



## Wie Currency Overlay Strategien von künstlicher Intelligenz profitieren können



Dr. Ulrich Janus ist promovierter Mathematiker und befasst sich mit der Analyse von Marktdaten mit Hilfe maschinellen Lernens. Als Senior Quant Researcher bei 7orca ist er für die Entwicklung quantitativer Investmentstrategien verantwortlich.

### Sicherung von Währungsrisiken

Als ein häufig unbeabsichtigtes Nebenprodukt internationaler Diversifikation können Währungsrisiken einen bedeutenden Risikofaktor in einem institutionellen Portfolio darstellen. Da das Währungsrisiko durch keine natürliche Risikoprämie entlohnt wird, wird oftmals eine Risikoreduzierung durch die Anwendung entsprechender Sicherungsstrategien verfolgt.

In vergangenen Jahren sind Currency Overlay Strategien als flexible und individuell anpassbare Lösungen zur Begrenzung von Währungsrisiken in den Fokus institutioneller Investoren gerückt.

Eine aktive Currency Overlay Lösung ist eine Strategie zur Währungssicherung, die ihren Sicherungsgrad an die aktuellen Marktbewegungen anpasst.

### Der quantitative Ansatz

Quantitativ ausgerichtete Sicherungsprogramme nutzen Algorithmen für ihre Handelsentscheidungen. Die dabei zum Einsatz kommenden, trendfolgenden Algorithmen basieren auf Ideen aus der Behavioural Finance und verwenden typischerweise technische Indikatoren wie Momentum oder gleitende Durchschnitte. Andere Algorithmen nutzen zusätzlich makroökonomische Faktoren.

Quantitative Manager setzen diese Modelle computergestützt um und vermeiden dadurch die Probleme menschlicher Ermessensentscheidungen. Dieses Setup ermöglicht zudem, die Modelle bei der Entwicklung automatisiert und nach einheitlichen Maßstäben zu testen. 7orca verfolgt einen solchen quantitativen, preisbasierten und trendfolgenden Ansatz. Damit sind wir in der Lage, den Sicherungsgrad dynamisch anzupassen, um unsere Kunden zusätzlich zur Absicherung an positiven Bewegungen profitieren zu lassen.

### Künstliche Intelligenz eröffnet neue Möglichkeiten

Die mit der fortschreitenden Digitalisierung einhergehende steigende Verfügbarkeit großer Datenmengen, sowie die weiter wachsende Rechenkapazität haben Methoden der künstlichen Intelligenz zunehmend ins Zentrum der Aufmerksamkeit gerückt. War ihr Nutzen lange Zeit wegen ihres Anspruches an Rechenressourcen begrenzt, eröffnen sie nun interessante Möglichkeiten, um den beschriebenen quantitativen Ansatz weiterzuentwickeln.

Ein besonderer Fokus liegt auf den künstlichen neuronalen Netzen. Inspiriert von den biologischen Grundlagen des menschlichen Gehirns sind diese ihrer Struktur nach an die durch Synapsen miteinander verbundenen Nervenzellen angelehnt.

Mittlerweile haben sie sich jedoch zu einer eigenständigen Disziplin maschinellen Lernens entwickelt und bewiesen, dass sie in der Lage sind, komplexe Muster in Daten zu erkennen. Das macht sie für die Analyse von Marktbewegungen interessant, deren vielschichtige Dynamik bekanntlich schwer zu spezifizieren ist.

### **Funktionsweise eines künstlichen neuronalen Netzes**

Neuronale Netze verarbeiten Daten über eine Reihe von hintereinander geschalteten und untereinander vernetzten Schichten.

Jede Schicht besteht aus einer Anzahl von Knoten. In einem typischen „feedforward“-Netz ist jeder Knoten einer Schicht mit jedem Knoten der nachfolgenden Schicht verbunden. Der Name „feedforward“ beschreibt den Fluss der Information von den Eingabeknoten über die inneren Schichten bis in die Ausgabeschicht.

In jedem Knoten findet eine Aggregation der Informationen aller Vorgängerknoten statt. Dabei ist jeder Knotenverbindung ein Gewichtsparameter zugeordnet.

Die Aggregation besteht aus einer mit diesen Parametern gewichteten Summe der Vorgängerausgaben und anschließender Anwendung einer nichtlinearen Aktivierungsfunktion.

Der Ausgabewert dieser Funktion dient seinerseits wiederum als Eingabewert für die Aggregation in der nächsten Schicht. Obwohl jeder einzelne Aggregationsschritt recht einfach ist, ist ein solches Netzwerk durch die Hintereinanderschaltung vieler solcher Elemente in der Lage, hochkomplexe Funktionen abzubilden.

### **Der Lernalgorithmus**

Die Struktur des Netzwerks, sowie die Anzahl der Schichten und die Art der Aktivierungsfunktionen

sind a-priori gesetzt. Die Gewichtsparameter hingegen werden mit Hilfe des sogenannten Backpropagation-Algorithmus ermittelt. Dabei wird das Netzwerk mit Trainingsdaten gefüttert und die entsprechenden Ausgaben werden mit den korrekten Antworten verglichen.

Im Backpropagation-Schritt wird der Einfluss der Gewichte auf den gemachten Fehler analysiert. Die Information fließt nun also rückwärts durch das Netzwerk von der Ausgabeschicht bis hin zu den einzelnen Gewichten. Dadurch kann der Lernalgorithmus nun Schritt für Schritt die Gewichte so verändern, dass der Fehler kleiner wird, bis eine optimale Konfiguration gefunden ist.

### **Balance zwischen Unter- und Überanpassung**

Neuronale Netze haben eine große Anzahl freier Parameter. Dies birgt grundsätzlich die Gefahr, dass sich der Algorithmus den Trainingsdaten zu sehr anpasst, und so für die Anwendung auf neuen Daten unbrauchbar wird.

Diesem Problem der Überanpassung kann zum einen durch eine hinreichend große Menge an Daten begegnet werden. Zum anderen existieren verschiedene Methoden, die der Überanpassung wirkungsvoll entgegenwirken. Ein Beispiel für eine solche „Regularisierung“ ist die Erweiterung der Kostenfunktion um einen gewichtsabhängigen Strafterm. Diese Maßnahme hält das Netz davon ab sich zu sehr auf einzelne Knoten und Verbindungen zu verlassen. Dadurch ist es möglich, eine Balance zwischen einer Unter- und Überanpassung herzustellen.

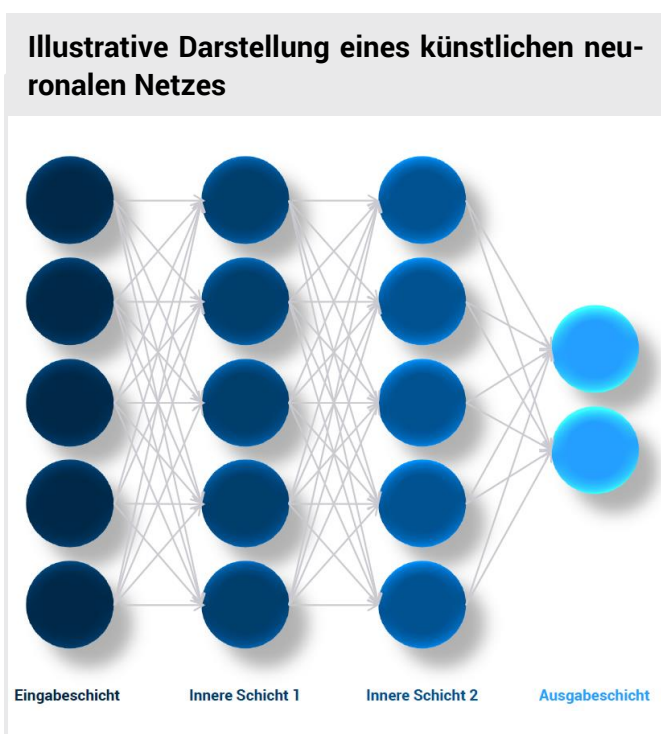
Um diesen Prozess der Ausbalancierung zu steuern, werden die Daten für das Training und die Validierung separat vorgehalten. Die Gewichtsparameter werden ausschließlich aus den Trainingsdaten hergeleitet und das Netzwerk danach auf den Validierungsdaten getestet. Eine vergleichbare Performance des Netzwerks auf beiden Datenmengen ist eine Voraussetzung für die erfolgreiche Anwendung auf neue Daten im Live-Betrieb.

## Trenderkennung mit künstlicher Intelligenz

Im Zusammenhang mit einer dynamischen und trendfolgenden Währungsabsicherung stellt sich das Problem der Trenderfassung. Sich anbahnende Trends müssen rechtzeitig erkannt werden, damit die Sicherungsstrategie diese erfolgreich ausnutzen kann.

Wie angeführt, basieren Handelsalgorithmen typischerweise auf Marktpreis- oder Fundamentaldaten beziehungsweise auf hieraus abgeleiteten Indikatoren.

Künstliche Intelligenz kann nun dadurch zum Einsatz kommen, dass diese Daten als Eingabeknoten eines künstlichen neuronalen Netzes dienen. Für die Trainingsdaten können die zu jedem Zeitpunkt vorherrschenden Trends rückblickend bestimmt werden. Die untenstehende Abbildung zeigt wie ein solches System aussehen kann.



Die Marktdaten werden von den Eingangsknoten über die inneren Schichten des Netzes bis in die Ausgabeknoten gereicht, wo schließlich eine Aussage über die vorherrschende Trendrichtung abgeleitet wird.

## Vorteile des maschinellen Lernens

Im Hinblick auf das Currency Overlay Management lassen sich einige interessante Vorteile des

maschinellen Lernansatzes der künstlichen neuronalen Netze (NN) hervorheben:

- NNs sind in der Lage unbekannte Zusammenhänge zu entdecken. Damit stellen sie eine komplementäre Ergänzung zu traditionellen technischen Modellen dar, bei denen der Algorithmus im Voraus festgelegt ist. Innerhalb eines Multi-Modell-Ensembles vermehren sie damit die methodische Diversifikation und Stabilität der Gesamtstrategie.
- NNs können große Mengen an Daten verarbeiten und auf unterschiedliche Eingabedaten angepasst werden. Dies ermöglicht es beispielsweise einem NN von den Daten unterschiedlicher Währungen gleichermaßen zu lernen, was seine Robustheit erhöht.
- Die hohe Flexibilität von NNs ermöglicht ihnen das jeweilige Marktumfeld aus mehreren Perspektiven zugleich zu betrachten und dann zu einem ausgewogenen Urteil zu gelangen.
- NNs können fortlaufend von neuen Daten lernen und sich so, geleitet durch das aktuelle Marktumfeld, kontinuierlich weiterentwickeln.

Die erfolgreiche Anwendung eines neuronalen Netzes hängt von verschiedenen Faktoren ab wie etwa der Aufbereitung der Daten, der Wahl der Netzarchitektur und der Anwendung der Regularisierungsmethoden. Bei entsprechender Umsicht birgt die künstliche Intelligenz ein signifikantes Potential für die Entwicklung erfolgreicher Sicherungsstrategien. Demnach ist Torca der Auffassung, dass maschinelles Lernen eine wichtige Diversifizierung innerhalb eines modellgetriebenen Sicherungsansatzes darstellt.

**Ansprechpartner:**

Tindaro Siragusano, CEO

[tindaro.siragusano@7orca.com](mailto:tindaro.siragusano@7orca.com), DW -10

Sven O. Müller, Head of Relationship Management,

[sven.mueller@7orca.com](mailto:sven.mueller@7orca.com), DW -13

André Bode, Advisor

[andre.bode@7orca.com](mailto:andre.bode@7orca.com); DW -11

+49 (0) 40 3346 046-0

7orca Asset Management AG

Am Sandtorkai 77, 20457 Hamburg,

Deutschland



7orca Asset Management AG ist ein unabhängiger, systematischer und fokussierter Asset Manager. Mit seinem erfahrenen Team betreut das Unternehmen institutionelle Kunden im Bereich Overlay Management und Short Volatility-Strategien. Mehr Infos unter: [www.7orca.com](http://www.7orca.com)

**7orca**