


LEARNING FROM ALTERNATIVE DATA

In der heutigen Welt nutzen institutionelle Investoren eine Vielzahl öffentlich verfügbarer Datenquellen zur Optimierung ihrer Investitionsentscheidungen.

Dabei hat in den vergangenen Jahren die Bedeutung von sogenannten «alternativen Daten» stark zugenommen.



Alternative Daten sind unkonventionelle bzw. nicht marktbezogene Daten, die in der Regel extern erhoben werden, also nicht aus dem unternehmenseigenen oder üblicherweise verwendeten Datenpool stammen. Für ihre wachsende Bedeutung sprechen zweierlei Gründe: Zum einen werden immer mehr Daten gesammelt, elektronisch aufbereitet und in digitalisierter Form, oft in Echtzeit, zur Verfügung gestellt. Zum anderen spielen, gerade bei der Aufbereitung der Daten, Methoden aus der Welt der künstlichen Intelligenz sowie des maschinellen Lernens – wie zum Beispiel das «Natural Language Processing» oder «Machine Learning-based Image Processing» – eine immer stärkere Rolle.

Haben Computer noch vor wenigen Jahren eingescannte Dokumente lesbar gemacht und interpretiert (z.B. Schlagworte und Stimmung eines Geschäftsberichtes oder Zeitungsartikels), so analysieren sie heutzutage z.B. in Echtzeit Reden von CEOs auf Hauptversammlungen hinsichtlich ihrer Botschaft und ihrer Stimmung, um darauf basierend Aktien zu kaufen oder abzustossen. Eine weitere Form alternativer Daten, die stark an Bedeutung gewonnen hat, sind Daten zur Bewertung der Nachhaltigkeit von Unternehmen.

WIESO LOHNT SICH DIE ANALYSE VON ALTERNATIVEN DATEN?

Neben den üblichen Argumenten zur Bedeutung von Daten für Investitionsentscheidungen sind es Nachhaltigkeitsdaten, die besonders im Fokus stehen. Einerseits ist es für viele private und institutionelle Investoren wichtig, in ein nachhaltig agierendes Unternehmen zu investieren. Andererseits verspricht man sich von nachhaltig agierenden Unternehmen eine langfristig höhere Rendite, da diese besser gegen den Klimawandel, die gesellschaftlichen und demographischen Veränderungen sowie gegen politische Risiken geschützt sind. Nachhaltigkeitsbestrebungen haben dadurch einen Einfluss auf die erwartete Rendite, aber auch auf das Risiko. Investoren nutzen daher alternative Daten, um bestimmte Unternehmen in kritischen Industrien (z.B. Öl- und Gasunternehmen) bei der Investmentauswahl auszuschliessen («Negative Screening»), oder andere besonders nachhaltige Unternehmen in ihren Portfolios überzugewichten («Positive Tilt»).

WELCHE NACHHALTIGKEITSDATEN GIBT ES?

In den Vereinigten Staaten werden laut dem Forum for Sustainable Investing (US SIF) circa 17 Billionen US-Dollar an verwaltetem Vermögen nach Nachhaltigkeitskriterien investiert. Trotz dieser enormen ökonomischen Relevanz sind die finanziellen Auswirkungen dieser nicht-finanziellen Unternehmensleistungen bis heute unklar. Ein Grund dafür ist sicherlich die enorme Schwierigkeit, die Nachhaltigkeit von Unternehmen in den drei üblichen Kategorien Umwelt (Environment), Soziales (Social) und Unternehmensführung (Governance) – kurz ESG – objektiv und genau zu bewerten. Trotz Milliardeninvestitionen verschiedener Unternehmen sind diese Bewertungen oft intransparent, basieren auf Analystenschätzungen und weichen signifikant voneinander ab (Berg et al., 2022). In der Zukunft soll manche Datengrundlage, wie zum Beispiel die von den Unternehmensaktivitäten verursachten CO₂-Emissionen, gemäss der Sustainable Finance Initiative der Europäischen Kommission sowie der EU-Taxonomie-Verordnung (Verordnung (EU) 2020/852) in Form einer umsatzbasierten Kennzahl offengelegt werden. Jedoch betrifft dies zunächst lediglich die Umweltdimension der Nachhaltigkeit. Eine Lösung zur akkuraten und effektiven Nachhaltigkeitsbewertung von Unternehmen ist daher erst einmal nicht in Sicht. Abhilfe können hier jedoch Methoden des maschinellen Lernens schaffen.

NACHHALTIGKEITSBEMESSUNG DURCH MASCHINELLES LERNEN

Eine Frage, die es hierbei zu beantworten gilt, ist jene nach der tatsächlichen Bedeutung einer «akkuraten Nachhaltigkeitsbewertung». Nimmt man hier wiederum die Investorenperspektive ein, so sollten echte Verbesserungen/Verschlechterungen in der Nachhaltigkeit vom Markt erkannt und honoriert oder sanktioniert werden. Beim jetzigen Stand der Forschung ist noch nicht klar, ob der Zusammenhang ein positiver (Verbesserungen in der Nachhaltigkeit führen zu positiven Renditen) oder ein negativer (Nachhaltigkeitsverbesserungen wirken sich negativ auf die Unternehmensbewertung aus) ist. Methoden des überwachten («supervised») maschinellen Lernens können Aufschluss geben. Diese sind in der Lage, aus grossen Mengen von Input-Daten nicht nur die tatsächlich relevanten herauszufiltern (Variablenselektion), sondern auch komplexe nicht-lineare Zusammenhänge zu erkennen. Die Anwendung dieser Methoden bestätigen die zuvor erwähnten Unterschiede zwischen den verschiedenen Datenanbietern (MSCI ESG Ratings haben einen vorausschauenden Charakter, siehe Serafeim & Yoon, 2022) sowie innerhalb der drei Kategorien E, S und G (G hat hier den grössten Einfluss, siehe auch Giese et al., 2021). Ebenso findet man den von Shanaev und Gimire (2021) dokumentierten nicht-linearen Zusammenhang zwischen ESG-Rating-Veränderungen und zugehörigen Aktienrenditen (negative Veränderungen in der Mitte des ESG-Spektrums haben die grösste Auswirkung auf den Aktienkurs). Nutzt man nun die Vorteile mancher Methoden des maschinellen Lernens in diesem Zusammenhang aus, so kann man sogenannte «Random Forests», «Boosted Trees» oder auch speziell konfigurierte neuronale Netze (bekannt als «Deep Learning») verwenden, um die Ergebnisse zuvor erwähnter Forschungsarbeiten zu bestätigen, aber auch, um Fondslösungen zusammenstellen, welche in optimaler Weise die Informationsfülle der alternativen (Nachhaltigkeits-)Daten für sich nutzen. Dies geschieht derzeit zum Beispiel im Rahmen einer Innosuisse-geförderten Kooperation der Universität Liechtenstein mit der Liechtensteinischen Landesbank AG im Projekt «An ESG-based Investment Case for Absolute Return Funds».



Dr. Sebastian Stöckl,
Assistenzprofessor (mit Tenure-Track)
am Lehrstuhl für Finance



Dr. Othar Kordsachia,
Assistenzprofessor am Lehrstuhl für
Betriebswirtschaftslehre, Bank- und Finanz-
management

Quellen

- Berg, F., Kölbl, J. F., & Rigobon, R. (2022). Aggregate Confusion: The Divergence of ESG Ratings. *Review of Finance*, rfac033. <https://doi.org/10.1093/rof/rfac033>
- Giese, G., Nagy, Z., & Lee, L.-E. (2021). Deconstructing ESG Ratings Performance: Risk and Return for E, S, and G by Time Horizon, Sector, and Weighting. *The Journal of Portfolio Management*, 47(3), 94–111. <https://doi.org/10.3905/jpm.2020.1.198>
- Serafeim, G., & Yoon, A. (2022). Stock Price Reactions to ESG News: The Role of ESG Ratings and Disagreement. *Review of Accounting Studies*. <https://doi.org/10.1007/s11142-022-09675-3>
- Shanaev, S., & Ghimire, B. (2021). When ESG Meets AAA: The Effect of ESG Rating Changes on Stock Returns. *Finance Research Letters*, 102302. <https://doi.org/10.1016/j.frl.2021.102302>