
Forschung am ivwKöln
Band 6/2020

Künstliche Intelligenz im Risikomanagement

Proceedings zum 15. FaRis & DAV Symposium am 6. Dezember 2019 in Köln

Jan-Philipp Schmidt (Hrsg.)

ivwKöln
Institut für Versicherungswesen

Fakultät für Wirtschafts-
und Rechtswissenschaften

Technology
Arts Sciences
TH Köln

Forschung am ivwKöln, Band 6/2020

Jan-Philipp Schmidt (Hrsg.)

Forschungsstelle FaRis

Künstliche Intelligenz im Risikomanagement. Proceedings zur 15. FaRis & DAV Symposium am 6. Dezember 2019 in Köln

Zusammenfassung

Über mathematische Methoden und Verfahren der Künstlichen Intelligenz wird auch in der Versicherungsbranche und speziell in den Aktuarwissenschaften zunehmend intensiver diskutiert. Dazu zählen insbesondere auch Themen des Risikomanagements der Unternehmen. Bedeutende Aspekte sind dabei die Risikomessung, die Risikobeurteilung sowie die Risikokommunikation im Zuge von Solvency II. Vor diesem Hintergrund widmen wir das 15. FaRis-Symposium der Künstlichen Intelligenz im Risikomanagement. Unsere Referenten berichten in ihren Vorträgen von verschiedenen Projekten, in denen sie Künstliche Intelligenz im Risikomanagement erfolgreich eingesetzt haben. Sie referieren über Chancen und Herausforderungen sowie über zukünftige Themenfeldern der Aktuarinnen und Aktuare in Deutschland.

Abstract

Artificial intelligence as well as machine learning methods get nowadays more and more attention in the insurance industry and, especially, in actuarial science. This affects risk management topics of insurance companies. Important aspects are the risk measurement, the risk judgement as well as the risk communication in accordance with Solvency II. We dedicated the 15th FaRis & DAV symposium to artificial intelligence in risk management. Our speakers presented in their talks, how they incorporated artificial intelligence in risk management. They talked about opportunities and challenges. They showed current and future topics of actuarial practice in Germany.

Inhalt

1 Solvency II-Prognosen mit neuronalen Netzen	2
2 Machine Learning in der aktuariellen Risikomodellierung.....	11
3 Unterstützung des Reportings durch Natural Language Generation.....	15

Hinweis:

Dieser Tagungsband fasst nur drei der insgesamt vier Vorträge zusammen, welche im Rahmen des 15. FaRis & DAV-Symposiums gehalten wurden.

Die Vortragsunterlagen zu allen vier Vorträgen können [hier](#) abgerufen werden.

1 Solvency II-Prognosen mit neuronalen Netzen

Oliver Stoll (ARCS, Zürich, in Zusammenarbeit mit SV Sparkassenversicherung, Stuttgart)

Motivation

Versicherungsunternehmen ("VU") müssen im Rahmen der EU-Solvency II-Direktive auf Quartalsbasis eine sogenannte Solvenzquote ermittelt. Diese ergibt sich aus dem Verhältnis der Eigenmittel ("AFR": Available Financial Resources) und des Risikokapitals ("SCR": Solvency Capital Requirement).

Diese Berechnung ist recht aufwändig und wird daher üblicherweise nur zu den erforderlichen Zeitpunkten (per Quartalsende) durchgeführt. Jedoch ist es für die Steuerung eines VU hilfreich bzw. sogar erforderlich, zu anderen Zeitpunkten die Solvenzquote zu kennen und insbesondere abschätzen zu können, wie Entscheide auf Unternehmensebene oder Bewegungen auf den Kapitalmärkten die Solvenzquote beeinflussen werden.

Daher besteht die Anforderung, die Quote zumindest approximativ abschätzen zu können. Mit neu verfügbaren Methoden des Machine Learnings könnte diese Quote zum Beispiel unter Zuhilfenahme von Trainingsdaten durch ein geeignetes Modell prognostiziert werden. Dies war die Kernidee der beschriebenen Fallstudie.

Es wurde ein mehrstufiges Projekt durchgeführt:

1. Erzeugung von Trainingsdaten
2. Kalibrierung eines ML-Modells mit diesen Daten und dem Ziel einer bestmöglichen Schätzung
3. Testen des Modells mit Evaluationsdaten und Backtesting anhand der bekannten "offiziellen" Quartalswerte

Datengenerierung

Damit das Modell mit Daten trainiert werden kann, muss eine größere Zahl von Datenpunkten erstellt werden. Diese Datenpunkte beinhalten die zu identifizierenden Inputgrößen (beispielsweise Zinsniveau) und die sich aus dem exakten Modell ergebenden Ausgaben (insbesondere Solvenzquote, Eigenmittel, Solvenzkapital).

Input-Daten

Potentiell könnten alle relevanten Input-Daten für die Berechnung der Solvenzquote variiert werden. Insbesondere die Erstellung der Daten auf der Liability-Seite (Cash Flows aus Risk Agility Financial Modeller) ist jedoch sehr ressourcen- und zeitaufwändig, so dass wir davon abgesehen haben, die Liability-Cash Flows als Inputs variieren. Da unser Modell sowieso nur für eine Prognose über mehrere Monate hinweg vorgesehen ist, werden sich die betreffenden Cash Flows eher wenig ändern und wir können daher auch aus fachlichen Gründen diese Vorgehensweise begründen.

Damit haben wir uns auf die Variation der Inputs auf der Aktivseite und der Managementparameter beschränkt. Die Inputparameter sollten so gewählt werden, dass sie die aktuelle Aktivseite und deren Entwicklung bestmöglich beschreiben. Wiederum aus Gründen der Modellierbarkeit wurde eine Gesamtheit von 20 Input-Parametern identifiziert.

Z. B. wurde die komplexe Zinsstrukturkurve mittels einer Hauptkomponentenanalyse durch drei Parameter abgebildet, welche (stark vereinfacht) das Zinsniveau, die Steigung und die Krümmung der Zinsstrukturkurve beschreiben.


Die modellierten Input-Parameter sind wie folgt:

Zahl der Parameter	Bezeichnung	Inhalt	Impact auf Startbilanz	Impact auf ESG-Kalibrierung
3	ZSK1-ZSK3	Zinsstrukturkurve	ja	ja
3	Vola4-Vola6	Volatilität	(nur eingeschränkt auf einige Instrumente)	ja
2	Verlust7-Verlust8	Verlustrisiko	nein	Ja
12	MR9-MR20	Parametrisierung von Managementregeln	Nein; nur Impact auf die Steuerung des BSM.	

Der Datensatz der Inputparameter soll dabei folgende Kriterien erfüllen:

- Abdeckung des vollen möglichen Wertebereichs
- Gleichmäßige Überdeckung des Wertebereichs
- Normalisierung (d. h. Skalierung auf Intervall [0, 1])
- Die Parameter sollten jeweils voneinander unabhängig sein.
 - Bei den Managementregeln ist dies teilweise nicht möglich, weil die Parameter Nebenbedingungen erfüllen müssen bzw. mehrere Parameter für die Beschreibung einer einzelnen Managementregel benötigt werden.


Die Erfüllung dieser Kriterien kann man visuell in Python sehr schön mit folgenden Übersichten überprüfen:



Visuelle Überprüfung:

Die Ausgabegrößen folgen einer **wohldefinierten Verteilung** (keine Lücken, Ausreisser*)

Korrelation ≈ 0 zwischen Variablen 1-8 und den anderen Eingabevariablen, zwischen Ausgabegrößen klar begründbar.



Die linke Graphik zeigt, dass die Wertebereiche, paarweise verglichen, unabhängig voneinander überdeckt werden.


Die rechte Graphik zeigt Korrelationen:

- Zwischen den Eingabeparametern 1-8 und allen Eingabeparametern ist die Korrelation nahe bei Null.
- Korrelationen zwischen den Managementparametern sind wie oben erläutert zu erwarten.
- Ebenso können wir die Korrelation zwischen den Ein- und Ausgabegrößen erkennen:
 - Insbesondere hat der Eingabeparameter ZSK1 einen großen Einfluss auf die Ausgabegrößen.
- EM und Quote sind positiv korreliert, SCR und Quote sowie SCR und EM negativ korreliert:

In "guten" Szenarien steigen meist die EM, das SCR sinkt und die Quote steigt, umgekehrt in "schlechten" Szenarien. Daher sind diese Korrelationen erklärbar.

Prozess der Datenerzeugung

Es wurde entschieden, einen Datensatz von ca. 10000 Datenpunkten zu erstellen. Der bisherige manuell geprägte Prozess war damit nicht mehr sinnvoll nutzbar. Daher wurde die Prozesskette stark automatisiert:



Obwohl die Laufzeiten immer noch recht hoch waren, konnte damit eine Berechnung z. B. über ein Wochenende hinweg durchgeführt werden. Trotzdem war der Aufwand weiterhin hoch, weil zum Beispiel gewisse Fehler nochmals korrigiert werden mussten und somit ein Neu-Lauf notwendig war, und weil ein anderes Mal ein Wochenendlauf abgebrochen wurde, da Updates auf die Rechner verteilt wurden und diese daraufhin zwangsweise neugestartet wurden.

Der erzeugte Datensatz umfasste somit etwas mehr als 10000 Zeilen, 20 Input-Spalten und unter anderem unsere gewünschten drei Ausgabespalten (Eigenmittel, Solvenzkapital, Solvenzquote).

Modellierung

Für die Modellierung haben wir ein Projekt mit der Software Python aufgesetzt. Python wird üblicherweise in einem Jupyter-Notebook programmiert und kann direkt aus diesem Notebook gestartet werden. Das Notebook ist eine Datei, die in einem beliebigen Webbrowser aufgerufen und von dort aus bearbeitet werden kann.

Python ist eine Programmiersprache, viele Funktionalitäten werden in sogenannten Packages bereitgestellt, die zum Beispiel eine Implementierung von neuronalen Netzen sehr vereinfachen. Es gibt Sammlungen dieser Packages, die am meisten verbreitete ist die Anaconda-Distribution. Man kann jedoch auch einzelne Packages manuell installieren und dann auf deren Zusatzfunktionen zugreifen.


Unser Datensatz wurde im Python-Projekt eingelesen, validiert und für die Weiterverarbeitung in die benötigten Datenstrukturen umgewandelt. Gerade die benötigten unterschiedlichen Formate und deren Umwandlung hat teilweise viel Zeitaufwand erfordert, weil nicht immer klar war, wie genau solche Transformationen durchgeführt werden mussten. Umgekehrt war das Erstellen der Modelle wie Random Forest und Neuronale Netzwerk vergleichsweise einfach zu bewerkstelligen.

Wir haben versucht, möglichst vielen wiederkehrenden Code in Funktionen auszulagern. Dies reduziert zum einen die Menge des Gesamtcodes und erhöht damit die Übersichtlichkeit, und macht es insbesondere einfacher, Änderungen konsistent durchzuführen (weil nur an einer Stelle etwas angepasst werden muss). Insbesondere haben wir Ausgabefunktionen geschrieben, welche Messergebnisse in eine Excel-Datei schreiben (und die Werte aktualisieren, falls dort schon vorhanden), neuronale Netze erzeugen, auswerten und evaluieren und automatisiert Ausgabegraphiken in definierte Verzeichnisse abspeichern.

Analyse

Generell erfolgt die Modellkalibration ("Training") nach der folgenden Vorgehensweise:

1. Der grösste Teil der Datensätze dient der Modellkalibrierung («Training»)
2. Der restliche Teil wird zum Test («Evaluation») herangezogen
3. Mit dem fertig kalibrierten Model können wir dann beliebige neue Input-Datensätze eingeben und eine Schätzung der Ausgabeparameter (insbesondere Solvenzquote) erhalten



Wir haben drei methodische Ansätze vertieft untersucht:


- Polynomiale Regression
- Random Forest
- Neuronale Netze

Polynomiale Regression


Als Benchmark haben wir lineare, quadratische und kubische Regressionen durchgeführt. Die lineare Regression ist offensichtlich nicht geeignet, die nicht-linearen Komponenten abzubilden. Die

quadratische Regression hat zufriedenstellende Ergebnisse geliefert. Eine kubische Regression führte jedoch zu einem massiven Overfitting und war daher nicht zu verwenden.


Linear:
 R^2 zu niedrig



Quadratisch:
Gut im Training,
Evaluation etwas schlechter



Kubisch:
Overfitting!



Random Forest

Wir haben die Performance des Modells in folgenden Varianten untersucht:

- Einzelner Entscheidungsbaum;
- Random Forest mit 1000 Bäumen;
- Random Forest mit limitierter Anzahl von Schichten;
- Random Forest mit den fünf wichtigsten Input-Parametern;
- Optimierter Random Forest durch Grid Search.

Der Standard-Random Forest mit 1000 Bäumen hat hier schon sehr gute Ergebnisse geliefert:

Results for Solvency ratio	Average maximum depth	Average number of nodes	Number of trees in forest	Training: R^2	Evaluation: R^2
Single tree	28	9077	1	0.912	0.767
Forest with 1000 trees	28	9008	1000	0.988	0.904
Forest with only 10 levels	10	1508	1000	0.958	0.876
Forest with only 5 niv	27	9009	1000	0.985	0.877
Optimized forest (grid search)	28	9006	961	0.988	0.904

Neuronale Netzwerke

Hier haben wir versucht, durch geeignete Wahl der Hyperparameter ein optimales Netzwerk zu finden:

Gebiet	Parameter	Kommentar
Architektur	Anzahl der Schichten	Das Optimum ist das möglichst einfachste Modell welches trotzdem gute Ergebnisse liefert
	Anzahl Neuronen	
	Aktivierungsfunktion	ReLU und Derivate davon, Sigmoid, TanH
Training	Wahl des Optimizers	SGD ("Standard Gradient Descent") oder Adam
	Wahl des Verlust-Masses	Mit diesem Mass wird der Verlust berechnet, welcher dann für die Optimierung minimiert wird. Hier: meist MSE ("Mean Squared Error")
	Lernrate (Höhe, fallend, ...)	Dieser Parameter muss unbedingt in weiten Größenordnungen getestet werden
	Dropout	Kann ggfs. ein Overfitting reduzieren
Modelltest	Random Seeds	Abhängigkeit von Random Seeds muss unbedingt untersucht werden
	Aufteilung Training-/Testdaten	Siehe oben: Wird üblicherweise auch mit einem Random Seed gesteuert. Die Güte des Modells darf nicht von dieser Aufteilung abhängen.
Optimierung durch Grid Search	Variation über alle Parameter	Sehr zeitaufwändig, da viele verschiedene Kreuzkombinationen getestet werden. Nicht unbedingt notwendig falls die gezielte Auswahl der Einzelparameter schon gute Ergebnisse liefert

Bei der Optimierung der neuronalen Netze sollte insbesondere die Lernrate über einem sehr weiten Wertespektrum (z. B. in 10er-Potenzen zwischen 0.1 und 10^{-6}) getestet werden, weil es hier üblicherweise ein lokales Optimum gibt:


- Ein hoher Wert der Lernrate ist notwendig, damit der Optimierungsalgorithmus einen ausreichend weiten Bereich der Parameter abdeckt und nicht in einem lokalen Minimum stecken bleibt;
- Gleichzeitig kann ein zu aggressiver Wert der Lernrate dazu führen, dass optimale Wertebereiche immer wieder übersprungen werden;
- Umgekehrt führt eine zu niedrige Lernrate oft dazu, dass nur lokale Minima gefunden werden;
- Eine niedrige Lernrate bedeutet auch, dass jeder Trainingsschritt nur sehr langsam voranschreitet und damit eine Konvergenz sehr viele Iterationen benötigt.

Hier kann es auch helfen, sogenannte Training Schedules zu verwenden. Zum Beispiel kann am Anfang des Trainings eine hohe Lernrate gewählt werden, welche bei Konvergenz dann reduziert wird, um eine Feinoptimierung zu ermöglichen.

Wichtig ist auch, die Abhängigkeit von Random Seeds zu untersuchen und nachzuweisen, dass die Ergebnisse nicht wesentlich von der Wahl der Random Seeds abhängen. Bei neuronalen Netzen spielen diese insbesondere bei der Aufteilung der Daten in Test- und Trainingsdatensätze und bei der Initialisierung der Gewichtsmatrizen eine Rolle.


Wir haben in diesem Zusammenhang knapp 100 Modellvarianten einzeln untersucht und konnten folgende optimierte Modelle finden:

Die Graphiken mit den Punktwolken visualisieren für die Evaluationsdaten die tatsächlichen Werte (horizontale Achse) gegenüber den berechneten Werten (vertikale Achse). Optimal wäre, wenn alle Werte auf der ersten Winkelhalbierenden liegen würden (schwarze Gerade im Hintergrund).



KPI	Quote		
	Training	Evaluation	R2
Row Labels	L1-loss	L1-loss	
NN_2hl_20-100-50-3_ opt=SGD_lr=1E-01_ep=2000_batch=175	0.0795	0.0988	0.9763
NN_2hl_20-100-50-3_ opt=Adam_w-dec=1E-04_lr=1E-02_lr-dec=1E-02_ep=2000_batch=250	0.0762	0.0947	0.9785
NN_4hl_20-100-200-200-50-3_ opt=Adam_w-dec=1E-04_lr=3E-03_lr-dec=1E-01_ep=2000_batch=250	0.0502	0.0890	0.9798


Zu erwähnen ist, dass die Ergebnisse vergleichsweise stabil gegenüber (sinnvollen) Kombinationen von Hyperparametern waren. Das bedeutet, dass die konkrete Auswahl der Parameter zum einen nicht wesentlich die erzielten Aussagen verändert, es jedoch umgekehrt auch aufwändig ist, das Modell mit einer optimalen Parameterauswahl signifikant zu verbessern.




Oben: stark vereinfachtes Modell, unten: optimiertes Modell.

"Backtesting" der Modelle

Als letzten Validierungsschritt haben wir die jeweils besten Modelle mit den tatsächlich materialisierten Werten der Quartale Q4 2018 bis Q3 2019 verglichen. Man sieht, dass die Inputparameter, insbesondere der wichtigste Parameter MR1 (entspricht ungefähr dem Zinsniveau), stark gegen den unteren Rand des Wertebereichs gelaufen ist, von (sowieso schon niedrigen) 0,068 auf 0,013.




Dies hat einen starken Einfluss auf die Ausgabegrößen, was man in dieser Übersicht sieht:



N. B.: Die hier gezeigten Zahlen sind Rohwerte aus dem Modell, es fehlen hier wichtige Anpassungen und Teile der Kapitalanlagen sowie ein Teil des Versicherungsgeschäfts sind dort nicht berücksichtigt worden. Die endgültigen Zahlen weisen weiterhin eine überdurchschnittliche Solvenzquote aus.

Wir haben nun diesen Out-of-sample—Datensatz in vier Modelle eingelesen und die realen mit den prognostizierten Ausgabewerten verglichen:



Während die quadratische Regression und Random Forest keine gute Vorhersage leisten konnten, schnitt insbesondere das Modell mit zwei Hidden Layers ("HL") sehr gut ab. Hier ist jedoch anzumerken, dass wir mit statistischen Methoden arbeiten und daher die Vorhersage von einzelnen Werten immer mit sehr viel Vorsicht zu genießen ist. Insofern kann sowohl das schlechte Abschneiden der Regression und des Random Forests als auch die gute Vorhersagequalität der 2 HL-Netzes zufällig sein.

Fazit und Ausblick

Aus Sicht der Beteiligten haben sich aus dem Projekt wertvolle Erkenntnisse ergeben:

1. Wir konnten nochmals klar herausstellen, welche Parameter auf der Aktivseite einen besonders großen Einfluss auf die Solvenzquote haben. Dies wird uns helfen, bei Unternehmensentscheiden noch stärker den Einfluss auf die Solvenzquote zu berücksichtigen.
2. Unser Projekt diente als Machbarkeitsstudie. Wir sind der Überzeugung, dass der gewählte Ansatz prinzipiell geeignet ist, Schätzungen der Solvenzquote in der notwendigen Güte abzugeben.
3. Als Nebeneffekt haben wir weite Teile des Prozesses zur Berechnung der Solvenzquote automatisiert – dies hilft uns schon im Standard-Prozess, welchen wir quartalsweise durchführen müssen.

In diesem Prozess war die Datenerstellung ein wesentlicher Treiber des Aufwandes. Dies deckt sich mit der generellen Aussage, dass bei Data Analytics-Projekten ca. 80% der Zeit für die Datenaufbereitung benötigt wird.

Wir planen, dieselbe Analyse zum Stichtag Jahresende 2019 durchzuführen. Es wird dann besonders interessant sein, ob die Modelle in dem Sinne stabil sind, dass die Modellparameter der optimal kalibrierten Modelle vergleichbar sind. Hierbei könnten wir z. B. die per Jahresende 2018 optimierten Modelle nochmals mit dem Datensatz per Jahresende 2019 laufen lassen und umgekehrt, und dann wiederum die Evaluationsergebnisse vergleichen.

2 Machine Learning in der aktuariellen Risikomodellierung

Zoran Nikolić (B&W Deloitte, Köln) und Christian Weiß (Hochschule Ruhr West, Mülheim an der Ruhr)

“Without big data analytics, companies are blind and deaf, wandering out onto the web like deer on a freeway.” (Gary King, Harvard University)

Die Solvency II Rahmenrichtlinie verlangt die Berechnung des Risikokapitals von Versicherungsunternehmen (Solvency Capital Requirement, SCR) anhand der vollständigen Wahrscheinlichkeitsverteilung der Verluste des Unternehmens, siehe [3]. Als Risikomaß wird der Value at Risk zum 99,5% Quantil herangezogen und das SCR als Differenz aus dieser Größe und dem Erwartungswert der Eigenmittel (Own Funds) bestimmt, siehe Abbildung 1.




Abbildung 1: Bestimmung des SCR-Bedarfs

Zur Berechnung des SCR werden die stochastischen Risikomodelle der Versicherungen herangezogen. Diese bilden die hochkomplexe Interaktion von Passivseite (Versicherungsverträge), Aktivseite (Kapitalanlagen), Managemententscheidungen (Überschussverwendung, Notstandsmaßnahmen, ...) und Kapitalmarkt (ökonomisches Umfeld) in einer einzigen aktuariellen Software ab. Aufgrund der Komplexität dieser Aufgabe dauert die Auswertung der Software in einer einzigen stochastischen Simulation oft mehrere Minuten. Weil für die Herleitung einer vollständigen Wahrscheinlichkeitsverteilung gleichzeitig mehrere hunderttausend Modellauswertungen (Szenarien) bestehend aus jeweils mindestens 1.000 Monte Carlo Simulationen nötig wären, vergleiche [5], stoßen selbst große Serverfarmen bei der Berechnungsaufgabe an ihre Grenzen. Diese einzelnen Szenarien bestehen aus Real-World-Kombinationen einer gewissen Anzahl von Risikofaktoren im Risikomodell. Die Risikofaktoren umfassen beispielsweise die Zins-Veränderung, die Aktienentwicklung, Spread-Ausweitung, Kosten, Sterblichkeit und so weiter.

Deswegen werden bei der Bestimmung des SCR hauptsächlich Approximationstechniken eingesetzt, die den Gesamt-Berechnungsaufwand erheblich reduzieren. Insbesondere die Least Squares Monte Carlo (LSMC) Technik hat sich als am Markt als erfolgreich erwiesen, vergleiche [2],[6]. Hierbei handelt es sich um eine typische Machine Learning Anwendung, weil ein Computer mittels eines vorgegebenen

Lern-Algorithmus in der Lage ist, anhand der Daten das beste Modell innerhalb der vorgegebenen Modellklasse zur Vorhersage der Ergebnisse des stochastischen Risikomodells auszuwählen.

Im Einzelnen besteht der LSMC-Prozess aus den folgenden Schritten:

1. Erzeugung von Regressionsszenarien von gleichmäßig verteilten Ein-Jahres-Entwicklungen der Risikotreiber
2. Durchführung weniger stochastischer Simulationen
3. Regression der LSMC-Funktion
4. Validierung der LSMC-Funktion, z.B. durch out-of-sample-Tests
5. Simulation der Wahrscheinlichkeitsverteilung der Own-Funds mittels der LSMC-Funktion und Bestimmung des SCR

In diesem Artikel interessieren wir uns besonders für den dritten Schritt des LSMC-Prozesses, nämlich die Regression der LSMC-Funktion. Hierzu werden im weiteren Verlauf verschiedene mögliche Ansätze beleuchtet:

Die einfachste mögliche Idee ist es, eine lineare Ausgleichsfunktion zu suchen. Mathematisch formuliert, bedeutet dies bekanntermaßen, dass für eine Kombination von Risikofaktoren $X^i = (X_1^i, \dots, X_n^i)$ in Simulation i und zugehörigen Own Funds Werten OF_i solche Faktoren $\beta = (\beta_0, \beta_1, \dots, \beta_n)$ gewählt werden, sodass der Ausdruck $\|X\beta - OF\|$ minimiert wird. Als linearer Schätzer ergibt sich dann $\widehat{OF}_{Lin} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$. In unseren Testrechnungen lieferte dieser simple Ansatz für Company 2 und Company 3 bereits erfreuliche Ergebnisse in der Out-Of-Sample Validierung, während der lineare Schätzer für Company 1 erhebliche Abweichungen aufweist, siehe Tabelle 1 und Tabelle 2. Wird zusätzlich eine genauere Out-Of-Sample-Validierung auch für den Bereich durchgeführt, in dem der Value-At-Risk liegt, sieht man, dass auch für Company 3 größere Abweichungen vorliegen.

Methodik	Company 1	Company 2	Company 3
Lineare Regression	-17,8%	-0,4%	-0,1%
Quadratische Terme	-6,8%	-0,5%	-0,1%
Expertenschätzung	-6,6%	-0,5%	-0,1%
AIC	-1,6%	-0,5%	+0,0%
Neuronale Netze	+0,2%	+0,1%	-0,0%

Tabelle 1: Ergebnisse Validierung

Methodik	Company 1	Company 2	Company 3
Lineare Regression	+12,0%	+0,9%	-3,7%
Quadratische Terme	+27,4%	+1,6%	-2,3%
Expertenschätzung	+20,8%	+0,5%	-1,7%
AIC	+6,7%	-0,9%	-1,3%
Neuronale Netze	-1,1%	+0,4%	+1,0%

Tabelle 2: Ergebnisse Value at Risk

Als etwas fortgeschrittenere Regressionstechniken liegen zwei weitere Möglichkeiten unmittelbar nahe: Zum einen kann man allgemeine lineare Modelle verwenden, weil der in der Realität beobachtete Zusammenhang zwischen den Risikofaktoren und den Own Funds häufig nicht linear ist. Hierbei kann eine Vielzahl von Basisfunktionen eingesetzt werden, zum Beispiel Polynome, radiale Basisfunktionen oder Wavelets. Es wird also vorab eine Struktur der LSMC-Funktion festgelegt und anschließend das gleiche Optimierungsproblem wie für die einfache lineare Regression gelöst. In unseren Testrechnungen haben wir eine Polynomstruktur aus linearen und quadratischen Termen verwendet. Zum anderen bietet es sich an, dass ein Experte an der Struktur des Polynoms feilt und von

ihm beobachtete oder auch nur vermutete Zusammenhänge in der LSMC-Funktion berücksichtigt. Beispielsweise könnte dann für einen gewissen Risikotreiber ein linearer Ansatz gewählt werden, für einen anderen ein quadratischer und auch Kreuz-Terme können in die LSMC-Funktion einfließen. Grundsätzlich liegen beide Varianten relativ nahe beieinander, sodass es nicht verwundert, dass sie einerseits in der Out-Of-Sample spürbare Verbesserungen gegenüber dem linearen Ansatz liefern und sich die Ergebnisse andererseits sehr ähneln. Hingegen verschärfen sich die Probleme bei der Value-At-Risk Validierung von Company 1 mit beiden Techniken weiter, was einen Hinweis auf den Schwierigkeitsgrad dieser Aufgabe gibt.

Ein völlig neuartiger Ansatz zum Auffinden einer optimalen Regressionsfunktion wurde in den 1970er Jahren von Hirotogu Akaike entwickelt: In der klassischen Statistik geht es darum, den *unbekannten* Parameter einer *bekannt* Regressionsfunktion oder Verteilung zu schätzen. Wie wir gerade im Kontext von LSMC gesehen haben, liegt in der Realität jedoch oft die Notwendigkeit vor, die *unbekannten* Koeffizienten einer *unbekannten* Regressionsfunktion zu schätzen. Es sind also zwei Aufgaben simultan zu lösen. Aufbauend auf Vorarbeiten von Kullback und Leibler wurde zur Bewältigung dieses simultanen Problems das sogenannten Akaike Informationskriterium (AIC), siehe [1], entwickelt, welches die Güte verschiedener Regressionsfunktionen miteinander vergleicht. In vielen Fällen kann für das AIC zudem eine einfache Formel angegeben werden. Ein grundlegendes Theorem von Akaike aus dem Jahr 1973 besagt, dass das AIC ein erwartungstreuer Schätzer für die Kullback-Leibler-Divergenz ist, das heißt, dass es ein Maß dafür ist, wie gut eine gegebene Funktion f eine andere unbekannt Funktion g annähert.

Mithilfe des AIC kann nun ein Algorithmus entwickelt werden, um eine optimale Polynomstruktur für die LSMC-Funktion zu finden. Der Vorteil ist, dass das AIC dem Nutzer eine objektive Maßzahl liefert, die beurteilt, welche Funktion aus einer gegebenen Menge von Funktionen, die Daten der Own Funds am besten approximiert. Insbesondere liefert das AIC Indizien dafür, ob es bei der Regression zu Over- oder Underfitting gekommen ist. Hierbei bietet es sich in der Praxis an, einen mehrstufigen Ansatz zu wählen, weil selbst der Raum der Polynome hochdimensional ist und nicht alle denkbaren Kombinationen abgearbeitet werden können.

Unsere Testrechnungen zeigen, dass mit dem AIC ein Quantensprung bei der Out-Of-Sample Validierung von Company 1 eintritt, die nun auch adäquat mittels der LSMC-Funktion approximiert wird, während die Güte bei den anderen beiden Companies gleichbleibend hoch ist. Gleichzeitig stellt sich heraus, dass im Bereich des Value at Risks für Company 1 nach wie vor Ungenauigkeiten bestehen. Zwar scheint der AIC-Ansatz das bestmögliche lineare Modell konstruieren zu können, die Abhängigkeit von Own Funds OF von den Risikofaktoren (X_1^i, \dots, X_n^i) ist aber komplex und gekennzeichnet durch starke Richtungsänderungen, beispielsweise wenn das Unternehmen alle passivseitigen (ungebundene RfB) und aktivseitigen (Bewertungsreserven) Reserven aufgebraucht hat und die Garantien nicht mehr erwirtschaften kann. Daraus entsteht der Bedarf, flexiblere Proxy-Funktionen zu suchen.

Neuronale Netze haben sich in den vergangenen Jahren als sehr breit einsetzbare Regressionsfunktionen erwiesen. Die Erkenntnis, dass flexiblere Funktionen zur Lösung des SCR-Approximations-Problems erforderlich sind, führt natürlich zu neuronalen Netzen. Dabei kommt einem die Einfachheit einer praktischen Umsetzung in Python zugute – eine schnelle Überprüfung, ob neuronale Netze in der Lage sind, die komplexen Zusammenhänge zwischen Own Funds und den Risikofaktoren korrekt zu erfassen. Hierbei werden die Schritte 3 und 4 im oben dargestellten Prozess durch das Training von neuronalen Netzen ersetzt.

Die ersten Versuche, neuronale Netze zu trainieren, zeigen eine hohe Volatilität der Regressionsgüte. Eine augenscheinlich kleine Veränderung eines Parameters wie Lernrate oder Anzahl der Knoten in

einer Schicht der neuronalen Netze, kann zu einer großen Ergebnisauswirkung führen. In der Literatur werden zur Problembhebung diverse Methoden vorgeschlagen, vergleiche [4]. Hier wurden zwei von ihnen angewandt:

- (a) Hyperparameter-Suche mithilfe einer möglichst gleichmäßigen Abdeckung des Raumes (Sobol-Folge) basierend auf 8 (stetigen wie diskreten) Hyperparametern – insgesamt wurden 150 Hyperparameter-Kombinationen dabei gesampelt
- (b) die besten 10 neuronale Netze gemessen am mittleren absoluten Fehler an den Out-Of-Sample-Validierungspunkten werden zu einem Ensemble zusammengefasst.

Durch diese beiden Machine-Learning-Ansätze werden nun auch die Ergebnisse in der Value-at-Risk-Metrik für alle Unternehmen zufriedenstellend. Das mit (a) und (b) beschriebene Verfahren wurde zweimal durchgeführt. Dabei waren die Ergebnisse in den beiden Durchläufen für alle drei Unternehmen sehr ähnlich. Es gibt keine Anzeichen, dass es ein Overfitting oder Bias gibt, der Fehler ist in der Größenordnung des Sampling-Fehlers in den stochastischen Risikomodellen.

[1] H. Akaike: *"Information theory and an extension of the maximum likelihood principle"*, 2nd International Symposium of Information Theory, (1973).

[2] C. Bettels, J. Fabrega, and C. Weiß.: Anwendung von Least Squares Monte Carlo (LSMC) im Solvency-II Kontext - Teil 1, Der Aktuar (2) (2014), 85–91.

[3] European Parliament and European Council. 2009. Directive 2009/138/EC on the Taking-up and Pursuit of the Business of Insurance and Reinsurance (Solvency II).

[4] Hastie, T., Tibshirani, R., Friedman, J.: *The Elements of Statistical Learning*, Springer Series in Statistics (2017).

[5] Krah, A.-S., Nikolic, Z., Korn, R.: A Least-Squares Monte Carlo Framework in Proxy Modeling of Life Insurance Companies, Risks 6(2), (2018).

[6] M. Leitschkis, M. Hörig, F. Ketterer, and C. Bettels.: Least Squares Monte Carlo for fast and robust capital projections, Milliman White Paper (2013).

3 Unterstützung des Reportings durch Natural Language Generation

Andreas Penzel (ISS Software, Hamburg) und Glen Generich (Retresco, Berlin)

Künstliche Intelligenz ist eines der digitalen Hype-Themen dieser Tage. Vor wenigen Jahren galt es noch als unmöglich, dass ein Schachcomputer einen Schachgroßmeister besiegt oder dass die KI bei der Kategorisierung von Bildern eine niedrigere Fehlerquote erzielt als das menschliche Auge.

Zu einem der Teilgebiete der Künstlichen Intelligenz, deren Anwendungen bereits in einer Reihe von alltäglichen Anwendungen und B2B-Services stecken, gehört das Natural Language Processing. Mit der Zielsetzung, menschliche Sprache automatisiert zu verarbeiten, umfasst NLP Funktionen wie Spracherkennung, Dialogsysteme (Chatbots), automatische Textkategorisierung, automatisierte Zusammenfassung von Texten oder auch die natürliche Sprachgenerierung.

Natural Language Generation (NLG) als Teildisziplin von NLP ermöglicht die datengetriebene Erzeugung natürlichsprachlicher Texte. Als Input dienen strukturierte Daten; in Kombination mit einem auf den Anwendungsfall angepassten Textgenerierungsmodell werden. Entlang der Generierungspipeline werden sämtliche Aufgaben der Texterstellung – wie die Identifizierung relevanter Aussagen, der Text- und Satzaufbau sowie die Lexikalisierung von Entitäten – nacheinander und aufeinander aufbauend bewältigt. Der dabei zugrundeliegende Regelsatz wird vorab händisch in einem Expertenprozess erarbeitet. So ist sichergestellt, dass Aussagen korrekt und verlässlich getroffen werden.

Der Einsatz der Technologie ist keine Zukunftsmusik. Heute kommt sie unbemerkt bereits in vielen Bereichen des täglichen Lebens zur Anwendung – ob beim Liveticker in Sport-Apps, bei Online-Wetterdiensten oder Verkehrsnachrichten. Auch im Business-Kontext befindet sich der Einsatz von Natural Language Generation in diversen Branchen seit einiger Zeit auf dem Vormarsch, zum Beispiel bei der Erstellung von Fonds-Reports, bei der Finanzberichterstattung oder bei der Formulierung von Produktbeschreibungen.

Natural Language Generation stiftet insbesondere dort Nutzen, wo datengetriebene Entscheidungen zu treffen sind, große oder schnell wachsende Datenvolumina entstehen oder das manuelle Verfassen von Berichten sehr aufwändig ist. NLG kann aus den gleichen Eingangsdaten Reports für unterschiedliche Adressatengruppen oder für unterschiedliche Berichtszwecke formulieren. Insbesondere rund um die Erstellung des Finanz- und der Solvenzberichte sind die beteiligten Kapazitäten stark ausgelastet. Der Einsatz der automatischen Textgenerierung steigert Effizienz und verkürzt Abstimmprozesse, sodass mehr Zeit für die wesentlichen Aufgaben bleibt.

Eine empirische Studie der ISS zur SFCR-Berichterstattung mit einer Stichprobe von 59 Versicherungsunternehmen hat ergeben, dass ein Versicherer jährlich im Durchschnitt ca. 113 Personentage für die Erstellung der SFCR-Berichte aufwendet – im Regelfall sind etwas fünf Personen über einen Zeitraum von ungefähr elf Wochen an diesem Prozess beteiligt. Das bedeutet, dass umgerechnet ca. 134 EUR pro Seite und ca. 0,82 EUR pro Wort entstehen.

Bei einem Einsatz von Natural Language Generation lassen sich ca. 77% des SFCR-Berichts automatisieren. Sobald Daten insgesamt oder für einzelne Teilbereiche des Reports vorliegen und validiert sind, verarbeitet die NLG-Engine sie nach Anlieferung. Dabei ist es für das System völlig unerheblich, ob bereits alle Daten vorliegen oder der Bericht sequentiell nach Segmenten (Bilanz, Kapitalanlagen, Kapitalanforderungen, Eigenmittel etc.) erstellt werden soll. Dabei greift die Textgenerierung auf eine Vielzahl von zuvor von Menschen formulierten Textvorlagen und ein komplexes Set an Regeln zurück, aus dem es Informationsprioritäten ableitet und auf diese Weise aus

den Solvenzdaten einen Bericht formuliert. Dabei berücksichtigt sie zuvor festgelegte Schwellen- und Grenzwerte und weist auf Besonderheiten, beispielsweise durch die Platzierung von Informationen in einer bestimmten Reihenfolge im Text, hin. Dieser Prozess kann auch iterativ durchlaufen werden, etwa mit angepassten Berichtsparametern. Fertige Berichtssegmente werden abgespeichert. Ein sogenanntes Co-Editing ermöglicht eine nachträgliche individuelle Anpassung oder Erweiterung des Berichts und damit den letzten Feinschliff vor der Abgabe.

Retrescos NLG-Ansatz lernt nur aus Training durch Domänenexperten und wird den Menschen daher auch künftig nicht ersetzen können. Letztlich geht es um die Erleichterung der täglichen Arbeit und die Steigerung der Effizienz in Zeiten wachsender Berichtsanforderungen. Der Mensch als Risikomanager, Aktuar oder Leiter Rechnungswesen trägt weiterhin die Verantwortung für die Qualität und Richtigkeit des Inhalts. Der Prozess, um hierhin zu gelangen, wird durch den Einsatz von Natural Language Generation deutlich beschleunigt. Darüber hinaus hat die Technologie das Potenzial, Zeit und Ressourcen für Wesentliches zu schaffen, sowie als System der Informationsverwaltung individuelles Wissen und Erfahrungen interpersonell nutzbar zu machen und für transparentere Prozesse und Entscheidungsfindungen zu sorgen.

Impressum

Diese Veröffentlichung erscheint im Rahmen der Online-Publikationsreihe „Forschung am **ivwKöln**“.
Eine vollständige Übersicht aller bisher erschienenen Publikationen findet sich am Ende dieser
Publikation und kann [hier](#) abgerufen werden.

Forschung am ivwKöln, 6/2020
ISSN (online) 2192-8479

**Schmidt (Hrsg.): Künstliche Intelligenz im Risikomanagement. Proceedings zum 15. FaRis & DAV
Symposium am 6. Dezember 2019 in Köln**

Köln, Juni 2020

Schriftleitung / editor's office:

Prof. Dr. Jürgen Strobel

Institut für Versicherungswesen /
Institute for Insurance Studies

Fakultät für Wirtschafts- und Rechtswissenschaften /
Faculty of Business, Economics and Law

Technische Hochschule Köln /
University of Applied Sciences

Gustav Heinemann-Ufer 54
50968 Köln

Tel. +49 221 8275-3270

Fax +49 221 8275-3277

Mail juergen.strobel@th-koeln.de

Web www.th-koeln.de

Herausgeber der Schriftenreihe / Series Editorship:

Prof. Dr. Peter Schimikowski

Prof. Dr. Jürgen Strobel

Kontakt Autor / Contact author:

Prof. Dr. Jan-Philipp Schmidt

Institut für Versicherungswesen /
Institute of Insurance Studies

Fakultät für Wirtschafts- und Rechtswissenschaften /
Faculty of Business, Economics and Law

Technische Hochschule Köln /
University of Applied Sciences

Gustav Heinemann-Ufer 54
50968 Köln

Tel. +49 221 8275-3854

Fax +49 221 8275-3277

Mail jan-philipp.schmidt@th-koeln.de

Web www.ivw-koeln.de

Publikationsreihe „Forschung am ivwKöln“

Die Veröffentlichungen der Online-Publikationsreihe "Forschung am ivwKöln" (ISSN: 2192-8479) werden üblicherweise über [Cologne Open Science](#) (Publikationsserver der TH Köln) veröffentlicht. Die Publikationen werden hierdurch über nationale und internationale Bibliothekskataloge, Suchmaschinen sowie andere Nachweisinstrumente erschlossen.

Alle Publikationen sind auch kostenlos abrufbar unter www.ivw-koeln.de.

2020

- 5/2020 Müller-Peters: Die Wahrnehmung von Risiken im Rahmen der Corona-Krise
- 4/2020 Knobloch: Modellierung einer Cantelli-Zusage mithilfe einer bewerteten inhomogenen Markov-Kette
- 3/2020 Müller-Peters, Gatzert: Todsicher: Die Wahrnehmung und Fehlwahrnehmung von Alltagsrisiken in der Öffentlichkeit
- 2/2020 Völler, Müller-Peters: InsurTech Karte ivwKöln 2020 - [Beiträge zu InsurTechs und Innovation am ivwKöln](#)
- 1/2020 Institut für Versicherungswesen: [Forschungsbericht für das Jahr 2019](#)

2019

- 5/2019 Muders: [Risiko und Resilienz kollektiver Sparprozesse – Backtesting auf Basis deutscher und US-amerikanischer Kapitalmarktdaten 1957-2017](#)
- 4/2019 Heep-Altiner, Berg: [Mikroökonomisches Produktionsmodell für Versicherungen. Teil 2: Renditemaximierung und Vergleich mit klassischen Optimierungsansätzen.](#)
- 3/2019 Völler, Müller-Peters: [InsurTech Karte ivwKöln 2019 - Beiträge zu InsurTechs und Innovation am ivwKöln](#)
- 2/2019 Rohlf, Pütz, Morawetz: [Risiken des automatisierten Fahrens. Herausforderungen und Lösungsansätze für die Kfz-Versicherung. Proceedings zum 14. FaRis & DAV-Symposium am 7.12.2018 in Köln.](#)
- 1/2019 Institut für Versicherungswesen: [Forschungsbericht für das Jahr 2018](#)

2018

- 7/2018 Goecke: [Resilience and Intergenerational Fairness in Collective Defined Contribution Pension Funds](#)
- 6/2018 Miebs: [Kapitalanlagestrategien für die bAV – Herausforderungen für das Asset Management durch das Betriebsrentenstärkungsgesetz. Proceedings zum 13. FaRis & DAV Symposium am 8. Dezember 2017 in Köln](#)
- 5/2018 Goecke, Heep-Altiner, Knobloch, Schiegl, Schmidt (Hrsg.): [FaRis at ICA 2018 – Contributions to the International Congress of Actuaries 2018 in Berlin. Beiträge von FaRis Mitgliedern zum Weltkongress der Aktuarer vom 4. bis zum 8. Juni 2018 in Berlin](#)
- 4/2018 Knobloch: [Die Pfade einer bewerteten inhomogenen Markov-Kette - Fallbeispiele aus der betrieblichen Altersversorgung](#)
- 3/2018 Völler, Müller-Peters: [InsurTech Karte ivwKöln 1/2018 - Beiträge zu InsurTechs und Innovation am ivwKöln](#)
- 2/2018 Schmidt, Schulz: [InsurTech. Proceedings zum 12. FaRis & DAV Symposium am 9. Juni 2017 in Köln](#)
- 1/2018 Institut für Versicherungswesen: [Forschungsbericht für das Jahr 2017](#)

2017

- 8/2017 Materne, Pütz: [Alternative Capital und Basisrisiko in der Standardformel \(non-life\) von Solvency II](#)
- 7/2017 Knobloch: [Konstruktion einer unterjährlichen Markov-Kette aus einer jährlichen Markov-Kette - Eine Verallgemeinerung des linearen Ansatzes](#)
- 6/2017 Goecke, Oskar (Hrsg.): [Risiko und Resilienz. Proceedings zum 11. FaRis & DAV Symposium am 9. Dezember 2016 in Köln](#)

- 5/2017 Grundhöfer, Dreuw, Quint, Stegemann: Bewertungsportale - eine neue Qualität der Konsumenteninformation?
- 4/2017 Heep-Altiner, Mehring, Rohlf: Bewertung des verfügbaren Kapitals am Beispiel des Datenmodells der „IVW Privat AG“
- 3/2017 Müller-Peters, Völler: InsurTech Karte ivwKöln 1/2017 - Beiträge zu InsurTechs und Innovation am ivwKöln
- 2/2017 Heep-Altiner, Müller-Peters, Schimikowski, Schnur (Hrsg.): Big Data für Versicherungen. Proceedings zum 21. Kölner Versicherungssymposium am 3. 11. 2016 in Köln
- 1/2017 Institut für Versicherungswesen: Forschungsbericht für das Jahr 2016

2016

- 13/2016 Völler: Erfolgsfaktoren eines Online-Portals für Akademiker
- 12/2016 Müller-Peters, Gatzert: Todsicher: Die Wahrnehmung und Fehl Wahrnehmung von Alltagsrisiken in der Öffentlichkeit (erscheint 2017)
- 11/2016 Heep-Altiner, Penzel, Rohlf, Voßmann: Standardformel und weitere Anwendungen am Beispiel des durchgängigen Datenmodells der „IVW Leben AG“
- 10/2016 Heep-Altiner (Hrsg.): Big Data. Proceedings zum 10. FaRis & DAV Symposium am 10. Juni 2016 in Köln
- 9/2016 Materne, Pütz, Engling: Die Anforderungen an die Ereignisdefinition des Rückversicherungsvertrags: Eindeutigkeit und Konsistenz mit dem zugrundeliegenden Risiko
- 8/2016 Rohlf (Hrsg.): Quantitatives Risikomanagement. Proceedings zum 9. FaRis & DAV Symposium am 4. Dezember 2015 in Köln
- 7/2016 Eremuk, Heep-Altiner: Internes Modell am Beispiel des durchgängigen Datenmodells der „IVW Privat AG“
- 6/2016 Heep-Altiner, Rohlf, Dağoğlu, Pulido, Venter: Berichtspflichten und Prozessanforderungen nach Solvency II
- 5/2016 Goecke: Collective Defined Contribution Plans - Backtesting based on German capital market data 1955 - 2015
- 4/2016 Knobloch: Bewertete inhomogene Markov-Ketten - Spezielle unterjährliche und zeitstetige Modelle
- 3/2016 Völler (Hrsg.): Sozialisiert durch Google, Apple, Amazon, Facebook und Co. – Kundenerwartungen und –erfahrungen in der Assekuranz. Proceedings zum 20. Kölner Versicherungssymposium am 5. November 2015 in Köln
- 2/2016 Materne (Hrsg.): Jahresbericht 2015 des Forschungsschwerpunkts Rückversicherung
- 1/2016 Institut für Versicherungswesen: Forschungsbericht für das Jahr 2015

2015

- 11/2015 Goecke (Hrsg.): Kapitalanlagerisiken: Economic Scenario Generator und Liquiditätsmanagement. Proceedings zum 8. FaRis & DAV Symposium am 12. Juni 2015 in Köln
- 10/2015 Heep-Altiner, Rohlf: Standardformel und weitere Anwendungen am Beispiel des durchgängigen Datenmodells der „IVW Privat AG“ – Teil 2
- 9/2015 Goecke: Asset Liability Management in einem selbstfinanzierenden Pensionsfonds
- 8/2015 Strobel (Hrsg.): Management des Langlebkeitsrisikos. Proceedings zum 7. FaRis & DAV Symposium am 5.12.2014 in Köln
- 7/2015 Völler, Wunder: Enterprise 2.0: Konzeption eines Wikis im Sinne des prozessorientierten Wissensmanagements
- 6/2015 Heep-Altiner, Rohlf: Standardformel und weitere Anwendungen am Beispiel des durchgängigen Datenmodells der „IVW Privat AG“
- 5/2015 Knobloch: Momente und charakteristische Funktion des Barwerts einer bewerteten inhomogenen Markov-Kette. Anwendung bei risikobehafteten Zahlungsströmen
- 4/2015 Heep-Altiner, Rohlf, Beier: Erneuerbare Energien und ALM eines Versicherungsunternehmens

- 3/2015 Dolgov: Calibration of Heston's stochastic volatility model to an empirical density using a genetic algorithm
- 2/2015 Heep-Altiner, Berg: Mikroökonomisches Produktionsmodell für Versicherungen
- 1/2015 Institut für Versicherungswesen: Forschungsbericht für das Jahr 2014

2014

- 10/2014 Müller-Peters, Völler (beide Hrsg.): Innovation in der Versicherungswirtschaft
- 9/2014 Knobloch: Zahlungsströme mit zinsunabhängigem Barwert
- 8/2014 Heep-Altiner, Münchow, Scuzzarello: Ausgleichsrechnungen mit Gauß Markow Modellen am Beispiel eines fiktiven Stornobestandes
- 7/2014 Grundhöfer, Röttger, Scherer: Wozu noch Papier? Einstellungen von Studierenden zu E-Books
- 6/2014 Heep-Altiner, Berg (beide Hrsg.): Katastrophenmodellierung - Naturkatastrophen, Man Made Risiken, Epidemien und mehr. Proceedings zum 6. FaRis & DAV Symposium am 13.06.2014 in Köln
- 5/2014 Goecke (Hrsg.): Modell und Wirklichkeit. Proceedings zum 5. FaRis & DAV Symposium am 6. Dezember 2013 in Köln
- 4/2014 Heep-Altiner, Hoos, Krahorst: Fair Value Bewertung von zedierten Reserven
- 3/2014 Heep-Altiner, Hoos: Vereinfachter Nat Cat Modellierungsansatz zur Rückversicherungsoptimierung
- 2/2014 Zimmermann: Frauen im Versicherungsvertrieb. Was sagen die Privatkunden dazu?
- 1/2014 Institut für Versicherungswesen: Forschungsbericht für das Jahr 2013

2013

- 11/2013 Heep-Altiner: Verlustabsorbierung durch latente Steuern nach Solvency II in der Schadenversicherung, Nr. 11/2013
- 10/2013 Müller-Peters: Kundenverhalten im Umbruch? Neue Informations- und Abschlusswege in der Kfz-Versicherung, Nr. 10/2013
- 9/2013 Knobloch: Risikomanagement in der betrieblichen Altersversorgung. Proceedings zum 4. FaRis & DAV-Symposium am 14. Juni 2013
- 8/2013 Strobel (Hrsg.): Rechnungsgrundlagen und Prämien in der Personen- und Schadenversicherung - Aktuelle Ansätze, Möglichkeiten und Grenzen. Proceedings zum 3. FaRis & DAV Symposium am 7. Dezember 2012
- 7/2013 Goecke: Sparprozesse mit kollektivem Risikoausgleich - Backtesting
- 6/2013 Knobloch: Konstruktion einer unterjährlichen Markov-Kette aus einer jährlichen Markov-Kette
- 5/2013 Heep-Altiner et al. (Hrsg.): Value-Based-Management in Non-Life Insurance
- 4/2013 Heep-Altiner: Vereinfachtes Formelwerk für den MCEV ohne Renewals in der Schadenversicherung
- 3/2013 Müller-Peters: Der vernetzte Autofahrer – Akzeptanz und Akzeptanzgrenzen von eCall, Werkstattvernetzung und Mehrwertdiensten im Automobilbereich
- 2/2013 Maier, Schimikowski (beide Hrsg.): Proceedings zum 6. Diskussionsforum Versicherungsrecht am 25. September 2012 an der FH Köln
- 1/2013 Institut für Versicherungswesen (Hrsg.): Forschungsbericht für das Jahr 2012

2012

- 11/2012 Goecke (Hrsg.): Alternative Zinsgarantien in der Lebensversicherung. Proceedings zum 2. FaRis & DAV-Symposiums am 1. Juni 2012
- 10/2012 Klatt, Schiegl: Quantitative Risikoanalyse und -bewertung technischer Systeme am Beispiel eines medizinischen Gerätes
- 9/2012 Müller-Peters: Vergleichsportale und Verbraucherwünsche
- 8/2012 Füllgraf, Völler: Social Media Reifegradmodell für die deutsche Versicherungswirtschaft
- 7/2012 Völler: Die Social Media Matrix - Orientierung für die Versicherungsbranche
- 6/2012 Knobloch: Bewertung von risikobehafteten Zahlungsströmen mithilfe von Markov-Ketten bei unterjährlicher Zahlweise
- 5/2012 Goecke: Sparprozesse mit kollektivem Risikoausgleich - Simulationsrechnungen
- 4/2012 Günther (Hrsg.): Privat versus Staat - Schussfahrt zur Zwangsversicherung? Tagungsband zum 16. Kölner Versicherungssymposium am 16. Oktober 2011
- 3/2012 Heep-Altiner/Krause: Der Embedded Value im Vergleich zum ökonomischen Kapital in der Schadenversicherung
- 2/2012 Heep-Altiner (Hrsg.): Der MCEV in der Lebens- und Schadenversicherung - geeignet für die Unternehmenssteuerung oder nicht? Proceedings zum 1. FaRis & DAV-Symposium am 02.12.2011 in Köln
- 1/2012 Institut für Versicherungswesen (Hrsg.): Forschungsbericht für das Jahr 2011

2011

- 5/2011 Reimers-Rawcliffe: Eine Darstellung von Rückversicherungsprogrammen mit Anwendung auf den Kompressionseffekt
- 4/2011 Knobloch: Ein Konzept zur Berechnung von einfachen Barwerten in der betrieblichen Altersversorgung mithilfe einer Markov-Kette
- 3/2011 Knobloch: Bewertung von risikobehafteten Zahlungsströmen mithilfe von Markov-Ketten
- 2/2011 Heep-Altiner: Performanceoptimierung des (Brutto) Neugeschäfts in der Schadenversicherung
- 1/2011 Goecke: Sparprozesse mit kollektivem Risikoausgleich