

Selbstlernende Algorithmen

in der Optionspreiskalkulation

Künstliche Intelligenz beherrscht die Diskussionen. Und auch in der Finanzbranche ist das Interesse an Machine-Learning-Methoden geweckt. Unternehmen, die sich schon länger auf diesen Bereich konzentrieren, ernten bereits jetzt die ersten Früchte ihrer Investitionen. Die BaFin-Studie „Big Data trifft auf künstliche Intelligenz, Herausforderungen und Implikationen für Aufsicht und Regulierung von Finanzdienstleistungen“ vom Juni 2018 hat ergeben, dass künstliche Intelligenz sowohl den bestehenden als auch potenziell neuen Marktteilnehmern Wettbewerbschancen am Markt bieten kann.

EINBLICK IN SELBSTLERNENDE ALGORITHMEN

Selbstlernende Algorithmen sind ein wesentlicher Bestandteil einer künstlichen Intelligenz (KI). Sie lernen, auf Basis von bereits existierenden Beispielen ihre Entscheidungen zu treffen. Im Detail bilden sich die selbstlernenden Algorithmen nach dem einmaligen Entwicklungsprozess anhand der getroffenen Entscheidungen und der infolgedessen entstandenen Gegenentscheidungen weiter.

Bei selbstlernenden Algorithmen unterscheidet man zwischen dem überwachten Lernen (supervised learning) und dem unüberwachten Lernen (unsupervised learning). Gemeinsam haben diese beiden Vorgehensweisen, dass die zugrunde liegende Datenmenge in Lern- und Testdaten unterteilt wird.

Die Unterschiede liegen im Wesentlichen in der Art und Weise des Lernens. Mit „lernen“ ist hierbei gemeint, dass der jeweilige Algorithmus seine Vorgehensweise an zuvor gegebene Lerndaten (Trainingsdaten) anpasst. Beim überwachten Lernen ist dem Algorithmus bei jedem Lerndatum ein Ziel vorgegeben. Im Gegensatz dazu existiert beim unüberwachten Lernen kein vorgegebenes Ziel. Hier besteht die Logik darin, unbekannte Muster zu erkennen und aus diesen

neue Regeln abzuleiten. Anschließend werden sowohl beim überwachten als auch beim unüberwachten Lernen die gewonnenen Erkenntnisse an den Testdaten getestet, um eine erste Prognosegüte festzustellen.

Selbstlernende Algorithmen werden in ihrer Funktionsweise häufig durch die Natur inspiriert. Eine gängige Methode erzeugt, nach dem biologischen Vorbild der neuronalen Netze, künstliche neuronale Netze. Sie sollen die Neuronen unserer Gehirne imitieren. Die Tausenden Neuronen im (menschlichen) Gehirn sind untereinander über Synapsen verbunden. Hier besitzt jedes einzelne Neuron in der Regel mehrere Eingangsverbindungen und eine Ausgangsverbindung. Die Neuronen gemeinsam bilden ein neuronales Netz. Dieses neuronale Netz verarbeitet Informationen und lernt ständig, sich auf neue Gegebenheiten der Umwelt einzulassen. Die künstlichen neuronalen Netze verarbeiten nach dem Vorbild der biologischen neuronalen Netze Informationen und lernen bei Umweltänderungen dementsprechend dazu. Hierzu bedient man sich unter anderem an Verfahren der Graphentheorie und quantitativer Methoden. Erstere werden verwendet, um die Struktur des künstlichen Netzwerks zu beschreiben. Letztere geben unter ande-

rem Auskunft darüber, wie der Lernprozess der einzelnen Neuronen erfolgt.

Im Gegensatz zu den klassischen Modellen benötigen die selbstlernenden Algorithmen keine Annahmen für ihre Funktionsweise. Daher sind sie sehr flexibel und anpassungsfähig.

Diese Eigenschaften sprechen für die Nutzung selbstlernender Algorithmen und machen diese attraktiv für hohe nichtlineare Daten, wie beispielsweise bei der Bestimmung von Optionspreisen.

GRENZEN DER KLASSISCHEN ANALYSEMODELLE ZUR OPTIONSBEWERTUNG

Klassische Analysemodelle, die heute zur Optionsbewertung eingesetzt werden, spiegeln die realen Marktbedingungen nur zu einem gewissen Grad wider. Eines der gängigen Modelle für die Optionspreiskalkulation ist das Black-Scholes-Modell. Es basiert auf ver-

einfachten Annahmen, wie beispielsweise keiner Dividendenzahlung während der Laufzeit der Option, der geometrischen brownischen Bewegung und Ausübungsoption nur bei Fälligkeit (europäischer Optionstyp).

» Im Gegensatz zu den klassischen Modellen benötigen die selbstlernenden Algorithmen keine Annahmen für ihre Funktionsweise. Daher sind sie sehr flexibel und anpassungsfähig.«

Diese Modellannahmen unterscheiden sich von den realen Marktbedingungen. Beispielsweise ist es üblich, dass eine Aktie während der Laufzeit der Option eine Dividende zahlt. Die geometrische brownische Bewegung setzt eine gleichmäßige Bewegung in alle Richtungen voraus (Stichwort: Normalverteilung). Dies entspricht nur einer Momentaufnahme des Marktes. Andererseits existieren auf dem Markt vorwiegend amerikanische und nichteuropäische Optionstypen, die »




der Käufer im Gegensatz zu europäischen Optionen flexibel ausüben kann.

Black-Scholes liegen zusätzlich eine Reihe systematischer Annahmen zugrunde. Beispielsweise das wohlbekannte Volatilitäts-Smile: Dadurch werden „Deep-in-the-money“-„Deep-out-of-the-money“-Optionen unterbewertet. Darüber hinaus wurden das Black-Scholes-Modell und die darauffolgenden Anpassungen in Zeiten hoher Zinsen entwickelt, in denen die Möglichkeit von Negativzinsen als abwegig galt, weshalb sie in den Modellentwicklungen unberücksichtigt blieb. Die durch die Krise verursachte Niedrig- und Negativzinsphase auf dem Markt beeinträchtigt den Anwendungsbereich der analytischen Modelle weiter.

VORTEILE DER NUTZUNG SELBSTLERNENDER ALGORITHMEN BEI OPTIONSPREISKALKULATION

Die selbstlernenden Algorithmen bieten einen höheren Grad an Flexibilität und Anpassungsfähigkeit und unterliegen keinen Annahmen zu Verteilungsmustern. So kann der selbstlernende Algorithmus sowohl im negativen als auch im positiven Zinsumfeld eingesetzt werden. Bennell und Sutcliffe konnten zum Beispiel bei den Optionen auf FTSE 100 eine bessere Prognose durch die neuronalen Netze gegenüber dem Black-Scholes-Modell feststellen¹. Gerade im „Deep-out-of-the-money“-Bereich können neuronale Netze eine bessere Prognose treffen.

Die heutigen Rechenleistungen und die Infrastruktur ermöglichen das Training der selbstlernenden Algorithmen in einer geringeren Zeit, sodass die selbstlernenden Algorithmen regelmäßig mit aktuellen Daten trainiert werden können. Untersuchungen haben gezeigt, dass diese Anpassungsfähigkeit den selbstlernenden Algorithmen



einen Vorteil gegenüber den klassischen Modellen bringt, da diese sich an die sich verändernden Marktbedingungen anpassen und keinen Annahmen unterliegen.²

Im „Deep-in-the-money“-Bereich und für Optionen mit einer langen Laufzeit trifft das Black-Scholes-Modell gute Prognosen. Dies liegt an den getroffenen Modellannahmen. Jedoch sind die Prognosen des neuronalen Netzes in diesen Bereichen von vergleichbarer Güte. Darüber hinaus ist ein neuronales Netz den impliziten und historischen Volatilitätsansätzen überlegen, die in den klassischen

» Eine Kombination von verschiedenen Methoden unter Anwendung der neuronalen Netze ermöglicht es den Händlern, die Markttrends besser vorherzusehen und die entsprechende Entscheidungshilfe für das eigene Portfolio und die eigene Strategie zu haben.«

BEWERTUNG VON OPTIONEN MITTELS BLACK-SCHOLES-MODELL

Das grundlegende Modell zur Bewertung von Optionen ist das Black-Scholes-Modell. Jedoch werden aufgrund der Einschränkungen der zugrunde liegenden Modellannahmen für verschiedene Optionstypen entsprechend adjustierte Modelle verwendet.

In der Softwarelösung zur Produktberatung und -kalkulation MARZIPAN werden beispielsweise zwei Modelle zur Bewertung von impliziten Zinsoptionen zur Verfügung gestellt: das Black-Derman-Toy-Modell und das Ho-Lee-Modell. Das Black-Derman-Toy-Modell ist bei positiven Zinsen ein gutes Vorhersagemodell, das bei der Verwendung negativer Zinssätze jedoch versagt, da die dem Modell zugrunde liegenden Zinssätze auf einer postulierten Lognormalverteilung basieren. In der Abbildung stellt die blaue Kurve den Wertebereich der Lognormalverteilung dar, während die rote Kurve den Wertebereich für die Normalverteilung zeigt, die unbeschränkt ist. Das heißt, bei Zahlen gegen null und vor allem kleiner null versagt die Lognormalverteilungsannahme. Daher nutzt man in einer Niedrigzinsphase unter anderem Normalmodelle, wie beispielsweise das Ho-Lee-Modell. Dieses kann, aufgrund einer zugrunde liegenden Normalverteilungsannahme für Veränderungsraten der Zinssätze, die negativen Zinsen berücksichtigen und somit die dazugehörigen Optionspreise berechnen. Jedoch ist die Güte der Vorhersage nicht so präzise wie die des Black-Derman-Toy-Modells.

Modellen verwendet werden. Infolgedessen sind gute Preisprognosen der selbstlernenden Algorithmen, speziell des neuronalen Netzes, auch in einem stark volatilen Markt möglich.³

Eine Kombination von verschiedenen Methoden unter Anwendung der neuronalen Netze ermöglicht es den Händlern, die Markttrends besser vorherzusehen und die entsprechende Entscheidungshilfe für das eigene Portfolio und die eigene Strategie zu haben.

AUSBLICK

Die selbstlernenden Algorithmen bieten eine hohe Flexibilität, die über das Beispiel der Optionspreisbewertung hinausreicht. Sie können bei der Bewertung vieler Produkte sinnvoll eingesetzt werden. Eine Begründung dafür ist, dass sie gute Vorhersagen in den Bereichen der Segmentierung sowie Klassifizierung erbringen. Aus diesem Grund sind ihre Einsatzmöglichkeiten, in Relation zu den klassischen Verfahren, weitaus vielfältiger. Ferner wurde ihr Potenzial noch längst nicht ausgeschöpft, da man sich erst am Anfang eines umfangreichen Entwicklungsprozesses befindet. In einem Proof of Concept prüft die msgGillardon AG aktuell die technische Umsetzung der Optionspreisbewertung mit selbstlernenden Algorithmen. Für weitere Einsatzmöglichkeiten siehe auch den Artikel „Mit Predictive Analytics in die digitale Zukunft“ in der NEWS 02/2018. ■

Ansprechpartner:



Senior Business Consultant

Nona Rahmat

nona.rahmat@msg-gillardon.de



Center of Competence
Financial Business
Intelligence

- 1 Bennell, J., & Sutcliffe, C. (2004). Black-Scholes versus Artificial Intelligence Neural Networks in Pricing FTSE 100 Options . Intelligent Systems in Accounting, Finance and Management , S. 243-260.
- 2 Andreou, P., Charalambous, C., & Martzoukos, S. (2005, 03). Pricing and trading European options by combining artificial neural networks and parametric models with implied parameters. European Journal of operational research , S. 1415-1433.
- 3 Yao, J., Li, Y., & Tan, C. L. (2000). Option price forecasting using neural networks. OMEGA The International Journal of Management Science, S. 455-466.