

# **Einsatz von maschinellen Lernverfahren zur Bewertung von Kundenverhalten in der Lebensversicherung**

## **Einleitung und Problemstellung**

Das Kundenverhalten von Versicherungsnehmer:innen hat einen erheblichen Einfluss auf das Management von Lebensversicherungsverträgen. Insbesondere die Storno-Optionen (aber z.B. auch die Beitragsfreistellung) beeinflussen künftige Zahlungsströme immens, sodass die Modellierung aus Sicht des Risikomanagements von entscheidender Bedeutung ist. Auch unter Solvency II wird Storno als zentrales Risiko eingestuft – konkret bildet Storno das wichtigste Untermodul des versicherungstechnischen Risikos, welches wiederum nach dem Marktrisiko als zweitwichtigstes Modul bewertet wird.

Die wissenschaftliche Literatur betrachtet sehr selten personen- und vertragsindividuelles Kundenverhalten (insbesondere, weil entsprechende Daten oft nicht für die Forschung zur Verfügung stehen), obwohl dieses Verständnis für eine gute Prognose und Modellierung notwendig ist. Stattdessen werden meistens makroökonomische Effekte analysiert, z.B. ob Zinsanstiege zu höheren Stornoquoten führen, da Versicherte den Rückkaufswert in profitablere Produkte investieren können (*interest rate hypothesis*). Die wenigen Arbeiten, die vertragsindividuelles Kundenverhalten analysieren nutzen meist sehr einfache GLMs, survival analysis Modelle oder Black-Box-Modelle (z.B. Random Forest).

In der Praxis treffen Modelle in Bezug auf das Kundenverhalten häufig ebenfalls vereinfachte Annahmen (z.B. univariate Modellierung). Präzisere Modelle auf Basis von GLMs sind zwar möglich, benötigen jedoch ein hohes Maß an manuellem Aufwand, z.B. Selektion der relevanten Merkmale und Merkmalsstrukturen. Wenn beispielsweise das gängige Merkmal „Alter“ betrachtet wird, erhält dieses in einem einfachen GLM einen einzigen Parameter. Somit sind nur rudimentäre Strukturen (nämlich linear steigend oder fallend) abbildbar. Um die Prognose zu verbessern, wird das Alter somit häufig nicht als numerische Größe interpretiert, sondern als Faktor mit vielen Ausprägungen (z.B. eine Ausprägung pro Alter). Das GLM schätzt dann einen Parameter pro

Ausprägung, was in der Praxis aber häufig zu granular ist und bestehende Effekte eher auswendig lernt, als zugrundeliegende Strukturen zu erkennen. Deshalb beginnt hier ein manueller Prozess, einzelne Altersgruppen zusammenzulegen, um ein gutes Mittelmaß zwischen den beiden Extremen zu finden. Aufgrund der multivariaten Fragestellung hat eine Anpassung an einem Merkmal (z.B. Altersgruppierung) aber auch Auswirkungen auf andere Merkmale. Somit ist mit jeder Anpassung eine Neukalibrierung des gesamten Modells notwendig. Insgesamt ist der Prozess also nicht nur manuell, sondern auch iterativ und dadurch zeitintensiv und anfällig für Overfitting.

Gleichzeitig scheiden gängige Black-Box Machine-Learning-Verfahren (z.B. Neuronale Netze oder baumbasierte Verfahren) aufgrund der ungenügenden Erklärbarkeit, auch gegenüber der Aufsicht, aus.

Diese Arbeit adressiert diese Lücken und stellt innovative, datengetriebene und automatisierbare maschinelle Lernverfahren auf Basis regularisierter GLMs vor, um damit das Kundenverhalten in der Lebensversicherung präzise modellieren zu können. Insbesondere das Lasso-Verfahren zeigt sich hierbei als besonders nützlich, da durch die Variablenelektion implizit die für viele Anwendungen entscheidende Interpretierbarkeit der Modellprognosen verbessert wird.

**Reck, L., Schupp, J. and Reuß, A. (2023). Identifying the Determinants of Lapse Rates in Life Insurance: an automated Lasso Approach. European Actuarial Journal, 13(2): 541-569.**

Um die oben beschriebene Problemstellung zu beantworten, wird im ersten Artikel Storno als binäre Zielgröße (Storno/kein Storno) analysiert. Die Daten stammen von einem europäischen Lebensversicherer im Run-Off. Die Methodik lässt sich aber ohne Weiteres auch für Versicherer, die nicht im Run-Off sind, anwenden. Der Datensatz enthält etwa eine halbe Millionen Beobachtungsjahre von etwa 100.000 Verträgen. Es werden 13 erklärende Merkmale betrachtet, welche gewöhnliche aktuarielle Größen wie Alter, Geschlecht, Versicherungssumme, etc. beinhalten.

Methodisch baut der Artikel auf bestehenden GLMs und Lasso-Ansätzen auf. Konkret werden drei Bestrafungsterme auf Basis der für das Lasso typischen L1-Norm verwendet: Erstens, das reguläre Lasso, welches die Differenz zum sogenannten Intercept bestraft. Diese Bestrafung wird vor allem für Merkmale ohne Ordinalskala verwendet (z.B. Land). Sie kann verwendet werden, um Merkmale zu identifizieren, die gemeinsam mit dem Intercept modelliert werden können, also keinen separaten Schätzer benötigen. Zweitens, das fused Lasso, welches die Differenz zweier

benachbarter Ausprägungen bestraft. Die Bestrafung ist insbesondere für Merkmale nützlich, bei denen gewisse Ausprägungen gruppiert bzw. auf ein Niveau zusammengefasst werden sollen (z.B. Alter). Drittens, das trend filtering, welches als Erweiterung des fused Lasso interpretiert werden kann und Änderungen im linearen Trend zwischen Ausprägungen bestraft. Die Bestrafung ist also insbesondere für numerische Merkmale mit stückweise linearen Abhängigkeiten hilfreich (z.B. abgelaufene Vertragsdauer). Die Bestrafungen können pro Merkmal vorgegeben werden und das Modell identifiziert automatisch und datengetrieben alle relevanten Ausprägungen, Niveaus, bzw. lineare Trends. Die Stärke der Bestrafung kann durch einen Hyperparameter  $\lambda$  vorgegeben und kontrolliert werden. Je nach Anwendung gibt es hierfür unterschiedliche Konfigurationsmöglichkeiten. Wir zeigen außerdem, wie Interaktionen effizient im Modell berücksichtigt werden können, um die Prognose weiter zu verbessern.

Der Artikel zeigt, dass der Lasso-Ansatz mit erweiterten Strukturen eine signifikante Verbesserung gegenüber univariaten Glättungsverfahren, klassischen GLMs und Black-Box-Verfahren bietet. Gegenüber univariaten Glättungsverfahren verbessert sich die Vorhersagegenauigkeit durch den multivariaten Ansatz immens. Gegenüber dem klassischen GLM reduziert sich die Modellkomplexität deutlich (knapp die Hälfte der Koeffizienten) bei vergleichbarer Vorhersagegenauigkeit. Außerdem wird der gesamte Ablauf, um ein geeignetes GLM zu erhalten datengetrieben automatisiert. In der Praxis ist dies ein hochgradig manueller, iterativer und zeitintensiver Prozess, um zu einem GLM vergleichbarer Qualität zu kommen. Gegenüber Black-Box-Verfahren bietet der Lasso-Ansatz ein sehr hohes Maß an Interpretierbarkeit, sodass die wesentlichen Treiber identifiziert und erklärt werden können.

**Reck, L., Schupp, J. and Reuß, A. (2025). Multistate Analysis of Policyholder Behaviour in Life Insurance - Lasso based Modelling Approaches. Risks, 13(4), 73.**

Im zweiten Artikel wird auf der zugrundeliegenden Methodik aus dem ersten Artikel aufgebaut und auf eine allgemeinere Zielgröße mit mehreren Zuständen des Kundenverhaltens angewandt. Neben reinem Storno wird nun insbesondere auch die Beitragsfreistellung analysiert. Diese ist aus Sicht des Versicherungsnehmers eine weniger endgültige Option, kann aber teilweise als Vorstufe eines folgenden Stornos gewertet

werden. Die gemeinsame und konsistente Modellierung dieser Zielgrößen ist deshalb naheliegend. Aus Sicht des Versicherers fließen auch hier keine weiteren Beitragseingänge, sodass dies ebenfalls eine der materiellsten VN-Optionen darstellt. Auch weitere Zustände wie beispielsweise Wiederinkraftsetzung oder Teil-Storno könnten analog modelliert werden.

In diesem Artikel diskutieren und vergleichen wir quantitativ und qualitativ verschiedene Möglichkeiten mehrere VN-Optionen gemeinsam und konsistent zu modellieren. Eine direkte Konsequenz dieser Modellerweiterung ist beispielsweise der Umgang mit der Vertragshistorie. Da bei der Betrachtung im ersten Artikel nur aktiv (A) und Storno (S) möglich war und Storno ein Endzustand war, gab es auch keine Vertragshistorie – der Vertrag galt so lange als aktiv, bis dieser storniert wurde (falls überhaupt). Mit mehreren Zuständen ergeben sich hingegen unterschiedliche Vertragshistorien und Übergänge. Es gibt mehrere Möglichkeiten, wie die Historie im Modell integriert werden kann. Eine intuitive Möglichkeit ist die Aufnahme eines weiteren erklärenden Merkmals, in dem der letzte Zustand gespeichert wird (Markov-Annahme).

Modellseitig gibt es im Wesentlichen zwei Möglichkeiten, mit mehreren Zuständen umzugehen: holistische Modellansätze, die direkt eine Zielgröße mit mehreren Ausprägungen verarbeiten können, oder Zerlegungsstrategien, die die zugrundeliegende Fragestellung in mehrere binäre Probleme unterteilen. Beim holistischen Ansatz kann eine multinomiale logistische Regression (MLR) verwendet werden. Bei den Zerlegungsstrategien werden drei Möglichkeiten verglichen: One-versus-One, One-versus-All und schließlich hierarchische Ansätze. Für alle Zerlegungsstrategien gilt, dass die Ergebnisse der einzelnen binären Modelle noch passend aggregiert werden müssen, um auf eine Gesamtvorhersage pro Vertrag zu kommen. Sowohl bei der MLR als auch bei den binären Modellen der Zerlegungsstrategien werden außerdem die erweiterten Lasso-Bestrafungen angewandt.

Der Artikel zeigt, dass sich auch für mehrere Zustände eine Lasso-basierte Modellierung sehr gut eignet. Insgesamt bietet eine MLR mit entsprechenden (Lasso-) Bestrafungs-Termen eine optimale Balance aus

Interpretierbarkeit, Modellleistung und der konsistenten Möglichkeit, noch weitere Zustände hinzuzufügen.

### **Reck, L. (2024). The Automation of Core Actuarial Modelling Tasks - an Analysis and Evaluation of the Lasso. Working Paper.**

Im dritten Artikel werden die Eigenschaften des erweiterten Lasso-Ansatzes mit Hilfe von simulierten Daten granular analysiert. Die simulierten Daten orientieren sich strukturell an den realen Daten des ersten Artikels, damit die Analysen realitätsnah bleiben. Die simulierten Daten bieten den Vorteil, dass weitere Strukturen und Abhängigkeiten (kontrolliert) vorgegeben werden können. Damit lässt sich die Robustheit und Flexibilität des Modells quantitativ bewerten. Die in den ersten beiden Artikeln identifizierten empirischen Stärken und Schwächen können dadurch isoliert analysiert werden.

In den simulierten Daten werden unterschiedliche marginale Strukturen für die erklärenden Merkmale vorgegeben. Hiermit können die einzelnen Bestrafungstypen (reguläres Lasso, fused lasso und trend filtering) bewertet und tiefer analysiert werden. Außerdem werden auch explizit Ausreißer bzw. Sprünge in den Randeffekten vorgegeben, um die Robustheit der einzelnen Bestrafungsterme zu beurteilen. Zuletzt werden auch Interaktionseffekte vorgegeben, um die Flexibilität des erweiterten Lasso-Ansatzes zu beleuchten. Im Artikel werden konkrete Handlungsempfehlungen zur Modellkonfiguration, zur Auswahl von Bestrafungstypen und zum Umgang mit Ausreißern und Interaktionen abgeleitet.

## **Fazit und Relevanz der Arbeit**

Die Arbeit liefert einen wesentlichen Beitrag zur versicherungsmathematischen Wissenschaft und Praxis, insbesondere im Kontext der aktuariellen Modellierung und des Risikomanagements. Durch die Integration von erweiterten Lasso-Ansätzen können bestehende interpretierbare Ansätze, die aktuell auf univariaten Modellen oder GLMs basieren, deutlich verbessert und automatisiert werden. Die Kombination aus Methodenkompetenz, datengetriebenem Vorgehen und praxisnaher Anwendung zeigt, wie moderne maschinelle Lernverfahren nachhaltig in aktuariellen Abteilungen implementiert werden und sich nahtlos in bestehende Prozesse einfügen können.