

Einzelchadenentwicklung: Wie und warum?

SAV Prüfungskolloquium
Lenn Krüger


Zürich, 09. November 2018



Agenda


- 1. Einführung**
- 2. Warum?**
- 3. Wie? – Aktuelle Methoden**
- 4. Wie? – Zukunft**
- 5. Zusammenfassung**
- 6. Stellungnahme**

Einführung - Schadenentwicklung



- t_1 : Zeitpunkt des Schadenfalls
- t_2 : Zeitpunkt der Schadenmeldung
- t_3 : Zeitpunkt der Schliessung des Schadenfalls

Warum? - Beispiel



Schaden- jahre (i)	Entwicklungsjahre (k)					
	0	1	2	...	$I-1$	I
1	$P_{1,0}$	$P_{1,1}$	$P_{1,2}$...	$P_{1,I-1}$	$P_{1,I}$
2	$P_{2,0}$	$P_{2,1}$	$P_{2,2}$...	$P_{2,I-1}$	
⋮	⋮	⋮	⋮			
$I-1$	$P_{I-1,0}$	$P_{I-1,1}$	$P_{I-1,2}$			
I	$P_{I,0}$	$P_{I,1}$				
$I+1$	$P_{I+1,0}$					



*Quelle: *Strategie im Bereich Data Science*, Fachgruppe Data Science der Schweizer Aktuarvereinigung, Version 2.0, August 2018

Warum?

Aggregierte Methoden verwerfen viele detaillierte Information zu Schäden

- ▶ Der Verlust von diesen Informationen bei der Aggregation kann in bestimmten Situationen zu Limitationen führen. Ansätze, die individuelle Schäden analysieren, sind davon nicht betroffen.

Aggregierte Methoden...

- ▶ ...benötigen homogene Datensätze
- ▶ ...können zu grossen Schätzungsfehlern führen (bei den neuesten Entwicklungsjahren)
- ▶ ...benötigen Tail-Faktoren für langsam abwickelnde Geschäftssparten
- ▶ ...können IBNyR und IBNeR nur schwierig separat bewerten

Weitere Gründe zur Betrachtung der Einzelschadenentwicklung werden diskutiert:

Non parametric individual claims reserving, M. Baudry & C. Robert, Workshop on « Data science in Finance and Insurance », 2017, oder [What Is the Future of Individual Claims Reserving?](#) A. Boumezoued, L. Devineau & F. Taillieu, 2017

Warum? – Beispiel Schätzungsfehler

- *Individual claims reserving: a survey, 2017, A.Boumezoued, L. Devineau**

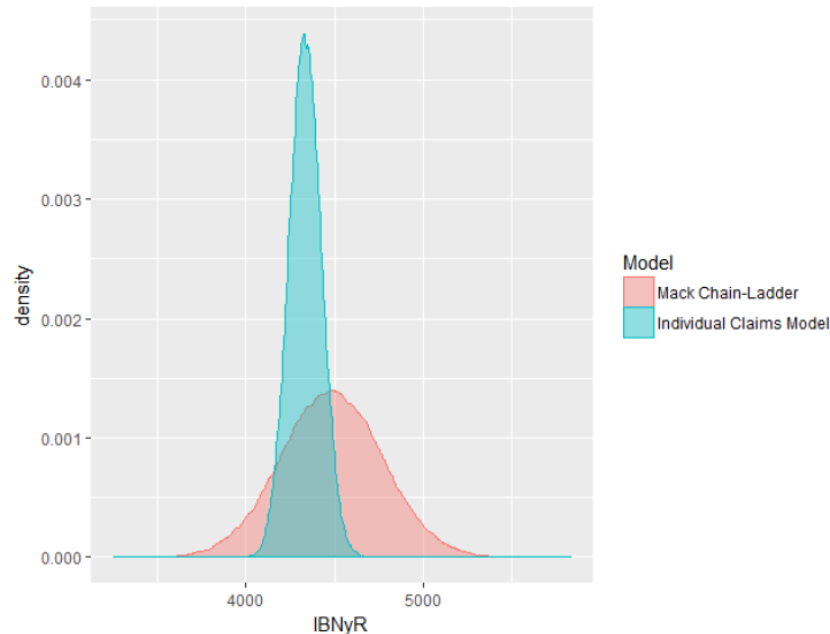
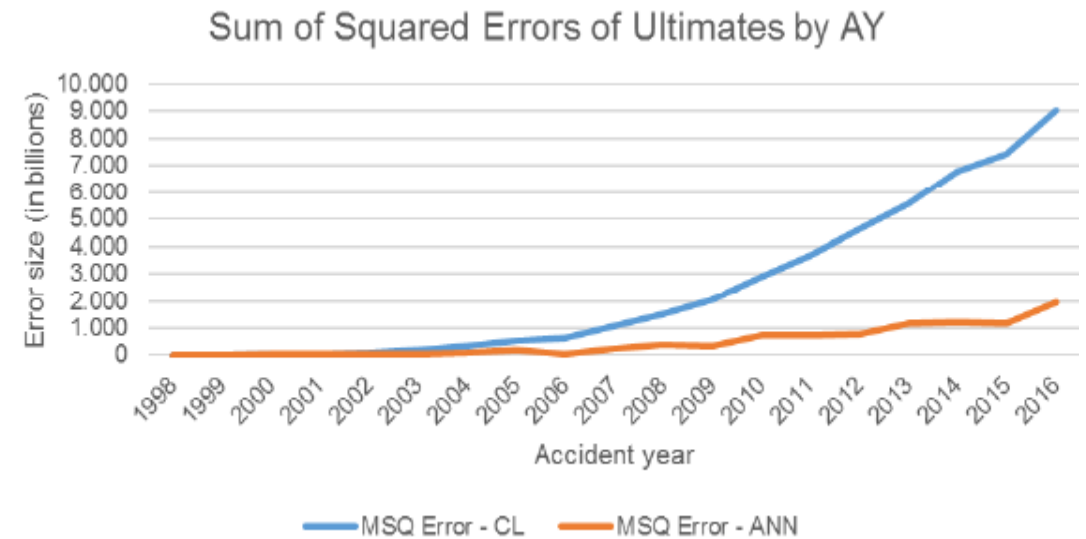


Figure 9: Prediction of the number of IBNR - comparison between the individual claims model and the Mack method

*Das verwendete Einzelschadenmodell ist ein stochastischer Poisson Prozess, mit einer assoziierten Verzögerung, welcher auf Basis der Daten simuliert wird.

- *2017 Report, Individual Claim Development with Machine Learning, ASTIN Working Party***



**Das verwendete Einzelschadenmodell ist ein neuronales Netzwerk.

Wie? - Aktuelle Methoden

Literatur Anfänge

- ▶ Karlsson 1976 – erster Ansatz individuelle Schäden anhand von Wahrscheinlichkeitstheorie zu modellieren

Literatur in den letzten Jahren

- ▶ Seit ca. 1990: Arjas 1989, Jewell 1989, Norberg 1993 & 1999, Hesselager 1994
- ▶ Kürzlich: unter anderem Pigeon et al. 2013, Antonio und Plat 2014

Praxis

- ▶ In der Praxis werden diese Methoden allerdings nur selten verwendet
- ▶ Beispiel Schweiz:

Wie? – Praxis

*ASTIN Working Party
on Non Life Reserving Practices
2016 Report, Schweiz:*

1. Standard claims: triangle-based technologies

	Main method	Peer method	Informational	Unused		
DETERMINISTIC	Percentage	29%	0%	43%	29%	
	Loss ratio	43%	43%	14%	0%	
	Chain ladder	86%	14%	0%	0%	
	Bornhuetter-Ferguson	86%	0%	0%	14%	
	Cape Cod	14%	14%	14%	57%	
	Average cost	29%	14%	14%	43%	
	De Vylder	0%	0%	0%	100%	
	Fisher-Lange	14%	0%	0%	86%	
	GLM	0%	14%	0%	86%	
	Munich Chain Ladder	0%	0%	0%	100%	
	STOCHASTIC	Market-based std dev	0%	43%	14%	43%
		Internal calibration	57%	14%	0%	29%
		Mack	43%	14%	0%	43%
Merz & Wüthrich		57%	0%	0%	43%	
GLM		0%	14%	0%	86%	
Bootstrap / CL		29%	14%	14%	43%	
Bootstrap / BF		29%	0%	0%	71%	
RJMCMC	0%	14%	0%	86%		

2. Standard claims: individual claims-based technologies

	Main method	Peer method	Informational	Unused
Percentage	14%	0%	0%	86%
ICR (Antonio-Plat)	0%	0%	0%	100%
ICR (Chalnot-Gremillet)	0%	0%	0%	100%
ICR (other)	17%	0%	17%	67%

Probleme

- ▶ Es werden sehr fixe strukturelle Formen angenommen, sodass die oben erwähnten spezifischen Charakteristiken nicht gut genug als Erklärungsvariablen verwendet werden können, bzw. sehr schwierig zu schätzen sind, da die Likelihood Funktionen sehr komplex sind.

Die Antwort...

Wie? – Zukunft

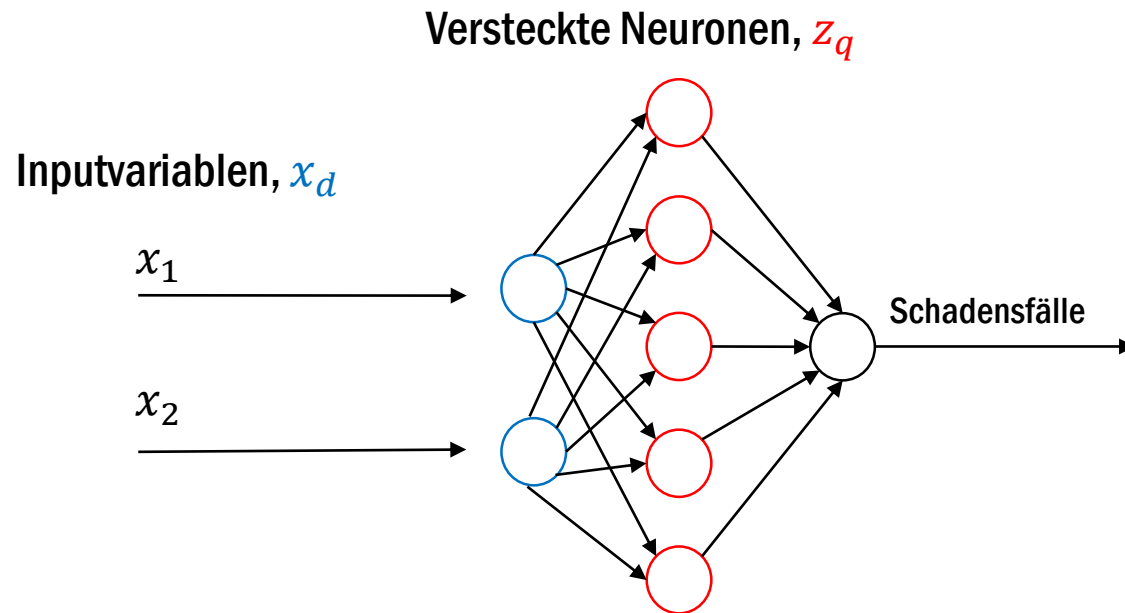
...Machine Learning

- ▶ Die neuesten Entwicklungen im Bereich Machine Learning ermöglichen es, komplexe Regressionen (spezifische Erklärungsvariablen) mit hoher Flexibilität (strukturierte sowie unstrukturierte Daten) für die Einzelschadenreservierung anzuwenden.
- ▶ Beispiele:
 - ▶ *Machine learning in individual claims reserving*, Wüthrich, 2018
 - ▶ *Case Study: French Motor Third-Party Liability Claims*, Noll, Salzmann, und Wüthrich, 2018
 - ▶ *Insights from Neural Networks*, Ferrario, Noll, und Wüthrich, 2018

Beispiel: Machine Learning vs. konventionelles GLM (Noll, Salzmann, Wüthrich)

- ▶ Prognose der Anzahl Schäden pro Police durch 9 Erklärungsvariablen a 678'013 Motorversicherungspolice plus einem Exposure-Mass, mit der Annahme, dass die Anzahl Poisson verteilt ist, und durch eine Regressionsfunktion der Erklärungsvariablen abgebildet werden kann.
- ▶ Daten werden in 2 Datensätze aufgeteilt, individuelle Modelle werden in einem, «in-sample», gefittet (90% der Daten) und im anderen, «out-of-sample», (10% der Daten) evaluiert.
- ▶ Es werden verschiedene Machine Learning Ansätze mit einem GLM (Generalized Linear Model) verglichen.

Beispiel «Neurales Netzwerk»



- ▶ Das neurale Netzwerk wird kalibriert, indem die definierte Verlustfunktion, durch Anwendung eines Algorithmus, minimiert wird
- ▶ Besonderheit: Es konnte bewiesen werden, dass jede kompakte, kontinuierliche Funktion beliebig genau von einem neuralem Netzwerk approximiert werden kann
- ▶ Resultat: Eine genauere Schätzung als mit der herkömmlichen GLM Methode

- *Case Study: French Motor Third-Party Liability Claims, 2018, A. Noll, R. Salzmann, und M. Wüthrich:*

	in-sample loss	out-of-sample loss
Model NN (shallow with $q = 20$)	30.45048	31.58770
Model PBM3 (depth $J = 3$, iterations $M = 50$)	30.09093	31.41314
Model RT2 (min. CV rule, 33 leaves)	30.70841	31.69326
Model GLM1	31.26738	32.17123

Zusammenfassung

Warum?

- ▶ Limitationen bei der Bewertung auf aggregierter Datenbasis können vermieden werden.
- ▶ Beispiele haben gezeigt, dass in solchen Situationen eine individuelle Schadenssicht, insbesondere durch Fortschritte im Machine Learning, bessere Resultate liefert.

Wie?

- ▶ Charakteristiken von einzelnen Schadensfällen ausnutzen
- ▶ Fortschritte in der Qualität und Verfügbarkeit von Daten
- ▶ Fortschritte in den aktuariellen Bewertungsmethoden, die auf Einzelschadenssicht basieren

Stellungnahme

Es tut sich viel

- ▶ ETH: Zwei neue Kurse (*Data Analytics for Non-Life Insurance Pricing* und *Statistical Machine Learning and Data Analytic Methods for Risk and Insurance*)
- ▶ SAV: Data Science Working Group mit Ziel Data Science in der SAV Aus- und Weiterbildung zu verankern
- ▶ Online Ressourcen: z.B. edX und udemy (Data Science Programme und Zertifikate)

Aber Vorsicht, diese Methoden...

- ▶ ...sind keine Allzweckwaffen
- ▶ ...sind in der Praxis noch nicht ausgereift
- ▶ ...haben hohe Anforderungen an Daten und Fachwissen
- ▶ ...sind mit Kosten bei ihrer Implementation verbunden

Anhang

- 1. Aggregation vs. Einzelbetrachtung**
- 2. Technische Aspekte zum Neuralen Netzwerk Beispiel**
- 3. Quellenangaben**

1. Aggregation vs. Einzelbetrachtung

- ▶ Traditionell basieren Berechnungsmethoden auf aggregierten Daten (d.h. Schadendreiecke):

Schaden- jahre (i)	Entwicklungsjahre (k)					
	0	1	2	...	$I - 1$	I
1	$P_{1,0}$	$P_{1,1}$	$P_{1,2}$...	$P_{1,I-1}$	$P_{1,I}$
2	$P_{2,0}$	$P_{2,1}$	$P_{2,2}$...	$P_{2,I-1}$	
⋮	⋮	⋮	⋮			
$I - 1$	$P_{I-1,0}$	$P_{I-1,1}$	$P_{I-1,2}$			
I	$P_{I,0}$	$P_{I,1}$				
$I + 1$	$P_{I+1,0}$					

- ▶ Einzelschadenmodellierung hingegen basiert auf der Analyse einzelner Schäden in Bezug auf Schadensmeldungen, der Modellierung von spezifischen Entwicklungsmustern, und den daraus resultierenden Geldflüssen.

2. Technische Aspekte zum Beispiel

Anzahl Schäden: $N_i \stackrel{i.i.d.}{\sim} Poi(\lambda(\mathbf{x}_i)v_i)$

Ziel: Schätzung der Regressionsfunktion $\lambda(\cdot)$

Verlustfunktion: $\mathcal{L}(\mathcal{D}, \lambda) = \frac{1}{n} \sum_1^n 2N_i \left[\frac{\lambda(\mathbf{x}_i)v_i}{N_i} - 1 - \log \left(\frac{\lambda(\mathbf{x}_i)v_i}{N_i} \right) \right]$

Vergleichsmodell GLM: $\mathbf{x} \mapsto \log \lambda(\mathbf{x}) = \beta_0 + \sum_{l=1}^d \beta_l x_l$

Monotone Transformation: $x_l \mapsto x_l^* = 2 \frac{x_l - \min x_l}{\max x_l - \min x_l} - 1 \in [-1, 1]$

Neurales Netzwerk Modell: $\mathbf{x} \mapsto \log \lambda(\mathbf{x}) = \beta_0 + \sum_{j=1}^q \beta_j z_j(\mathbf{x})$,

wobei die $z_j(\mathbf{x})$ die sogenannten «versteckten Neuronen» sind: $\mathbf{x} \mapsto z_j(\mathbf{x}) = \phi(w_{j,0} + \sum_{l=1}^d w_{j,l} x_l)$

Netzwerk Parameter: $\boldsymbol{\theta} = (\beta_0, \dots, \beta_q, w_{1,0}, \dots, w_{q,d})' \in \mathbb{R}^{q+1+q(d+1)}$ und nicht-linearer Aktivierungsfunktion $\phi: \mathbb{R} \rightarrow \mathbb{R}$

Neue Verlustfunktion ist eine Funktion von $\boldsymbol{\theta}$: $\mathcal{L}(\mathcal{D}, \boldsymbol{\theta}) = \frac{1}{n} \sum_1^n 2N_i \left[\frac{\lambda(\mathbf{x}_i)v_i}{N_i} - 1 - \log \left(\frac{\lambda(\mathbf{x}_i)v_i}{N_i} \right) \right]$

Gradientenverfahren Algorithmus nach Schritt t : $\boldsymbol{\theta}^{(t)} \mapsto \boldsymbol{\theta}^{(t+1)} = \boldsymbol{\theta}^{(t)} - \varrho_t \nabla_{\boldsymbol{\theta}} \mathcal{L}(\mathcal{D}, \boldsymbol{\theta}^{(t)})$ mit *Schrittweite* $\varrho_t > 0$

3a. Quellenangaben

Artikel

- *Machine learning in individual claims reserving*, M. Wüthrich, Scandinavian Actuarial Journal, 2018,
- *Case Study: French Motor Third-Party Liability Claims*, Noll, Salzmann, und Wüthrich, 2018
- *Insights from Neural Networks*, Ferrario, Noll, und Wüthrich, 2018
- *Individual claims reserving: a survey*, A. Boumezoued und L. Devineau, HAL archive, 2017.
- *Macro vs. Micro Methods in Non-Life Claims Reserving (an Econometric Perspective)*, A. Charpentier und M. Pigeon, MDPI Risks, 2016
- *Micro-level stochastic loss reserving for general insurance*, K. Antonio, R. Plat, Scandinavian Actuarial Journal, 2014
- *Individual loss reserving with the multivariate skew normal framework*, Pigeon et al., ASTIN Bulletin, 2013
- *A Markov Model for Loss Reserving*, O. Hesselager, ASTIN Bulletin, 1994.
- *Prediction of Outstanding Liabilities in Non-Life Insurance*, R. Norberg, ASTIN Bulletin, 1993.

3b. Quellenangaben

Skripte

- *Data Analytics for Non-Life Insurance Pricing*, Lecture Notes Version June 2018, M. Wüthrich und C. Buser
- *Statistical Machine Learning and Data Analytic Methods for Risk and Insurance*, Lecture Notes Version December 2017, G. Peters

Präsentationen, Berichte und Webseiten

- *Strategie im Bereich Data Science*, Fachgruppe Data Science der Schweizer Aktuarvereinigung, Version 2.0, August 2018
- *2017 Report*, Individual Claim Development with Machine Learning, ASTIN Working Party
- *Non parametric individual claims reserving*. M. Baudry und C.Y. Robert. Workshop on « Data science in Finance and Insurance », ISBA (UCL), 2017
- <https://www.captive.com/news/2017/06/14/what-is-the-future-of-individual-claims-reserving>
- *2016 Report*, ASTIN Working Party on Non Life Reserving Practices
- *Individual Claim Development: An Application*, B. Lodder, Bahnhofskolloquium 2015