen. Ein Autoencoder kann hier zur Extraktion relevanter Signale vorgelagert werden, wodurch eine kompakte Repräsentation relevanter Marktinformationen bereitgestellt wird. Dadurch ergibt sich eine saubere Trennung zwischen der Eingangsinformation und der späteren Vorhersage, was die Testbarkeit und Dokumentation erleichtert.

Für die Kompression der Zinskurve selbst liefern Autoencoder nicht zwangsweise bessere Ergebnisse. Dies deutet darauf hin, dass die wesentlichen Strukturen bei sieben Laufzeiten bereits durch lineare, einfache Modelle gut erklärt werden können. Dahingegen kann ein Autoencoder in anderen Anwendungsfällen, etwa bei mehreren Laufzeiten, mehreren Kurventypen oder bei Aufgaben wie der Szenariogenerierung und Rekonstruktion, an Bedeutung gewinnen. Autoencoder sollten also immer in Betracht gezogen werden, wenn die Dimension hoch und die Struktur potenziell nichtlinear ist.

Sind die Faktoren zur Beschreibung der Zinskurve gewonnen, kann diese kompakte Beschreibung des Kurvenzustands genutzt werden, um diesen Zustand zu zukünftigen Zeitpunkten vorherzusagen.

Auch hier gibt es die Möglichkeit, neben klassischen Methoden wie autoregressiven (AR) oder vektorautoregressiven (VAR) Modellen auch Machine-Learning-Modelle einzusetzen. Genauer gesagt können neuronale Netze verwendet werden, denen als Eingabegrößen die Faktoren übergeben werden, und die daraus entweder die Faktoren selbst oder die Zinskurve zu künftigen Zeitpunkten schätzen.

Im Gegensatz zu klassischen Modellen ist bei neuronalen Netzen die Nutzung makroökonomischer Faktoren als zusätzliche Eingabegrößen problemlos möglich. Durch dieses Vorgehen bleibt das Modell also erklärbar, solange es auf der Ebene der bekannten Faktoren und nicht auf der Ebene der Zinskurve selbst operiert. Eine klare, zur Erklärbarkeit beitragende Trennung findet auch zwischen dem Vorhersagemodell und der Logik der Anlagestrategie statt, die in der Folge erläutert wird.

Von der Vorhersage der Zinskurve zur Steuerung der Duration

Selbst die beste Vorhersage ist nur dann nützlich, wenn sich daraus eine konkrete Handlungsempfehlung ableiten lässt, in unserer Anwendung also eine realistische und erfolgreiche Steuerung der Duration. Wir setzen dafür ein Duration-Overlay ein, das bewusst einfach genug ist, um interpretierbar zu bleiben, aber realistisch genug, um tatsächlich Anwendung zu finden. Wir verwenden unsere Zinskurven-Vorhersagen, um die Ein-Monats-Änderungen der Yields vorherzusagen, und aktualisieren diese wöchentlich. Dies entspricht auch genau der Frequenz der Reallokation des Portfolios. Die Ziel-Duration liegt zwischen 2,5 und 7,5 Jahren und wird durch die Kombination aus Cash (1M T-Bill) und einem 10Y-orientierten Total-Return-Index erreicht. Als Benchmark-Portfolio wird eine konstante 5Y-Duration festgelegt.

Diese Herangehensweise hilft, zwei typische Verzerrungen in Backtest-Analysen zu vermeiden. Erstens wird nicht täglich gehandelt, was Turnover und Kosten in Grenzen hält. Zweitens verhindern die Beschränkungen der Duration, dass das Modell durch extreme Hebelung kurzfristig unrealistisch hohe Gewinne erzielt.

Wer eine Anlagestrategie in der Praxis umsetzen möchte, muss sich in der Regel an Limits wie etwa das Risikobudget halten. Auch der Konflikt zwischen aggressiver Steuerung und Akzeptanz im für Risikosteuerung verantwortlichen Gremium eines Anlegers ist allseits bekannt. Eine Beschränkung der Duration greift beiden Problematiken vor.

In der Bewertung der Ergebnisse fokussieren wir uns nicht nur auf statistische Kennzahlen wie die mittlere quadratische Abweichung (RMSE), die mittlere absolute Abweichung (MAE) oder die durchschnittliche Korrektheit der Vorhersage der Richtungsverschiebung, sondern beziehen auch explizit risikoadjustierte Performance-Kennzahlen der Anlagestrategie wie die Information Ratio (IR), die Omega Ratio und den Maximum Drawdown (MDD) ein. Der Grund dafür ist, dass ein Modell zwar eine statistisch herausragende, aber zugleich ökonomisch unterdurchschnittliche Performance aufweisen kann, was z. B. daran liegen kann, dass es in Trendwenden falsch positioniert ist oder weil wenige Extremereignisse die Performance dominieren. Umgekehrt kann ein Modell mit leicht schlechteren statistischen Merkmalen eine bessere ökonomische Performance liefern, wenn es stabilere Richtungssignale erzeugt. Die Modellauswahl sollte daher auch an portfoliorelevanten Kennzahlen statt ausschließlich an Vorhersagefehlern ausgerichtet werden. Nur dann kann eine sach- und zielgerechte Selektion gelingen.

Modellperformance und Sicherstellung der Konsistenz


Die Auswertung der Ergebnisse zeigt, dass neuronale Netze in unserer Herangehensweise gegenüber traditionellen Methoden konsistente Vorteile erzielen können – sowohl hinsichtlich der Vorhersagefehler als auch der risikoadjustierten Performance-Kennzahlen des abgeleiteten Portfolios. Gleichzeitig zeigt die Analyse, dass es keine universell dominierende Modellarchitektur gibt. In der Analyse der U.S.-Daten erweist sich eine Kombination aus AFNS-Faktoren zur Kurvenkompression, einer Autoencoder-Kompression für ein breites Spektrum an Makrodaten und einem neuronalen Netz zur direkten Vorhersage der Zinskurve als besonders leistungsfähig (**ABBILDUNGEN 2 UND 3**).

Bei den europäischen Daten basiert die beste Architektur hingegen auf PCA-Faktoren und Vorhersagen der zukünftigen Faktorentwicklung mittels eines neuronalen Netzes ohne zusätzlichen Makroinput (**ABBILDUNG 4**).

Daran ist unter anderem erkennbar, dass mehr Eingabedaten nicht zwingend zu besseren Ergebnissen führen: Die Einbindung von Makrodaten erhöht die Modellfreiheit, aber auch die Gefahr, dass das Modell instabile Zusammenhänge lernt, die außerhalb der Trainingsperiode nicht in gleichem Maße vorhanden sind.


In den U.S.-Daten, in denen makroökonomische Einflüsse und geldpolitische Reaktionen historisch deutlich in der Zinskurve widerspiegelt sind, bringen Makrodaten einen eindeutigen Mehrwert. In den europäischen Daten ist der tatsächliche Nutzen zumindest im untersuchten Setup geringer, sodass ein Modell ohne Makro am Ende besser abschneidet. Entsprechend empfiehlt sich eine systematische Prüfung

2 Schematischer Aufbau des Modells zur Vorhersage der U.S. Zinskurve



Quelle: eigene Darstellung

3 Duration des gesteuerten Portfolios vs. Benchmark mit zugehöriger Zinsentwicklung und Analyse der Performance



Quelle: eigene Darstellung

unterschiedlicher Spezifikationen sowie eine sorgfältige Auswahl der verwendeten Makroindikatoren.

Die zentrale Eigenschaft guter statistischer und Machine-Learning basierter Modelle ist es, sowohl „in-sample“ (also auf Trainingsdaten) als auch „out-of-sample“ (also auf Testdaten, die im Kalibrierungsprozess nicht berücksichtigt wurden), gleichermaßen gute Vorhersagen zu treffen.


Dieser Punkt wird in unserer Herangehensweise durch eine gezielte Kalibrierung der Hyperparameter der einzelnen Modelle in den Mittelpunkt gerückt. Hierbei betrachten wir nicht nur den mittleren quadratischen Fehler der Vorhersagen, sondern verwenden eine Implementierung, die extreme Fehler stärker bestraft, da diese in der späteren Umsetzung ein erhöhtes Risikopotenzial bergen. Eine einzelne große fehlerhafte Vorhersage, die das Modell in die falsche Richtung der Duration weist, kann die Performance über einen längeren Zeitraum hinweg nachhaltig beeinträchtigen. Daraus folgt, dass neben der mittleren quadratischen Abweichung auch robuste Verlustfunktionen oder explizite Strafterme zur Begrenzung von Extremfehlern berücksichtigt werden sollten.

Praktische Anwendung

Zur Anwendung in der Praxis sind neben der Modellierung auch Fragen der operativen Umsetzung und der Governance zu berücksichtigen. Die Anwendung kann dafür in mehrere funktionale Ebenen gegliedert werden:

- ▶ Zunächst eine Datenebene, in der Kurven- und Makrodaten versioniert, Lags berücksichtigt und Qualitätsprüfungen automatisiert werden.
- ▶ Zweitens eine Aufbereitungsebene, in der alle Transformationen reproduzierbar ausgeführt werden und sichergestellt wird, dass diese ausschließlich auf Trainingsdaten erfolgen.
- ▶ Drittens eine Ebene mit Modellinformationen, klarer Versionierung und einem Plan zur Neuschätzung des Modells.
- ▶ Viertens eine Ebene zur Asset-Allokation, die das Signal in Duration übersetzt, Restriktionen berücksichtigt und um weitere Schritte, wie z. B. Transaktionskosten, ergänzt werden kann.

4 Schematischer Aufbau des Modells zur Vorhersage der europäischen Zinskurve



Quelle: eigene Darstellung

- Fünftens eine Monitoring-Ebene, in der Performance, Turnover und Einhaltung definierter Limits überwacht werden.

Bezüglich des Retrainings (also des Schätzens des Modells mit neu verfügbaren Daten) wird in unserer Implementierung ein zweistufiges Verfahren angewandt: wöchentliche inkrementelle Updates (z. B. wenige Durchläufe des lokalen Optimierungsalgorithmus mit neuen Daten) und regelmäßige, aber seltene Neuschätzungen des gesamten Modells mit allen Daten (z. B. alle 24 Monate). Dieses Vorgehen ermöglicht eine laufende Aktualisierung auf Basis neuer Marktdaten, ohne bei jeder Anpassung einen vollständigen Validierungs- und Freigabeprozess durchlaufen zu müssen.

Schließlich lassen sich aus dem Ansatz zusätzliche Erweiterungsmöglichkeiten ableiten. Transaktionskosten sowie Margin- und Liquiditätsanforderungen spielen in der tatsächlichen Umsetzung eine große Rolle. Sie können aggressive Signalsysteme entwerfen, weshalb ein jeweiliges Kostenmodell sowie ein Turnover- und ein Positionsziel Teil der Implementierung sein sollten. Wer über eine reine Steuerung der Duration hinausgehen möchte, kann die Kurvenprognose auch für Steeper-, Flattener- und Butterfly-Positionen nutzen. Das erhöht zwar die Komplexität, ermöglicht jedoch zusätzliche relative Positionierungen entlang der Kurve.

Fazit

Wer ein Modell zur Zinsstrukturprognose implementiert, sollte dieses nicht unabhängig von der späteren Anwendung in konkreten Portfolioentscheidungen evaluieren, denn erst im Anwendungskontext zeigt sich, welche Modelle tatsächlich Mehrwert liefern. Neuronale Netze liefern insbesondere in Kombination mit etablierten Kurvenfaktoren (DNS / PCA / AFNS) und sinnvoller Dimensionsreduktion makroökonomischer Eingangsgrößen einen belegbaren ökonomischen Nutzen. Die geeignete Modellwahl hängt vom jeweiligen Marktumfeld ab, wie die unterschiedlichen Ergebnisse auf dem amerikanischen und dem europäischen Markt zeigen. Dabei kann ein schlankes, gut erklärbares Modell einem komplexen Ansatz überlegen sein, wenn es stabiler ist und in der Zielanwendung besser funktioniert.

Setzt man ein Modell auf, sollte man früh auf drei Dinge achten: eine saubere, zeitkonsistente Datenpipeline, eine Validierung, die auch Portfolio-Kennzahlen berücksichtigt, und ein Betriebsmodell mit Versionierung, Datenupdates und Monitoring. Wenn diese Grundlagen beachtet werden, ist datengestütztes Duration Management keine Machine-Learning-Black-Box, sondern eine nachvollziehbare methodische Ergänzung zur Portfoliosteuerung.



Quelle

Lausser, T., Vuolo, J. E., & Zagst, R. (2025/2026). Data-Driven Duration Management: Term Structure Forecasting Using Machine Learning. Manuskript, Version 23. Januar 2026.

Impressum

Ausgabe 01|2026 | Jg. 25 | Nr. 149

ISSN 1616-5373

Verlag

Absolut Research GmbH
Große Elbstraße 277a
22767 Hamburg
T +49 40 3037790
F +49 40 303779-15
info@absolut-research.de
www.absolut-research.de

Herausgeber Michael Busack
michael.busack@absolut-research.de

Redaktion Ellen Hörth (Chefredaktion)
Hendrik Schlimper
redaktion@absolut-research.de

Grafik Marei Mauritz, Irene Karger,
Petra Dammann

Verlagsabteilungen

Geschäftsführung Michael Busack

Media Augustina Nebelthau (Leitung)
Britta Brandenburger
anzeigen@absolut-research.de

Abbonentenservice Martje Thäßler
martje.thassler@absolut-research.de

Leseexemplare und weitere Informationen:
info@absolut-research.de

Erscheinungsweise 6-mal im Jahr

Anzeigenpreisliste 2026

Datenschutzrichtlinien

www.absolut-research.de/datenschutz/

Druck Langebartels+Jürgens Hbg. GmbH,
Wördemanns Weg 58, 22527 Hamburg,
info@langebartelsdruck.de

Copyright © 2026, Haftungsbeschränkung

Absolut Research GmbH, Hamburg. Alle Rechte vorbehalten. Nachdruck in jeglicher Form, auch auszugsweise, nur nach vorheriger schriftlicher Genehmigung des Verlags. Dies gilt auch für die Aufnahme in elektronische Datenbanken, Vervielfältigung auf Datenträgern oder in internen Pressespiegeln. Den Artikeln, Analysen und Grafiken liegen Informationen zugrunde, die die Redaktion für verlässlich hält. Eine Garantie für die Richtigkeit können Redaktion und Verlag jedoch nicht übernehmen. Wir übernehmen keine Haftung für Verluste, die Dritten dadurch entstehen, dass sie aufgrund von im Absolutreport veröffentlichten Informationen gehandelt oder nicht gehandelt haben. Alle Fragen zu konkreten Anlageentscheidungen sind mit einem kompetenten Berater zu besprechen.

Gender-Hinweis Wir verwenden das generische Maskulinum, da unser Fokus auf der institutionellen Kapitalanlage liegt und es i. d. R. um Firmen (Asset Manager, Investoren etc.) und keine Einzelpersonen geht. Entsprechende Begriffe gelten im Sinne der Gleichbehandlung aber grundsätzlich für alle Geschlechter und beinhalten keine Wertung.


Titelbild: © allanswart_iStock

Papier: Amber Graphic, Arctic Paper



Der Kompass für Private Markets

Unabhängige Produktplattform für professionelle Investoren



Real Estate



Infrastructure



Private Debt



Private Equity



Natural Resources

Registrieren Sie sich jetzt!

Die Produktplattform Absolut|**private products** bietet Asset Ownern eine kostenfreie, aktuelle, vollkommen unabhängige Datenbank für die am Markt zur Verfügung stehenden Private-Market-Investments in fünf Assetklassen.

Absolut| research

DIE PLATTFORM FÜR INSTITUTIONELLE INVESTOREN

Absolutreport

Neue Perspektiven für
institutionelle Investoren

artikel



Alternative Investments in der SAA | Data-Driven Duration Management | Family Offices als Transformationstreiber: Neue Chancen für Private Equity | SFDR 2.0 – Produktqualifikation nachhaltiger Finanzprodukte | Attraktivität von Absicherungsstrategien mit Optionen und Futures | Klimakippunkte als Risikofaktor für Wirtschaft und Finanzsysteme

Alternative Investments in der strategischen Asset Allocation

PHILIPP BRUGGER, JENS GOTTMANN | Union Investment

Data-Driven Duration Management

TOBIAS LAUSSER, JOAO EDUARDO VUOLO, PROF. DR. RUDI ZAGST | TUM
PROF. DR. OLIVER SCHLICK | SECARO/Hochschule der Bayer. Wirtschaft

Attraktivität von Absicherungsstrategien mit Optionen und Futures

DR. TANSEL ALP, NIKOLA SELAKOVIC | Metzler Asset Management

Family Offices als Transformationstreiber: Neue Chancen für Private Equity

PROF. DR. YVONNE BRÜCKNER | ResFutura
VANESSA BOLMER | WWF Deutschland

SFDR 2.0 – Vom Offenlegungsregime zur Produktqualifikation nachhaltiger Finanzprodukte

PATRICIA SCHNEIDER LL.M. | Simmons & Simmons LLP

Klimakippunkte als Risikofaktor für Wirtschaft und Finanzsysteme

DR. HEINZ-WERNER RAPP | FERI Cognitive Finance Institute



kommentare

Sven Schuster

PBeaKK

Aaron Hussein

J. P. Morgan AM

standpunkt

Prof. Dr. Sebastian Heilmann

Universität Trier

Geoökonomische Verwerfungen

kompakt

Matthias Heiß

Universal Investment
Deutschland

Spezialfondsanalyse im Zehnjahresvergleich

drei fragen an

Dr. Birka Benecke

BASF Gruppe

Infrastruktur als Investment für Pensionseinrichtungen