

## Die Seher 2019 – Mensch und Maschine

*Wer kann 2019 den Markt schlagen? Eine Subspezies des lernenden Menschen, die Superforecasters, oder lernende Maschinen, die auf so klingende Namen wie Support Vector Machine hören?*

Prognosen haben nicht den besten Ruf, aber ganz ohne sie scheint es auch nicht zu gehen. Zwar glauben wir sehr oft, dass manche „Seher“ systematisch besser prognostizieren als Normalsterbliche. Nur deshalb besuchen wir das Orakel, hören auf Propheten, lassen uns den Vogelflug deuten, befragen Meteorologen nach dem Wetter von morgen oder erhoffen uns vom „aktiven“ Vermögensverwalter einen Mehrertrag über dem Marktdurchschnitt. Jedoch bestreiten wir auch in vielen Bereichen die angepriesene Rangordnung oder Unterschiede der Prognosekraft. Dieser Widerstreit prägt auch den Bereich der Geldanlage. Eine breite Strömung in der Finanzwissenschaft sagt: Systematisch und langfristig monetär ausbeutbare Prognosevorteile im Hinblick auf zukünftige Kursänderungen am Finanzmarkt gibt es so gut wie nicht. Ansätze, die dieser Ansicht folgen, werben deshalb häufig mit dem Attribut „prognosefrei“. Sind sie aber wirklich prognosefrei? Die hier als Begründung meist zugrunde gelegte (Effizienzmarkt-) Hypothese besagt in ihrer

strikten Form, dass in den gegenwärtigen Preisen bereits alle verfügbaren Informationen enthalten sind. Damit sind aber zugleich auch alle Prognosen enthalten. Insofern sind die aktuellen Preise durchaus prognosehaltig und nicht prognosefrei. „Prognosefrei“ besagt in diesem Kontext also nur, dass es keine überlegene Prognose einer zukünftigen Preisänderung gibt. Genaugenommen ist natürlich auch das eine Prognose, die falsch sein kann. Und falsch ist sie, wenn die Vertreter des aktiven Managements richtig liegen. Die sagen nämlich, dass sich erstens zukünftige Preisänderungen durchaus systematisch besser voraussagen lassen als per Zufallsgenerator und dass sich zweitens dadurch längerfristig Mehrerträge (positives Alpha) über dem Marktdurchschnitt erzielen lassen. Der Haken daran ist nur, dass sich alle Alphas am Finanzmarkt zu null summieren müssen. Deshalb muss es, wenn es überlegene Prognostiker gibt, die überdurchschnittliche Erträge (bzw. positives Alpha) erzielen, auch Anleger geben, die unterdurchschnittliche Erträge

(bzw. negatives Alpha) erzielen. Und beide Teilgruppen werden aus der Gruppe der „aktiven“ Anleger rekrutiert. Daher ist es für Anleger nicht ganz verkehrt, für sich zunächst eine Prognose zu erstellen, ob ein Anbieter von aktiven Managementleistungen eher zu den Gewinnern oder Verlierern gehören wird. Aber an was sich orientieren? An den Performancedaten? An erweiterten Datenkränzen? An der Organisation und ihrer Reputation? An den Strategien? An den Menschen, die zu den Prognosen beitragen? An den formalen und automatisierten Prognoseverfahren, die verwendet werden, also den „Maschinen“? Wir beschränken im Folgenden auf Mensch und Maschine.

### Der Mensch als Superforecaster

In dem 2015 veröffentlichten Buch „Superforecasting. The Art and Science of Prediction“ stellte der kanadische Psychologe und Politikwissenschaftler Philip Tetlock gemeinsam mit dem Journalisten David Gardner die Ergebnisse langjähriger wissenschaftlicher Untersuchungen zur

Prognosefähigkeit von Personen im Rahmen von Wettbewerben vor. Prognosewettbewerbe sind zentraler Bestandteil eines wachsenden Forschungsfeldes, an dem auch die US-Intelligencegemeinschaft (also die Analytiker der Geheimdienste) reges Interesse hat. Die Forschungen werden jedoch auch in der professionellen Finanzszenen rezipiert. Prognosewettbewerbe umfassen in der Regel eine Vielzahl von Teilnehmern (teilweise im X-Tausenderbereich) über längere Zeiträume (bis zu mehreren Jahren) und ermöglichen es überhaupt erst, die Prognosefähigkeit auf einer sehr breiten Experimental-Datenbasis wissenschaftlich zu untersuchen. Die Teilnehmer mussten bis zu ein paar hundert Prognosen zu möglichen geopolitischen Ereignissen in Form einer Schätzung der Eintrittswahrscheinlichkeit abgeben. Der Zeithorizont lag dabei meist zwischen einem Jahr und einigen Monaten. Bei den Teilnehmern handelte es sich je nach Wettbewerb teils um professionelle Analytiker in diesem Gebiet, vielfach aber um „Laien“, allerdings wohl meist um gut bis sehr

gut ausgebildete. Zur Berechnung der Prognosequalität werden quantitative Maße (insbesondere der Brier Score) verwendet.

Die Analyse bisheriger Wettbewerbe zeigte nun zunächst, dass es unter den Teilnehmern unterschiedlich gute Prognostiker gibt. Die 2 Prozent der am besten abschneidenden Prognostiker bezeichnen die Wissenschaftler als Superforecasters. Zwei zentrale Fragen lauten nun: Welche Eigenschaften bzw. Merkmale unterscheiden die Superforecasters von den übrigen Teilnehmern? Inwieweit können prognostische Fähigkeiten trainiert werden?

Superforecasters wussten zwar in politischen Fragen mehr als der Durchschnitt, sie waren aber größtenteils keine Experten. Bei einem Vergleich schnitten Superforecasters sogar deutlich besser ab als professionelle Analysten der US-Geheimdienste. Die meisten sind auch nicht superintelligent, aber doch von deutlich überdurchschnittlicher Test-Intelligenz (IQ 115 plus). Typischer für sehr erfolgreiche Prognostiker ist die Motivation und die Art und Weise, wie sie Informationen aufnehmen und verarbeiteten: Sie sind hochmotiviert, leistungsehrgeizig, betrachten Prognosen als intellektuelle Herausforderung und glauben an die Möglichkeit der individuellen Leistungsverbesserung. Bei der Informationssuche zeigen sie hohes Durchhaltevermögen. Im Hinblick auf die Informationsverarbeitung sind Superforecasters




Superforecasters im Imperium Romanum bei der Arbeit

typischerweise schneller bereit, ihre Meinungen, Ansichten oder Hypothesen in Abhängigkeit von neuen Informationen zu ändern. Auch sind Superforecasters weniger stark kognitiven Verzerrungen unterworfen und neigen stärker zum kontrafaktischen Denken. Sehr wichtig für eine hohe Prognosequalität scheint zu sein, dass Superforecasters die gewonnenen Infor-

mationen differenzierter in Wahrscheinlichkeiten übersetzen: während durchschnittliche Teilnehmer ihre Wahrscheinlichkeiten in 10er Schritte (10%, 20%, 30%...) einteilten, wählten viele Superforecasters 1er-Schritte (1%, 2%, 3% ...). Schließlich zeigte sich, dass die Bildung von Superforecaster-Teams auch die individuelle Performance verbesserte.

Das sind Hinweise, dass man durch Training und geeignete Umweltstimuli die individuelle Prognosefähigkeit in Grenzen auch relativ schnell trainieren kann. Allerdings ist unabdingbare Voraussetzung eines Trainings die stetige Messung der Prognosefähigkeit. Wettbewerbe sind auch aus Gründen der Motivation ideal dafür. Verbessern lassen sich wohl am schnellsten technische Fertigkeiten, die weniger eng an die Persönlichkeit (Motivation, kognitive Stile usw.) gebunden sind: So etwa die Sensibilisierung für kognitive Verzerrungen und die Übung im Umgang mit Wahrscheinlichkeiten.

Nun muss man sich allerdings fragen, ob die Ergebnisse von Tetlock und Kollegen überhaupt für die quantitativ-empirisch hochgerüstete Finanzbranche mit ihrem mächtigen Methodeninstrumentarium relevant sind? Wird das, was einen Superforecaster ausmacht, hier nicht schon routinemäßig praktiziert? Machen wir es uns möglichst einfach mit der Antwort: Im Zusammenhang mit den Finanzmärkten wird regelmäßig auf geopolitische Unsicherheiten verwiesen. Wenigstens in dieser Fallgruppe wäre damit zu rechnen, dass geopolitische Superforecasters zu überlegenen Prognosen gelangen und letztlich dann davon abhängige zukünftige Preisbewegungen treffsicherer vorhersagen. Da nun aber diese Superforecasters keine Experten in Geopolitik sind, sondern über allgemeinere Fähigkeitsvorteile verfügen,



dürften sie auch auf anderen Feldern „analog“ erfolgreich sein. Sie dürften generell dort im Vorteil sein, wo es darum geht, eher qualitative oder komplexere Informationen in Wahrscheinlichkeiten zu transformieren, wie vielfach bei der fundamentalen Analyse. Ob sie dann nach Kosten auch den Markt schlagen können, ist dann eine andere Frage, die von Tetlock und Kollegen (noch) nicht beantwortet wurde.

#### Die Maschine als Superforecaster

Mit Maschinen sind im Folgenden formale Verfahren gemeint, die man mit Daten füttert und die dann als Output eine Prognose produzieren. Zwei Kategorien von „Maschinen“ werden für die Finanzanalyse hauptsächlich benutzt: Erstens die klassische statistische Analyse. Sie ist das Werkzeug der Wahl in der Finanzwissenschaft. Dabei wird unterstellt, dass z.B. Erträge durch ein lineares Modell abgebildet werden können, was allerdings Annahmen zur Verteilung erforderlich macht. Namen einiger dieser Modelle sind: Regressionsanalyse, ARIMA oder GARCH. Die zweite Kategorie sind Lernende Maschinen. Diese Verfahren sind in der „zünftigen“ Finanzwissenschaft noch nicht weit verbreitet, sie werden vor allem von einschlägigen Ingenieurwissenschaftlern (Informatikern usw.) auch zum Zweck der Preisprognose an Finanz-

märkten eingesetzt. Man verspricht sich von Lernenden Maschinen insbesondere deshalb Prognosevorteile, weil sie auch nichtlineare Zusammenhänge abbilden können. Damit werden sie, so die Hoffnung, eher Charakteristika des Finanzmarktes gerecht. Diese „Maschinen“ sind datengetrieben, selbstadaptiv und nicht auf statistische Vorannahmen angewiesen. Im Wesentlichen geht es darum, meist im Sinne der technischen Analyse Muster am Markt zu erkennen, für die herkömmliche statistische Verfahren „blind“ sind.

Es stellt sich dann die Frage, ob etwa lernende Maschinen auch „Superforecasters“ sein können. Eine Arbeit von Hsu, Lessmann, Sung, Ma und Johnson ([Bridging the Divide in Financial Market Forecasting: Machine Learners vs. Financial Economists](#))>> die wir unseren Ausführungen zu Maschinen zugrunde legen, berichtet, dass der Anteil zutreffender Voraussagen der Richtung zukünftiger Preisbewegungen (Prognosehorizont: ein Tag und weniger) in der Literatur zu Lernenden Maschinen bei durchschnittlich rund 80% liegt. Das scheint der Effizienzmarkthypothese krass zu widersprechen.

Hsu et al. führten daher umfassende Untersuchungen der Prognose- und Renditeeigenschaften von Maschinen durch. Sie fanden dabei aber eine deutlich geringere Prognosekorrekt-

heit der Lernenden Maschinen; sie lag unter 60% und damit weit unter dem bisher publizierten Durchschnittswert. Zudem stellte sich heraus, dass die Vorhersagegüte mit den (regionalen) Märkten variiert und dass sie bei längerem Prognosehorizont (Tag vs. Stunden) sowie bei technischer statt fundamentaler Analyse besser ist. Insbesondere ist die Treffergenauigkeit von der Modellwahl abhängig: die besten Lernenden Maschinen prognostizierten besser als die besten statistischen Modelle; auch konnten sie höhere Erträge erzielen. Bei den Lernenden Maschinen waren Modelle vom Typ „Support Vector Machine“ (SVM) bei Prognose und Handelsgewinnen besser als Modelle vom Typ „Artificial Neural Network“ (ANN). SVM scheinen daher so etwas wie die gegenwärtigen Superforecasters unter den Maschinen zu sein. Sie sollten nach Ansicht der Autoren als Benchmark dienen. Allerdings wurden in der Studie Transaktionskosten nicht berücksichtigt. Die Autoren sehen daher ihre Studienergebnisse nicht notwendig im Widerspruch zur Effizienzmarkthypothese, zumal diese in milderer Form die partielle Vorhersage in der kurzen Frist nicht ausschließt. Insgesamt aber können aber Lernende Maschinen, so die Autoren, Marktanomalien entdecken und sollten deshalb in den Werkzeugkasten der Finanzanalyse aufgenommen werden.

#### Die Mensch-Maschine

Wer nun die referierten Forschungsergebnisse in seine Bewertung aktiver Manager einfließen lassen möchte, orientiert sich auch bei dieser Prognose am besten an den menschlichen Superforecastern.

Das bisher Geschriebene legt nun die Frage nahe: Warum nicht von vorneherein ein Vermögensverwalter-Team aus Superforecastern und Support Vector Machines bilden? Ergänzen können sich beide Komponenten beim Zeithorizont: während Maschinen bisher meist im Prognosehorizont von Tagen bis Stunden erfolgreich operieren, brillieren die besten menschlichen Prognostiker im Bereich kleiner als ein Jahr. Gemeinsam ist beiden Systemen, dass sie besser abschneiden als die jeweiligen Normalprognostiker ihrer Kategorie. Da menschliche Superforecasters besonders qualitative Informationen überdurchschnittlich gut in Wahrscheinlichkeiten transformieren können, sollte dies bei der Fundamentalanalyse von Vorteil sein. Und maschinenartige Superforecasters exzellieren vor allem bei der technischen Analyse. Wäre das nicht eine überlegene Kombination für 2019? Die Studien, die wir referierten, geben darauf keine Antwort. Was wohl menschliche Superforecasters dazu sagen würden?