




Branchensimulationsmodell trifft auf Machine Learning

qx-Club
Köln, den 05.05.2020

Johannes Fabrega, B&W Deloitte; Prof. Dr. Christian Weiß, Hochschule Ruhr West, B&W Deloitte

Einführung

Herausfordernde Fragen in Risikomanagement und Aktuariat der deutschen Versicherer

	US Corporate Bonds versprechen derzeit eine vergleichsweise hohe Rendite. Hätte ein Investment starke Auswirkungen auf unser Risikoprofil?		Was für eine Aktienquote sollen wir langfristig anstreben um von Diversifikationseffekten maximal zu profitieren?
	Wie wäre es, wenn wir die Duration unseres Bond Portfolios deutlich verlängern, sodass es besser zu unserem Passiv-Bestand passt?		Welche neue Geschäftsstrategie kann uns nachhaltig gegen das langandauernde Niedrigzinsumfeld wappnen?
	Wir kennen die Kapitalmarktsituation in drei Jahren noch nicht. Wie können wir in unserer Planung alle realistischen Szenarien einbeziehen?		Unsere Schätzung für die Solvenzquote zum Jahresende lag weit entfernt vom tatsächlichen Ergebnis. Wie können wir das in Zukunft verbessern?

Die Suche nach zufriedenstellenden Antworten führt zu neuartigen Lösungen.

Aktuarielle Risikomodelle

Aktuarielle Risikomodelle wie das **Branchen-simulationsmodell** (BSM) sind mächtige Tools für Analysen, etwa von Investmententscheidungen und Anlagestrategien, denn sie enthalten:


- die Kapitalanlagen
- die Versicherungsverträge
- Parameter für Management-Entscheidungen

aber:

- Aktuarielle Risikomodelle sind extrem laufzeitintensiv und daher unflexibel.
- Jeder Berechnungslauf muss oft manuell eingerichtet werden und benötigt viele Simulationen.
 - **Budget reicht nur für einzelne Sensitivitäten.**




Monte-Carlo-Ansatz





Bislang:

- Einzelne, isolierte Sensitivitäten
- Äußerst rechenintensiv
- Vollständige Modellberechnung für jede einzelne Sensitivität




Monte-Carlo-Ansatz:

- Berücksichtigung von Aktiva, Passiva, Management-Strategien und Kapitalmarkt
- Beliebige Kombinationen von Parametern
- Einmalige Kalibrierung – instantane Auswertungen



Herausforderndes Regressionsproblem

- **Ungenauigkeit** einzelner Fittingpunkte (Rauschen)
- **Wechselwirkungen** zwischen den Dimensionen des Parameterraumes
- **Komplexe Abhängigkeitsstruktur** (oft nicht glatt)
 - Konventionelle Ansätze liefern keine stabilen und präzisen Ergebnisse.



Lösung:
Moderne Machine Learning Algorithmen



Machine Learning Techniken (1/3)

Informationskriterium AIC

Akaike Informationskriterium (AIC)

Klassische Statistik

Schätze den **unbekannten Parameter einer bekannten Verteilung**, z.B. die Varianz einer normalverteilten Zufallsvariable

SCR Schätzung

Schätze **die unbekannten Koeffizienten einer unbekannten approximierenden Funktion**, z.B. eines Polynoms

- Es sind also **zwei simultane Aufgaben** zu erledigen: Finde beste approximierende Funktion **und** gleichzeitig deren beste Koeffizienten
- Das **Akaike Informationskriterium AIC** vergleicht die Güte des Fits unterschiedlicher Modelle



Hirotugu Akaike (1927 – 2009)

Bildquelle:
Wikipedia

Mathematischer Hintergrund


Satz (Akaike, 1973):

Das AIC ist ein erwartungstreuer Schätzer für die **Kullback-Leibler Divergenz**, das heißt, es ist ein Maß dafür wie gut eine gegebene Funktion f mit k Parametern eine andere unbekannte Funktion g annähert. Sind die Fehler der Regression normalverteilt, so gilt


$$AIC = n \log \left(\frac{RSS}{n} \right) + 2k$$

- Der erste Term in AIC misst die Güte des Modelfits (je kleiner die Abweichung, desto kleiner AIC)
- Der zweite Term „bestraft“ komplexe Modelle (je mehr Parameter, desto größer AIC)

Overfitting



Algorithmus zum Auffinden einer optimalen Funktion



- Teste jedes **"Kandidaten-Modell"**
- Der beste Term von den möglichen Kandidaten wird zur Funktion hinzugefügt
- **Multiple Regression**
- jedes mal wird nur ein einziger weiterer Term hinzugefügt

Machine Learning Techniken (2/3)

Random Forests

Random Forests

Einführung

- Der Begriff *Random Forests* wurde 1999 von **Leo Breiman** geprägt.
- Es ist ein klassisches Verfahren des Machine Learnings, das insbesondere zu Zwecken der **Klassifizierung** und zur **Regression** eingesetzt wird.
- Beruht auf der Verknüpfung von mehreren **Entscheidungsbäumen**, die in einem zufälligen Lernprozess gewachsen sind (**random subspace method**).

Vorteile


- **Geringer Zeitaufwand** für die Kalibrierung
- Es kann eine **sehr hohe Anzahl von Inputs** verwendet werden
- Als Ergebnis erhält man eine Einschätzung darüber, **welche Variablen besonders wichtig sind**




Leo Breiman (1928 – 2005)

Bildquelle:
Wikipedia

Entscheidungsbäume




- Allgemein: Ein **Entscheidungsbaum** ist eine Abfolge von Tests auf ein mögliches Ergebnis, um am Ende eine Vorhersage zu machen.
- Wenn die Ausgabevariable Werte in einem Intervall annehmen kann, spricht man von einem **Regressionsbaum**
- Regressionsbäume können zur Lösung von Regressionsaufgaben eingesetzt werden



Quelle (bearbeitet): <https://towardsdatascience.com/https-medium-com-lorli-classification-and-regression-analysis-with-decision-trees-c43cdb5805412>

Ensemble Techniken

- Ein **Random Forest** verknüpft verschiedene Entscheidungsbäume
- Jeder einzelne Entscheidungsbaum macht eine eigene Vorhersage
- Die finale Vorhersage bei den Regressionsbäumen wird durch **Durchschnittsbildung** gemacht
- Die standardmäßig genutzte Ensemble Technik ist also **Bagging**, weil verschiedene Modelle parallel laufen
- Oft werden Random Forests mit der **Boosting**-Technik kombiniert



Machine Learning Techniken (3/3)

Neuronale Netze

Neuronale Netze & Deep Learning

Warren McCulloch & Walter Pitts, 1943


erste Idee für ein künstliches neuronales Netz, aus verknüpften elementaren Einheiten
zur Berechnung logischer und arithmetischer Funktionen

Frank Rosenblatt, 1958


Neurocomputer *Marc I Perceptron*: Multi-Layer Perceptron

Idee: Sehr viele Berechnungseinheiten, die erst durch ihre Interaktion „intelligent“ werden

- Seitdem ein stetes Auf und Ab: Hypes und Ernüchterungen
- Boom seit ca. 10 Jahren durch den enormen Anstieg an Rechenkapazität




Warren McCulloch and Walter Pitts




Frank Rosenblatt

Neuronale Netze: Motivation aus der Gehirnforschung



Bildquelle: Wikipedia

Input – Versteckte Schichten – Output



Komponenten:

- Input Layer & Input Werte x_i
- Versteckte Layer a
- Output Layer & Output Werte y_i
- Aktivierungsfunktion φ
- Gewichte w_{ij}

Typische Aktivierungsfunktionen:

- Tangens Hyperbolicus
- Logistische Funktion

$$f(x, \theta) = 1 / (1 + e^{-(x - \theta)})$$
- Rectified Linear Unit (ReLU)

$$f(x, \theta) = \max[0, x - \theta]$$
- Leaky ReLU

$$f(x, \theta) = \max(a(x - \theta), x - \theta)$$

Training des Netzes

- **Ausgangsfrage:**

- Gegeben sei eine Datenmenge bestehend aus Paaren (Input, Zielwert). Welche Stellschrauben gibt es um das Netz so zu optimieren, dass die Zielwerte bestmöglich reproduziert werden?

- **Antwort:**

- Passe die Gewichte so an, dass sich der Output mit jedem neuen Paar ein Stück weiter in Richtung der Zielwerte bewegt.

- **Mathematische Grundidee:**


- Verwende das Gradientenabstiegsverfahren, um die Abhängigkeit des Fehlers von den Gewichten zu verringern

$$w_{ij}^{neu} = w_{ij}^{alt} - \eta \frac{\partial Err}{\partial w_{ij}}$$


Umsetzung für das Branchensimulationsmodell

Illustration anhand eines Beispiels

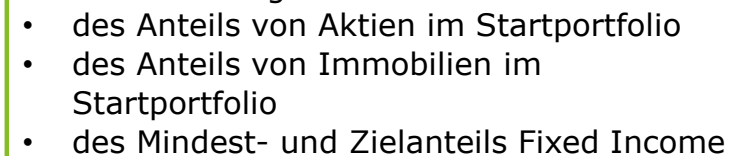
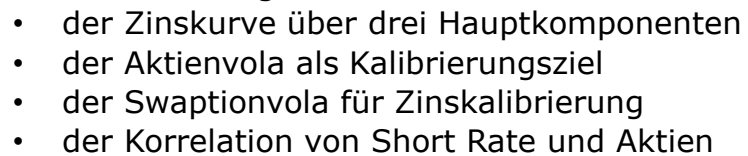
Automatisierung des BSM




- Konstruktion der Zinskurve aus Hauptkomponenten
- Extrapolation nach Smith-Wilson
- Kalibrierung der Modelle
- Szenarien-Generierung unter Korrelationen



- Aufteilung der Aktiva zum Stichtag
- Anpassung zeitabhängige und zeitunabhängige Managementregeln
- Automatisierte und vollständig parallelisierte Läufe




Exemplarische Analyse BSM: Aktien



- Modelliert wird Umschichtung zwischen **Aktien** und **Fixed Income** („risikofrei“) zum Berechnungstichtag
- **Asymmetrie des Geschäftsmodells** bewirkt negativen Einfluss von erhöhter Aktienvolatilität
- Dieser Effekt steigt mit zunehmendem **Aktienanteil**
- Für hypothetische Aktienvolatilität von Null existieren nur noch bilanzielle und **Durations-Effekte**

Exemplarische Analyse BSM: Aktien



- PC1 bewirkt im Wesentlichen **Parallelverschiebung** der **Zinskurve**
- **Duration Passiva** größer als Duration Aktiva
- Hoher Aktienanteil bewirkt weitere **Verkürzung** der aktivseitigen **Duration**
- In **Niedrigzins-Szenarien** schadet dies zusätzlich den Ergebnissen
- In **Hochzins-Szenarien** wird negativer Effekt durch erhöhte Volatilität durch positiven Effekt aus Durationsverkürzung überkompensiert

Fallstudie BSM: Vergleich Regressionsmethoden

	Mean Absolute Error
Informationskriterium AIC	0,13 %
Random Forest (XGB)	0,18 %
Künstliches Neuronales Netz	0,13 %
Validierungspunkte (1k Sim)	0,07 %

50k Trainingsdaten mit je 2 inneren Simulationen, Fehler in % des Marktwerts der Aktiva zu t=0

- Auswertung auf 80 zufällig im Fittingraum verteilten Out-Of-Sample-Validierungspunkten
- AIC und künstliche neuronale Netze mit höchster Güte
- Ungenauigkeit der Predictions fast im Bereich des Fehlers der Validierungspunkte
- Weiteres Optimierungspotential bei Entscheidungsbäumen

Welcher der Algorithmen die besten Ergebnisse liefert hängt sehr stark vom individuellen Problem ab.
→ Der optimale Weg ist jeweils ein Vergleich aller Varianten.

Kontakt



Prof. Dr. Christian Weiß

Externer Berater

Aktuar DAV

B&W Deloitte GmbH

Magnusstraße 11

50672 Köln

Tel. +49 (0)151 11 66 52 66

E-Mail: chrweiss@deloitte.de



Johannes Fabrega y Escatllar

Manager

Aktuar DAV

B&W Deloitte GmbH

Magnusstraße 11

50672 Köln

Tel. +49 (0)221 97324 520

E-Mail: jfabrega@deloitte.de