

Machine and deep learning in present actuarial challenges

Zusammenfassung der Dissertation an der Universität Ulm

Mark Kiermayer

In den vergangenen Jahren haben Methoden des maschinellen Lernens, insbesondere neuronale Netze, ihren Mehrwert in zahlreichen Anwendungsgebieten gezeigt. In der Versicherungsbranche ist der Einsatz dieser Methoden insgesamt allerdings wenig verbreitet. Die vorliegende Dissertation untersucht daher die Einsatzmöglichkeiten und Vorteile von maschinellem Lernen für drei aktuarielle Problemstellungen, nämlich das Verdichten von Versicherungsportfolien, die Analyse von Stornorisiken und das Kalibrieren verborgener Markovketten. Verbesserungen in den jeweiligen Bereichen haben unmittelbare Auswirkungen auf das aktuarielle Risikomanagement, etwa in Form der Kapitalreserve nach Solvency II oder einer verbesserten, internen Überwachung des Risikos, wie etwa in Paper 3.

Insgesamt konnte in allen drei Projekten der Mehrwert von maschinellem Lernen unter Beweis gestellt werden. Eine theoretische Analyse der Problemstellung bildet jeweils die Grundlage für die Konstruktion und Analyse neuer Modelle. In Paper 3 wird zudem erstmals eine Lösung für einen neuartigen, praxisrelevanten Anwendungsfall präsentiert.

Im Folgenden werden konkrete Inhalte und zentrale Ergebnisse der einzelnen Papiere der kumulativen Thesis präsentiert.

Papier 1 – Grouping of contracts in insurance using neural networks

Die Solvency II Richtlinie fordert u.a. die Ermittlung der vollständigen Verteilung der Verlustvariable, zur Bestimmung der Kapitalreserven. Aufgrund der Komplexität dieser Aufgabe sind hierbei in der Praxis Vereinfachungen notwendig. Eine Bestandsverdichtung bezeichne hierbei eine Vereinfachung des Versicherungsportfolios, d.h. eine Reduktion von (verschiedenartigen) Versicherungsverträgen bei einem Erhalt von wesentlichen, ausgewählten Eigenschaften des Portfolios.

Im Papier 1 wird das vorliegende Problem zunächst, zum ersten Mal in der Literatur, mathematisch formalisiert und in eine Aufgabenstellung für

überwachtes Lernen überführt. Hierbei findet die Berechnung der Verdichtungsgüte nicht nachgelagert, sondern während dem Verdichtungsprozess statt. Das Ermitteln der Verdichtung enthält zwei wesentliche Schritte:

1. Bestimmen eines Schätzers \hat{f} der die ausgewählten Eigenschaften eines Portfolios (approximativ) bestimmen kann.
2. Ermittlung von Modellpunkten, d.h. Verträge im verdichteten Bestand, so dass die Eigenschaften des tatsächlichen Portfolios bestmöglich erhalten werden.

Für beide Schritte werden neurale Netze verwendet. Dies führt methodisch zu einem verschachtelten neuronalen Netz, bei welchem durch ein Gradientenabstiegsverfahren Modellpunkte optimiert werden. Diese Methodik kann sowohl ganzheitlich für das komplette Portfolio, sowie schrittweise für einzelne Segmente bzw. Cluster verwendet werden. Allgemein lässt sich dieser Ansatz als eine ökonomische Verallgemeinerung von K-means clustering beschreiben, mit der Option fuzzy clustering durchzuführen.

Final wird die Qualität des Ansatzes numerisch untersucht, jeweils für ein Portfolio aus Risikolebensversicherungen und betrieblichen Pensionsverträgen. Die Verdichtungsgüte wird hierbei mit einem K-means clustering Algorithmus verglichen, welcher eine in der Praxis gängige Referenz darstellt. Hierbei erhalten wir folgende, zentrale Ergebnisse:

- Neuronale Netze liefern eine bessere Verdichtungsgüte, welche stabiler ist, insbesondere für höhere Verdichtungsgrade.
- Expertenwissen, wie etwa das Verdichten je Zinssegment, kann problemlos in das Verfahren eingebunden werden.
- Bestandsverdichtungen durch neuronale Netze zeigen sich als robuster gegenüber von Zinsschocks in Bezug auf den Investitionsüberschuss.

Papier 2 – Modelling surrender risk in life insurance: theoretical and experimental insight

Die Solvency II Richtlinie erfordert u.a. den Ausweis des Risikos einzelner Submodule, wie etwa Storno, welches allgemein als wesentliches Risiko anerkannt wird. Die Analyse von Stornorisiken ist allerdings erschwert durch sehr produkt- und länderspezifische Stornoverhalten der Kunden und die Imbalance der Daten.

Das vorliegende Papier behandelt hierzu drei Aspekte:

1. Die numerische Untersuchung von Methoden des maschinellen Lernens für eine Vielzahl von Stornoverhalten.
2. Eine theoretische und numerische Analyse der Auswirkungen von Resampling, d.h. einer gängigen Methoden um die Imbalance von Daten zu beheben.
3. Die Herleitung und Anwendung von Konfidenzbändern zur Stornomodellierung für nicht identisch verteilte Daten.

Für eine Vielzahl verschiedener, simulierter Stornoverhalten wird die Modellgüte von GLMs, baumbasierten Verfahren und neuronalen Netzen untersucht. Gängige Ensemble-Methoden, d.h. Bagging und Boosting, werden verwendet. Die Modelltypen XGBoost und neuronale Netze finden in der Literatur in diesem Kontext bisher kaum Verwendung. Insgesamt zeigen v.a. baumbasierte Modelle exzellente Ergebnisse bei der Modellierung der Stornowahrscheinlichkeiten, in Form von geringer Verzerrung und geringer Varianz. Zudem sind baumbasierte Modelle in den Experimenten robuster, etwa in der Anwesenheit von nicht-stationärem Rauschen. Allgemein zeigt sich zudem der Mehrwert einer impliziten, hierarchischen Verarbeitung der Vertragseigenschaften bei neuronalen Netzen und baumbasierten Verfahren, im Gegensatz zu GLMs.

Ein weiterer Fokus der Arbeit ist die Imbalance der Stornodaten, welche die Modellierung erschwert. Gängige Resampling-Methoden, wie etwa random over- oder undersampling oder SMOTE, haben in der Literatur ihre Fähigkeit gezeigt frequentistische Metriken, wie die Genauigkeit oder den F_1 -Wert, zu verbessern. Die numerischen Analysen in Papier 2 bestätigen dies. Theoretische, siehe Lemma 1 und 2, und numerische Analysen, siehe Kapitel 7, zeigen allerdings die Folgen dieser Methoden für die Modellierung. Stornowahrscheinlichkeiten werden systematisch überschätzt und beschreiben, im Streudiagramm mit den echten Wahrscheinlichkeiten, eine konkave Kurve. Dies zeigt, dass Resampling – und eine potentielle Verbesserung frequentistischer Metriken – im Widerspruch steht zu einer konsistenten Modellierung von

Stornowahrscheinlichkeiten. Letzteres ist elementar, um Risiken angemessen quantifizieren zu können, etwa durch den value-at-risk.

Als alternative Bewertung der Modellgüte wird zudem eine zeitabhängige Auswertung der durchschnittlichen Stornorate, inklusive Konfidenzbändern, eingeführt. Diese Konfidenzbändern sind approximativ und basieren auf dem Grenzwertsatz von Lindeberg-Feller, da die zugehörigen Zufallsvariablen nicht identisch verteilt sind. In der Anwendung zeigt diese Modellbewertung ihren Mehrwert, da Modelle in einer fortlaufenden Konzernperspektive Konfidenz-bezogen bewertet werden können. Dies liefert zudem ein diagnostisches Werkzeug, da sich im Zeitverlauf verschlechternde Modellgüten auch verändernde Kundenverhalten signalisieren können.

Papier 3 – Neural calibration of hidden inhomogeneous Markov chains

Die Migration eines Bestandes in eine neue IT Infrastruktur kann Versicherungsunternehmen zahlreiche Vorteile bieten, wie etwa ein effizienteres Speichern und Abrufen von Daten. Eine derartige Migration muss allerdings nachweislich konsistent gestaltet werden. Auf einem konkreten Datensatz von msg life central europe wird in Papier 3 ein automatisierter Konsistenztest entwickelt und getestet. Dazu wird eine Markovkette kalibriert, so dass deren Übertrittswahrscheinlichkeiten den Wahrscheinlichkeiten entsprechen, welche bei der Zeichnung von Versicherungsverträgen in einem Datensatz verwendet wurden. Dies ermöglicht den Vergleich ob Annahmen in der Zeichnung konsistent in das neue IT System übertragen wurden. Der Datensatz aus Versicherungsverträgen enthält hierbei keine Beobachtungen zu Zustandsübertritten oder den wahren Übertrittswahrscheinlichkeiten, sondern lediglich Vertragseigenschaften. Die wahre Markovkette ist daher verborgen und potentiell inhomogen. Ein derartiges Problem wurde in der Literatur bisher nicht behandelt oder gelöst.

In Papier 3 wird zunächst der Zusammenhang zwischen (inhomogenen) Markovketten und der fairen Bewertung von Versicherungsverträgen herausgearbeitet. Darauf aufbauend lässt sich die Kalibrierung der – den Verträgen implizit zugrundeliegenden – Markovkette als eine Aufgabenstellung für überwachtetes Lernen überführen. Zentral ist hierbei das Einführen von zeit- und zustandsabhängigen Zahlungsströmen, welche aus zeitunabhängigen Vertragseigenschaften abgeleitet werden.

Methodisch hat dieser Ansatz Ähnlichkeiten mit Belohnungen im Reinforcement Learning.

In der Optimierung kann das Problem somit durch das Minimieren des empirischen Risikos via Gradientenabstiegsverfahren gelöst werden. Die Verlustfunktion ist hierbei die versicherungsspezifische, faire Bewertung eines Vertrages. Um die resultierenden Übertrittswahrscheinlichkeiten quantitativ validieren zu können, lassen sich mit dieser Verlustfunktion zudem effizient Prämienbeträge – basierend auf der kalibrierten Markovkette – bestimmen und mit tatsächlichen Prämienbeiträgen vergleichen.

Für einen konkreten Datensatz für Risikolebensversicherungen von msg life central europe wird außerdem ein neuronales Netz entwickelt, welches die Aufgabenstellung lösen kann. Hierbei wird eine rekurrente Architektur verwendet. Techniken wie Transferlernen und Boosting werden genutzt, um das Optimierungsproblem zu stabilisieren. Für eine sinnvolle Initialisierung werden DAV Tabellen für männliche und weibliche Versicherungsnehmer:innen verwendet, um diese dann lokal auf den konkreten Datensatz anzupassen.

Eine qualitative Analyse offenbart für den Datensatz eine homogene Markovkette mit unisex-Tarif und einem Risikoaufschlag für einen Raucherstatus. In der quantitativen Analyse berechnen wir (geschätzte) Prämienbeiträge, basierend auf der kalibrierten Markovkette, und betrachten die relativen Fehler zu den tatsächlichen Prämienbeiträgen im Datensatz. Abweichungen sind stark konzentriert und zentriert um den wahren Wert und streuen in der Bandbreite von ca. +/- 5%. Diese Abweichungen sind bemerkenswert gering, in Hinblick auf ca. 40.000 zu kalibrierende Übertrittswahrscheinlichkeiten bei 10.000 Versicherungsverträgen im Datensatz.