

SIGLO Timeout Nr. 120 – Künstliche Intelligenz

Einführung

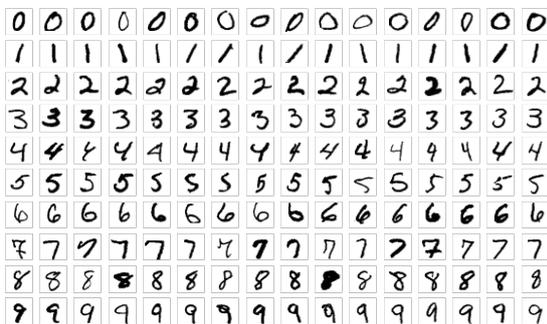
Je nachdem, wen man fragt, ist Künstliche Intelligenz ein Segen oder ein Fluch. Für die Finanzindustrie ist sie auf jeden Fall auch eine Chance, die man nicht verpassen sollte. Im Timeout beschreiben wir die Ausgangslage und zeigen anhand einfacher Beispiele einige praktische Ideen und Anwendungen.

Definitionen

Bevor wir beginnen können, benötigen wir einige Definitionen. Wir werden Künstliche Intelligenz (KI) und Maschinelles Lernen (ML) abwechselnd benutzen. KI bedeutet, eine Maschine z.B. einen Computer mit der Ausführung einer Aufgabe zu betrauen, die sonst ein Mensch erledigen würde. ML beschreibt dann das Set von Techniken und Algorithmen, um diese Aufgabe zu erfüllen. Mit anderen Worten fokussiert KI auf das Ziel und ML auf die Methode. Deep Learning (oder neuronale Netze) stellt eine dieser ML-Methoden dar, die in letzter Zeit vielversprechende Ergebnisse lieferte und daher Aufmerksamkeit und Interesse erhält.

ML ist das Hauptthema im Timeout. ML versucht im Prinzip ähnlich zu statistischen Methoden, Muster in Daten zu finden und daraus Prognosen zu erstellen. Die zentralen Unterschiede von ML zu Statistik liegen darin, dass in ML kein Modell spezifiziert werden muss und keine konzeptionelle Beschreibung gesucht wird.

ML erlaubt die Entwicklung des Modells rein aus den vorliegenden Daten selber. Auf diese Weise werden auch nicht direkt sichtbare Muster oder Zusammenhänge erfasst und erkannt.



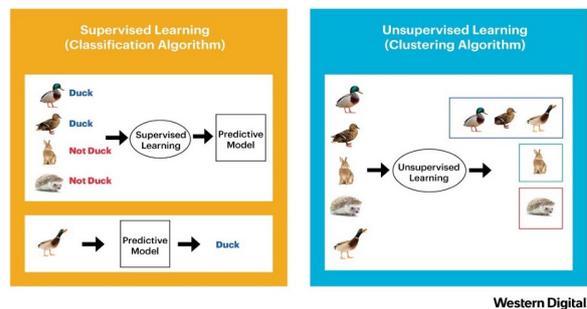
Ein Beispiel aus dem MNIST Datenset

Ein Beispiel finden wir beim bekannten MNIST Datenset, das handgeschriebene numerische Bilder darstellt. Das Ziel eines Computers lag darin, Symbole der richtigen Kategorie (Zahlen von 0-9) zuzuordnen. Jedem Symbol wurde nach jeder Zuordnung durch den Computer die korrekte Antwort mitgeteilt, damit der Computer

seine Zuordnung mit der Zeit verbessern und so aus seinen «Fehler» lernen konnte. Über «Trial and Error» passte der Computer sein Modell laufend an, womit er mit jeder Iteration besser wurde und die Aufgabe zuverlässiger löste.

Man spricht in diesem Zusammenhang von der **Supervised Learning** Technik, weil man dem Computer Aufgaben gibt, deren Lösung man im Voraus bereits kennt, um ihn so zu trainieren.

Der andere ML-Ansatz liegt im sogenannten **Unsupervised Learning oder Clustering**, wo der Computer ohne bereits vordefinierte Lösung Muster in den Daten erkennen soll. Dabei wird z.B. ein Computer mit einer Reihe von Daten zu Anlagefonds gefüttert (Renditen, AUM, Angaben zu Strategie, etc.). Der Clustering Algorithmus im Computer soll dann die Fonds in eigene Gruppen mit ähnlichen Mustern einteilen, wobei zu Beginn nicht spezifiziert ist, wofür die einzelnen Gruppen stehen. Im Ergebnis gewinnt der Computer evtl. neue Perspektiven auf diese Fonds findet und findet bisher nicht bekannte Zusammenhänge z.B. bzgl. Abhängigkeiten oder Diversifikation. Untenstehendes Bild stellt den Unterschied in den beiden ML-Techniken grafisch dar.



Western Digital

Was passiert in der Box?

Architektur und Konstruktion der Algorithmen sind zentral für Anlageerfolge von KI-basierten Strategien. Leider stellen sie auch die höchsten Hürden aus Anlegersicht bei der Beurteilung dar. Nicht nur aus technischer Sicht, sondern auch weil die Manager ihre Wettbewerbsvorteile in KI und ML nicht gerne preisgeben. Entsprechend müssen Anleger eine gewisse Intransparenz von

Seiten der Manager akzeptieren, ohne natürlich auf sorgfältige Analysen anderer Informationen wie z.B. Track Record, Prozesse, Infrastruktur Personen und Backgrounds, etc. zu verzichten. Besonders wichtig erscheint uns dabei auch der Entwicklungsprozess für KI und ML. Darunter fallen Dinge wie die Programmierung selbst, das Training, Umgang mit Modell-Overfitting oder Validierungen neuer Modelle. Nicht zuletzt spielt die Motivation des Managers für den Einsatz von KI und ML für uns eine wichtige Rolle, wie der nächste Abschnitt verrät. Weshalb wird KI und ML genau eingesetzt und was ist das Ziel damit?

Es geht um Vieles, nicht nur um Prognosen

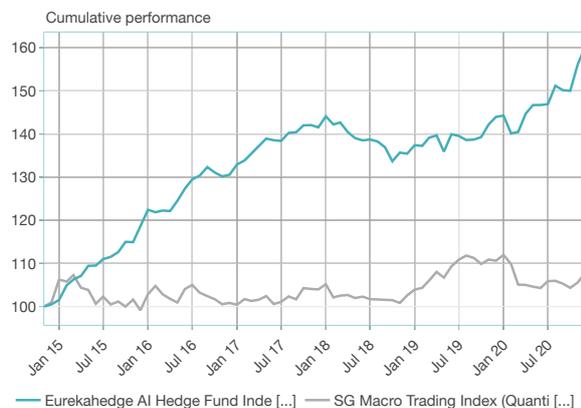
Ein häufiges Missverständnis besteht in der Vorstellung, dass ML in Finance benutzt wird, nur um künftige Preise und Renditen vorherzusagen. Marco Lopez de Prado, ein auf dem Gebiet führender Forscher, beschreibt in seinem Buch, dass mit ML zahlreiche andere Ziele zu verfolgen sind, wie z.B. Modellwahl, Positionsgewichtung, Risk Management, Identifikation und Validierung von Theorien, Trade Execution und viele mehr. Der praktische Einsatz von ML bei Fonds reicht also von der Analyse einzelner Inputs bis zur Fundierung von gesamten Anlagestrategien. Wir listen dazu einige Praxisbeispiele auf, woran uns bekannte Manager heute arbeiten.

- **Alternative Daten:** Systematic Macro Fonds integrieren häufiger KI-Daten und Signale in ihren Modellen. Diese stammen entweder aus eigenem Research oder extern eingekauft. Ein bekanntes Beispiel stellen Sentiment Analysen dar, die relevante Anlageinformationen in Auswertungen von Sprachmustern aus Zeitungen, Vorträgen oder Tweets suchen. Bereits heute sind solche Analysen breit erhältlich, z.B. auf Retail-Handelsplattformen, was zur Frage führt, ob überhaupt noch Mehrwert darin liegt. Andere Beispiele finden wir in der Auswertung von Bildern, z.B. solchen von Tankern im Meer um anhand der Form und Länge des Schattens die Lademengen zu schätzen. Auf aggregierter Ebene leitet man so eine Schätzung über das globale Ölangebot und die Lieferungen ab. Andere Ansätze werten Satellitenbilder von Agrarfelder aus, oder erfassen Feuchtigkeit und Bodentemperatur, um Trockenheit vorherzusagen. Eine zentrale Aufgabe für Manager liegt darin, aussagekräftige Signale von zwar coolen aber unnützen Messungen zu unterscheiden.
- **Preismuster:** Einige CTAs setzen auf ML, um weitere und bessere Muster (Trends oder bewusst keine Trends) zu finden.
- **Modul-Selektion:** stellt einen Standardfall dar, wobei oft versucht wird, verschiedene Strategien oder Portfoliobausteine zu identifizieren und diese dann über die Zeit optimal zu handeln oder zu gewichten.
- **Ideen-Generierung:** Discretionary Macro Fonds beschreiben uns, dass sie über Unsupervised Learning versuchen, Cluster in Renditen verschiedener Instrumente und Makro-Variablen zu finden und damit neu bzw. bisher unentdeckte Beziehungen aufzudecken. Anschliessend prüfen sie qualitativ, ob diese ökonomisch plausibel und profitabel handelbar sind. Ein Fonds kann so seinen Computer mit der Suche nach Anlage-Opportunitäten beauftragen, und sich anschliessend vertieft mit den besten zu befassen und zu handeln.
- **Slippage optimieren:** ML kann helfen, die Ausführungen von Handelstransaktionen besser oder günstiger umzusetzen, indem sie optimalere Handelsmuster findet.
- **Crowd-sourced Strategien:** sammeln Informationen aus öffentlichen Online-Wettbewerben, die sie organisieren und auswerten. Der Fonds Numerai gilt als ein Pionier auf diesem Gebiet. Alle Mitspieler erhalten ein Set von normalisierten Daten (Inputs) um damit In- und Outputs zu schätzen, ohne genau zu wissen, was die Daten darstellen. Das entspricht der ML-Ausgangslage und die Wettbewerber erarbeiten für Numerai die Lösungen, wobei die besten dann mit Tokens oder Staking belohnt werden, um ein breites Teilnehmerfeld cleverer Köpfe anzulocken.
- **Volle KI Fonds:** repräsentieren ein Cliché von KI-Managern, die viele Daten in ihre Maschinen stecken und in alle Richtungen nach Erkenntnissen suchen, d.h. nicht nur Renditeprognosen, sondern auch andere Infos wie z.B. Prognosen für Volatilitäten oder eigene Schätzfehler. Inputs dafür sind oft Preise von Anlagen, aber auch Makro- und alternative Daten.
- **Simulationen:** sind eine Erwähnung wert, weil der systematische Einsatz von Monte-Carlo-Simulationen zur Generierung von umfangreicheren Datensets zur Analyse und zum Training von KI eingesetzt wird. Dies ermöglicht weitere Techniken wie z.B. **Reinforcement Learning**.

Der sinnvollste Einsatz von ML liegt vermutlich in Bereichen mit den höchsten Freiheitsgraden für die Manager punkto Kreativität und weniger im Fine-Tuning bestehender Modelle. Aufgrund der Komplexität dieses Forschungsfeldes hat es sich als separater Bereich in der Mathematik etabliert. Innerhalb der Datenwissenschaften wird auch die sogenannte Domain Knowledge als zentrale Einflussgrösse für den Modellerfolg gesehen.

Performance

Aufgrund der Heterogenität beim KI-Einsatz ist die Bildung konsistenter Peergroups schwierig. Wir haben aber bereits rund 30 Fonds identifiziert, welche auf KI-Strategien setzen und deren Renditediskrepanz ist wie erwartet hoch. Im Jahr 2020 reichten die Renditen von 41% bis -32%, mit dem Median bei 7%. Der Eureka hedge AI Hedge Fund Index, der das KI-Universum verfolgt, lag zwar in den Jahren 2018 und 2019 etwas hinter anderen Macro- und Quant-HF-Indizes aber rentierte in 2020 signifikant besser als beispielsweise der SG Macro Trading Index (Quantitative). Zudem liegt er auch über die letzten 5 Jahre weit voraus, wie die kumulierten Renditen in der Abbildung deutlich machen.



Neben überzeugenden absoluten Renditen sind auch Diversifikationseffekte von KI-Fonds interessant. Der Eureka hedge AI Hedge Fund Index weist nur bisher eine geringe Korrelation mit dem SG Macro und dem HFRX auf, und eine höhere mit dem MSCI World Index. Zudem scheint sie in schwierigen Phasen in den letzten fünf Jahren zu bestehen, denn die Korrelation mit Aktien fällt in den negativen Aktienmonaten von 0.53 auf 0.27.

Correlation	All	Up	Down
SG Macro Trading Index (Quantitative)	0.3	0.32	0.09
HFRX Global Hedge Fund Index	0.41	0.58	0
MSCI World USD	0.53	0.61	0.27

Konklusion

Marktentwicklungen zu prognostizieren ist nicht so simpel wie handschriftliche Zahlen zu ordnen. Die Datenlage ist unübersichtlich und das Signal-to-Noise-Ratio tief. Zudem beeinflussen Marktteilnehmer laufend die Signale. Trotzdem ist für uns KI heute zu wichtig, um es zu ignorieren, da die Einsatzmöglichkeiten wie erwähnt breit sind. Es wird also weder ein Armageddon noch eine Eintagesfliege. Es wird auch nicht klassische Buy-and-Hold oder diskretionäre, aktive Anlagestrategien ersetzen. Die intransparente Natur der Technologie (für Laien) verlangen zudem nach Sorgfalt bei der Beurteilung und Umsetzung. Aber wir rechnen damit, dass früher oder später gewisse KI-Algorithmen wohl höhere und risiko-adjustiert bessere Renditen abliefern als andere Quant-Strategien, weil wir sie als natürliche und evolutionäre Weiterentwicklung auf der Suche nach überdurchschnittlichen Renditen sehen.

Zukünftige Gewinner dürften im Wettbewerb auf technisches Knowhow und Domain-Kenntnisse setzen, was ihnen erlaubt, KI so nutzenstiftend wie möglich einzusetzen.

SIGLO Capital Advisors AG

ist eine Anlageberatungsfirma in Zürich,
berät Sie bei der Umsetzung Ihrer Anlagen,
unterstützt Sie bei der Selektion von Anlageprodukten und Managern, bei der Portfolio-konstruktion und bei der Überwachung,
erarbeitet massgeschneiderte Lösungen mit konkreten Handlungsempfehlungen für Sie,
ist zu 100% im Besitz der Partner und hat keine Bindungen zu anderen Finanzinstituten.

www.siglo.ch / contact@siglo.ch

