


Whitepaper

Januar 2023

Machine Learning in der Marktrisikorechnung

In Zusammenarbeit mit

d-fine



Machine Learning in der Marktrisikorechnung – Ein innovativer Ansatz zur Performance-Optimierung



Dr. Gregor Wergen
Teamleiter Methoden-
und Produktmanagement
parcIT GmbH

Ausgangslage und Herausforderungen

Die Marktrisikoeermittlung im Kontext der ökonomischen Perspektive der Risikotragfähigkeitsbetrachtung stellt insbesondere kleine und mittlere Finanzinstitute vor neue Herausforderungen und wird als Teil einer monatlichen Risikoberichterstattung regelmäßig durch eine historische Simulation von Risikoszenarien abgebildet.

Eine Besonderheit im deutschen Bankenumfeld ergibt sich aus gesetzlich verankerten Kündigungsrechten für Darlehen mit Zinsbindungen von mehr als 10 Jahren (§ 489 BGB). Je nach Modellierung dieser kreditnehmerseitigen Optionalität ist für die Berücksichtigung im barwertigen Markt- bzw. Zinsrisiko die finanzmathematische Bewertung von komplexen Mehrfachkündigungsrechten erforderlich. Auch im Eigengeschäft des Bankportfolios können solche bermudischen Optionen enthalten sein, z. B. auch in Form von Hedge-Derivaten innerhalb von Spezialfonds.



Dr. Alexander Malinowski
Manager
d-fine GmbH

Die Bewertung solcher Optionalitäten ist selbst für kleine Portfolios mitunter sehr rechenintensiv und kann zu sehr langen Rechenlaufzeiten, stark beanspruchter Hardware und weiteren technischen Performance-Herausforderungen führen.

Lösungsansatz

Zur Beschleunigung dieses Vorgangs wurde in Zusammenarbeit mit der d-fine GmbH, einem Beratungsunternehmen mit Fokus auf analytisch-technisch anspruchsvolle Themen, im Rahmen einer Machbarkeitsstudie ein prototypisches, auf maschinellem Lernen basierendes Verfahren zur approximativen Bewertung dieser komplexen Finanzinstrumente entwickelt. Dieses wurde im Hinblick auf die Abwägung zwischen Geschwindigkeitsgewinnen und Rechengenauigkeit untersucht, und die Möglichkeit einer praktischen Umsetzung wurde am Beispiel unserer Standardsoftware *okular/VR-Control* evaluiert.

Resultate und Ausblick

Die entwickelte Machine-Learning-Lösung konnte durch den Einsatz von sog. "Neuronalen Netzen" maßgebliche Performance-Verbesserungen ermöglichen, ohne dabei materielle Abstriche im Hinblick auf die Bewertungsgenauigkeit oder die Qualität der Risikovorhersage zu erfordern.

An dieser Stelle sei betont, dass eine produktive Nutzung dieses Ansatzes in *okular/VR-Control* aktuell noch nicht möglich ist und eine entsprechende Umsetzung zum jetzigen Zeitpunkt auch nicht projiziert ist. Stattdessen werden aktuell andere Maßnahmen zur Performance-Verbesserung umgesetzt, die unter Verwendung etablierter Prozesse und bestehender technischer Infrastruktur Laufzeitvorteile in einer ökonomisch vorteilhaften Weise realisieren.

Value-at-Risk durch historische Simulation

Zur Prüfung der ökonomischen Risikotragfähigkeit sowie zur Risikosteuerung benötigen Kreditinstitute die Fähigkeit, das Risiko der im Bankportfolio befindlichen Produkte in einer barwertigen Perspektive zu quantifizieren. Hierfür kommen regelmäßig Risikometriken in Betracht, welche das Gesamtbankrisiko zusammengefasst ausdrücken können. Verbreitet ist hierbei der sog. "Value-at-Risk" als derjenige Verlustbetrag, welcher mit einer vorgegebenen Konfidenz und über einen festgelegten Risikohorizont nicht überschritten wird. Eine erprobte Technik, diese Risikometrik zu bestimmen, ist die historische Simulation. Dabei werden aus historisch beobachteten Marktbewegungen Szenarien generiert, die nach Anwendung auf das jeweils aktuelle Marktniveau zum Bewertungsstichtag zu einer Neubewertung (dem sog. Szenariobarwert) für jedes einzelne Produkt im Bankportfolio führen.

Unter gewissen Stationaritätsannahmen können aus der resultierenden Verteilung der Szenariobarwerte die erwarteten zukünftigen Risiken einer Bank abgeleitet werden. In der Praxis können hierbei täglich Tausende von Szenarien für Hunderttausende von Produkten berücksichtigt werden.

An dieser Stelle wird der Bedarf für die häufige Neubewertung des gesamten Portfolios sichtbar. Insbesondere für Produkte, welche alleinstehend bereits komplexe und rechenintensive Bewertungsmodelle (z. B. Monte-Carlo-Verfahren) benötigen, stellt diese wiederholte Bewertung auf Grundlage generierter Szenarien eine Herausforderung dar.

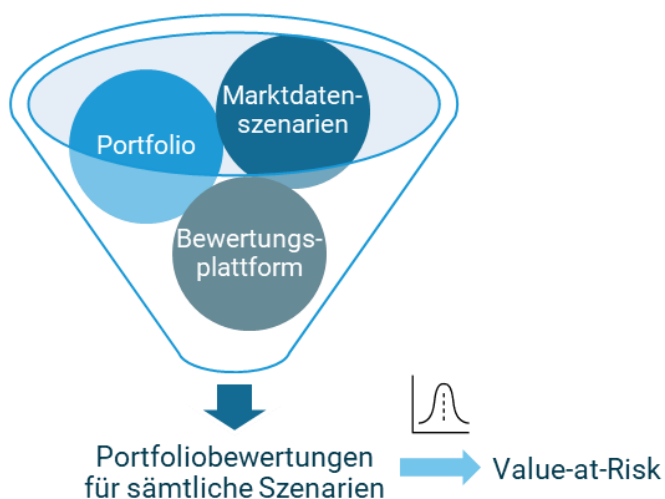


Abbildung 1: Schematischer Risikorechnungsprozess.

Bewertung von Mehrfachkündigungsrechten als tägliche Performance-Herausforderung

Eine Besonderheit des deutschen Bankenumfelds stellt das Kündigungsrecht von Darlehen nach § 489 BGB dar. Dieses ermöglicht Kreditnehmern die frühzeitige Kündigung eines Kredits mit langfristiger Zinsbindung. Die Inanspruchnahme dieses Sonderkündigungsrechts stellt aus Banksicht ein Risiko dar, da sie innerhalb vorgegebener Grenzen frei wählbar ist und regelmäßig vom Zinsumfeld zu einem möglichen Kündigungszeitpunkt abhängt.

Zur korrekten Evaluation dieses Risikos bedarf es der Darstellung des Kündigungsrechts als kreditnehmerseitige Optionalität im Bankportfolio. Dies ergänzt die bereits als Teil des Eigendepots und Handelsgeschäfts vorhandenen und zu bewertenden Mehrfachkündigungsrechte im Portfolio einer Bank.

Entsprechend komplex gestaltet sich die Bewertung dieses Portfoliobestandteils, sodass bereits eine gewöhnliche Anzahl an zu bewertenden Mehrfachkündigungsrechten sehr hohe Rechenlaufzeiten zur Folge haben kann. Dies kann somit Maßnahmen zur Beschleunigung erforderlich machen.

Optimierte Bewertung zur Reduktion der Gesamtlaufzeit der Risikorechnung

Da die Bewertung integraler Teil der Risikorechnung ist, stellt die Beschleunigung der Bewertung einen natürlichen Ausgangspunkt zur Reduktion der Rechenlaufzeit der Risikoberichterstattung dar.

Mögliche Ansätze zur Laufzeitoptimierung sind die technische Optimierung der IT-Infrastruktur sowie die mathematische Näherung der Bewertung. Ersteres stellt im Allgemeinen einen großen Eingriff in ein bestehendes System dar und erfordert umfangreiche technische Investitionen. Die zweite Möglichkeit beinhaltet stets eine Abwägung zwischen dem Grad der Beschleunigung und der Verringerung der Bewertungsgenauigkeit.

Ein im Folgenden präsentierter innovativer Ansatz, welcher nur kleine Eingriffe in ein bestehendes Bewertungssystem erfordert und dabei eine sehr hohe Genauigkeit aufrechterhalten kann, ist die Substitution der eigentlichen Bewertungsfunktionalität durch eine Machine-Learning-Lösung.

Machine Learning als innovativer Lösungssatz zur Performance-Optimierung der Bewertung

Machine Learning verwendet statistische und numerische Methoden zur automatischen Erkennung von Mustern und Gesetzmäßigkeiten in Datensätzen und kann den Bewertungsprozess unterstützen, indem die Bewertungsfunktion auf Grundlage einer umfangreichen Beispielmenge von gewöhnlich berechneten Bewertungen (approximativ) erlernt wird.

Hierbei wird nach dem erfolgten Lernprozess ("Training") eine komplexe Bewertungsfunktion durch eine Machine-Learning-Lösung abgelöst. Im konkreten Fall wurde ein "Neuronales Netz" als Grundlage zum Erlernen der tatsächlichen Bewertungsfunktion verwendet. "Neuronale Netze" können komplexe Beziehungen in Daten identifizieren und nach dem Training deutlich schneller ein Bewertungsergebnis berechnen als eine konventionelle Bewertungsmethode.

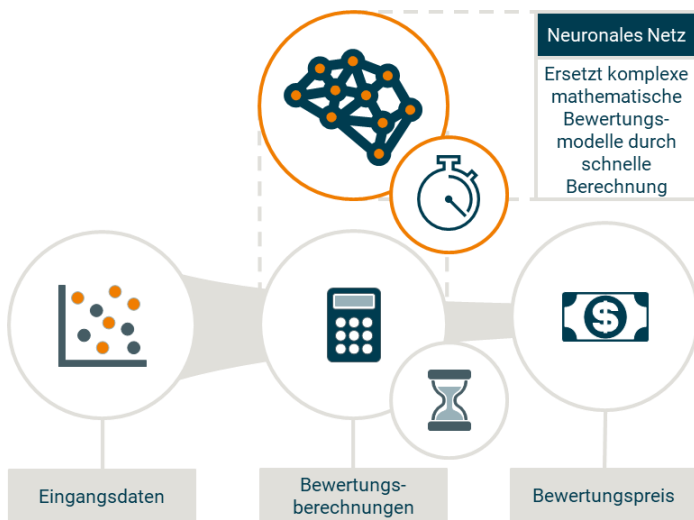


Abbildung 2: Neuronale Netze als Alternative zur konventionellen Bewertung.

✓ Implementierung neuer Ansätze in der Standardsoftware *okular/VR-Control*

Um die grundsätzliche Praxistauglichkeit für die Risiko-rechnung zu demonstrieren, wurde die entwickelte Machine-Learning-Lösung zur Bewertung von Mehrfach-kündigungsrechten prototypisch in die Standardsoftware *okular/VR-Control* integriert. Hierbei wurde die konventionelle Bewertungsfunktion vollständig durch ein trainiertes "Neuronales Netz" ersetzt.

Achtung: Eine produktive Umsetzung dieses Ansatzes in *okular/VR-Control* ist aktuell noch nicht projektiert.



Exkurs: Neuronale Netze

Technische Definition

Neuronale Netze stellen eine schichtweise Verkettung affin-linearer Funktionen (parametrisiert durch "Gewichte") und nicht-linearer Aktivierungsfunktionen ("Neuronen") auf einem potenziell hochdimensionalen Raum dar. Durch die Verkettung einfacher Funktionen kann das Modell komplexe nicht-lineare Zusammenhänge beschreiben und aus Daten extrahieren.



Analogie zum Gehirn

Durch sequenzielle Informationsverarbeitung ist das neuronale Netz, analog zum biologischen Gehirn, in der Lage, die für eine Aufgabe relevanten "Neuronen" zu identifizieren und zur Vorhersage zu verwenden.

Trainingsvorgang

Effiziente Algorithmen können Eigenschaften des neuronalen Netzes anpassen, sodass eine gewählte "Verlustfunktion" zur Beurteilung der Fehler zwischen Trainingsdaten und Modellvorhersage minimiert wird.

Bewertung durch Machine Learning

Ein "Neuronales Netz" kann als numerisch einfach auswertbare, nicht-lineare Funktion verstanden werden. Diese wird an einen Datensatz angepasst ("trainiert"), sodass sie unter Berücksichtigung der relevanten Marktdaten und Produkteigenschaften eine konventionelle Bewertung möglichst fehlerfrei nachbildet. Für die Erzeugung von Trainingsdaten werden die nachzubildenden ("korrekten") Bewertungen für eine Vielzahl von Produkten und Marktdaten-szenarien generiert, durch Verwendung des eigentlichen Bewertungsmodells. Im anschließenden Training erlernt das "Neuronale Netz" die Beziehung zwischen Marktdaten, den Produkteigenschaften sowie dem Barwert (gemäß dem eigentlichen Bewertungsmodell).

Nach dem Training ist das "Neuronale Netz" in der Lage, zu verallgemeinern, und kann damit auch noch nicht im Training berücksichtigte Marktdaten-situationen und Produkte bewerten. Das Training wird vor der eigentlichen Bewertung zentral durchgeführt; der rechenintensive Einsatz konventioneller Bewertungsmethoden ist hiernach zunächst nicht mehr notwendig. Sollten sich der Markt oder die Referenzmethodik zur Bewertung allerdings signifikant ändern, so kann ein erneutes bzw. fortgesetztes Training des "Neuronalen Netzes" erforderlich werden.

Ergebnisse der Machine-Learning-Vorstudie

Die prototypische Implementierung der Machine-Learning-Lösung als Teil der Standardsoftware *okular/VR-Control* wurde mit konventionellen Referenzmethoden zur Risikorechnung und Bewertung sowie mit einer performanten näherungsweise Bewertung verglichen. Hierbei wurde insbesondere die methodenübergreifende Übereinstimmung der resultierenden Risikokennzahlen überprüft und evaluiert.

Die Machine-Learning-Lösung konnte im Rahmen der Vorstudie die Laufzeit der Kernberechnungen der Bewertung um bis zu 99% reduzieren. Dies ist bedingt durch das vollständige Ersetzen komplexer Bewertungsmodelle durch eine trainierte Machine-Learning-Lösung. Unter Berücksichtigung weiterer Bewertungsschritte wie der Datenaufbereitung konnte die Machine-Learning-Lösung zu einer umfangreichen Laufzeitreduktion von 65% führen. Im Kontrast zu einer näherungsweise Bewertung war die Genauigkeit der Risikorechnung im Falle des "Neuronalen Netzes" nur marginal beeinträchtigt.

Vorteile von Machine Learning in der Risikorechnung

- ✓ Erhöhte Reaktionsfähigkeit durch Verringerung der Laufzeit einzelner kritischer Risikoanalysen
- ✓ Möglichkeit einer erweiterten Berichtsfrequenz durch Reduktion der Portfolio-Rechenlaufzeit
- ✓ Grundsätzliche Entlastung von IT-Systemen und damit verbundene Kostenreduktionen

Status Quo und Ausblick

Machine-Learning-Lösungen zur Risikorechnung und Bewertung konnten im Rahmen der durchgeführten Vorstudie als sinnvolle Ergänzung bestehender Methoden eingeschätzt werden. Solche innovativen Techniken bieten besonders dann hohe Vorteile gegenüber dem Status Quo, wenn Alternativen zur Performance-Optimierung nicht zur Verfügung stehen. Dies ist oftmals der Fall bei komplexen Finanzinstrumenten oder einer vielschichtigen Software-Infrastruktur zur Risikorechnung und Bewertung.

Aktuelle regulatorische Entwicklungen begünstigen zusätzlich die Adaption von Machine Learning in der Finanzwirtschaft. Zum einen resultieren aus den steigenden Anforderungen an die Risikorechnung zusätzliche Performance-Herausforderungen. Zum anderen kann Machine Learning durch die klare Positionierung der Finanzaufsicht¹ und hiermit geschaffene Transparenz im Hinblick auf die regulatorische Perspektive bezüglich innovativer Technologien immer häufiger als Ansatz in Betracht kommen, sofern ein produktiver Regelbetrieb durch gebotene Model-Governance-Prozesse unterstützt werden kann.



Exkurs: Definition eines repräsentativen Portfolios für Beispielrechnungen

Beispielportfolio

Das berücksichtigte Portfolio basiert auf dem Zinsbuch einer repräsentativen mittelgroßen Bank und den hierin enthaltenen Mehrfachkündigungsrechten.

Produktarten

Betrachtet wurden Mehrfachkündigungsrechte mit einer Laufzeit von bis zu 20 Jahren, einem variablen Einfluss der Optionalität sowie mehreren referenzierten Tilgungsarten.

Relevante Marktdatenhistorie für die Risikorechnung

Für die historische Simulation wurden die Marktdaten der vergangenen 12 Jahre bis Ende 2021 verwendet, d. h. etwa 3000 historische 1-tägige Marktdatenzenarien.




Abbildung 3: Schematische Laufzeitverteilung der Risikorechnung. Der Laufzeitblock "Numerischer Rechenaufwand" kann durch den Einsatz eines "Neuronalen Netzes" um 99% reduziert werden.

Praktische Machine-Learning-Herausforderungen

- ✓ Vorhersagen sind statistisch begründet und erfüllen nicht immer finanzmathematisch erwartbare Zusammenhänge
- ✓ Modellvalidierungsprozesse zur Interpretierbarkeit der Vorhersagen des "Blackbox-Modells" erforderlich
- ✓ Fachliches Know-how und technische Infrastruktur zur Umsetzung eines Model Lifecycle Management benötigt

¹ Z.B.: "Maschinelles Lernen in Risikomodellen", Bundesanstalt für Finanzdienstleistungsaufsicht (BaFin), 2022.

Kontakt

Dr. Gregor Wergen

Methoden- und Produktmanagement

parcIT GmbH

+49 221 584 75 170
Gregor.Wergen@parcIT.de

Dr. Alexander Malinowski

Manager

d-fine GmbH

+49 162 263 1538
Alexander.Malinowski@d-fine.de

Vertrieb

Herr Jens Engelbrecht

Beratung und Prozessmanagement

parcIT GmbH

+49 221 584 75 180
Jens.Engelbrecht@parcIT.de

parcIT GmbH

Erfstraße 15
50672 Köln

Info@parcIT.de
www.parcIT.de