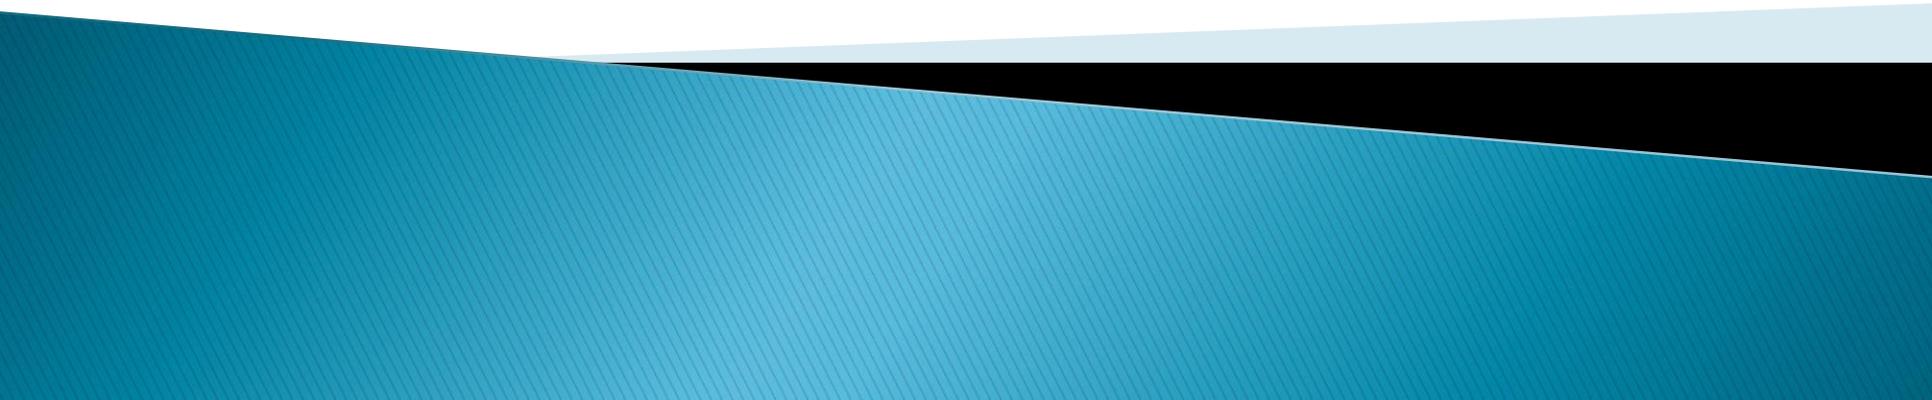


Machine Learning in der Nichtlebenreservierung

Kolloquium SAV, 24.05.2019

Markus Schwyn



Anwendungsbereiche Machine Learning (ML)



Nichtleben
Reservierung?



Agenda

1. **Was ist Machine Learning?**
2. Herausforderungen in der Reservierung
3. Wie kann Machine Learning in der Reservierung helfen?
4. Fazit/persönliche Einschätzung

Definitonen von Machine Learning (ML)

Maschinelles Lernen ist ein Oberbegriff für die „künstliche“ Generierung von **Wissen aus Erfahrung**: Ein künstliches System **lernt aus Beispielen** und kann diese nach Beendigung der Lernphase **verallgemeinern**.

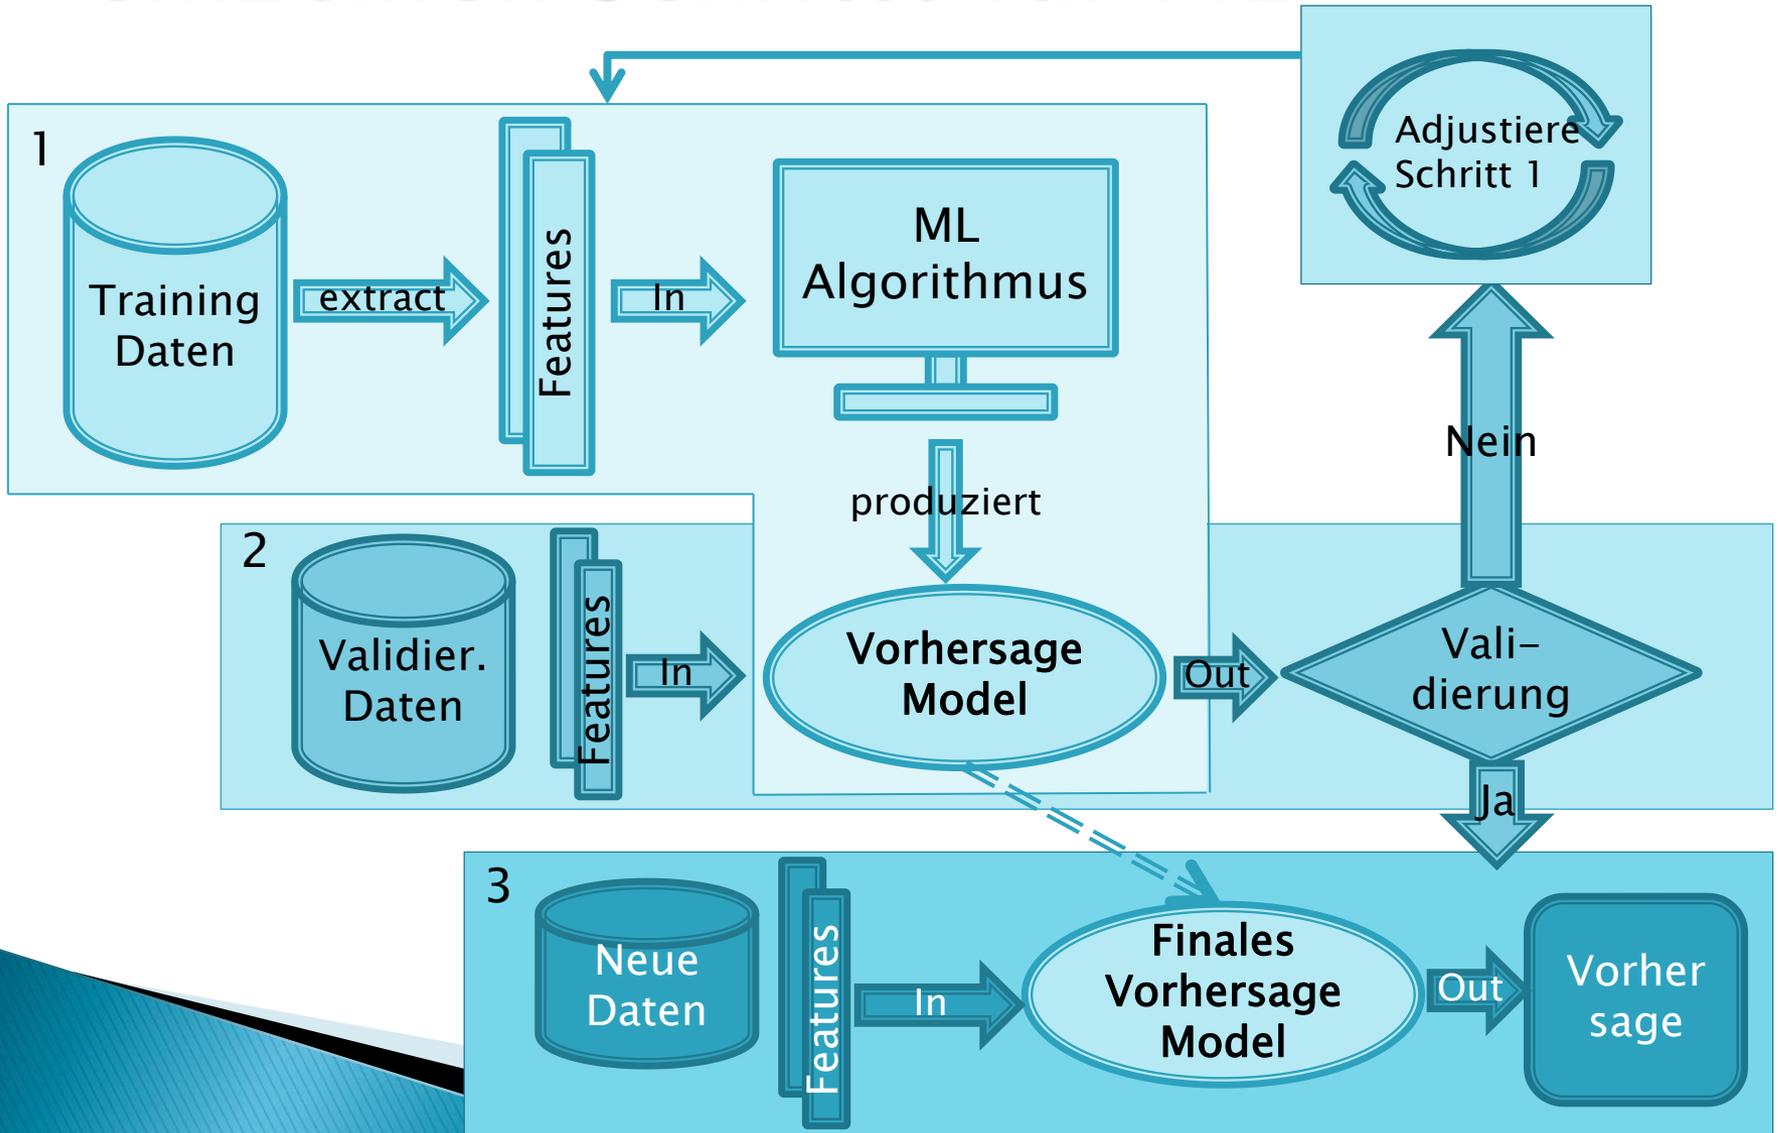
Wikipedia

Machine learning research is part of research on artificial intelligence, seeking to **provide knowledge to computers through data**, observations and interacting with the world. That acquired knowledge allows computers to **correctly generalize to new settings**.

Dr. Y. Bengio, University of Montreal

Ableiten einer **Verallgemeinerung**
durch **Lernen** aus **bekanntem Daten**
mit Hilfe von **Computern**

Verallgemeinerte Darstellung der einzelnen Schritte für ML

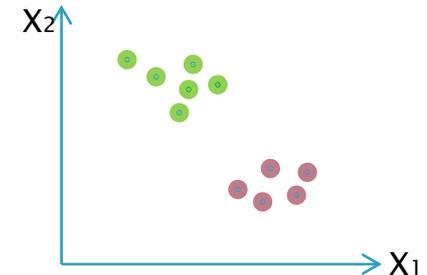


Verschiedene Kategorien von ML

▶ Supervised Learning

- Typen (u.a.):
 - Klassifizierung
 - Regression
- Algorithmen (u.a.):
 - Entscheidungsbäume
 - Ensemble Methods (Bagging, Random Forrest, Boosting)
 - Neurale Netzwerke

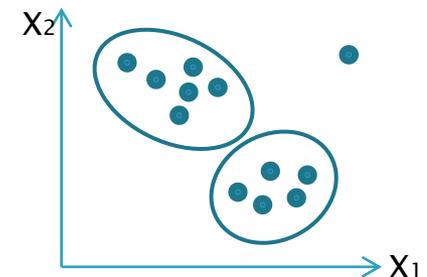
Outputdaten
werden in
Trainingsdaten
mitgegeben



▶ Unsupervised Learning

- Typen (u.a.):
 - Clustering
- Algorithmen (u.a.):
 - K-means clustering

Outputdaten
werden in
Trainingsdaten
nicht
mitgegeben



Chancen und Herausforderungen

Chancen (u.a.)

- ▶ Auswerten und Lernen aus **grossen Datenmengen**
- ▶ Erkennen von **Abhängigkeiten** in den Daten
- ▶ **Verbesserung** von Vorhersagen

Herausforderungen (u.a.)

- ▶ Genügend gute **Daten** verfügbar?
- ▶ Wahl des **passenden Modells** auf Problemstellung
- ▶ **Kalibrierung** des Modells
- ▶ **Overfitting** durch zu komplexes Modell

Agenda

1. Was ist Machine Learning?
2. **Herausforderungen in der Reservierung**
3. Wie kann Machine Learning in der Reservierung helfen?
4. Fazit/persönliche Einschätzung

Ziel der Reservierung



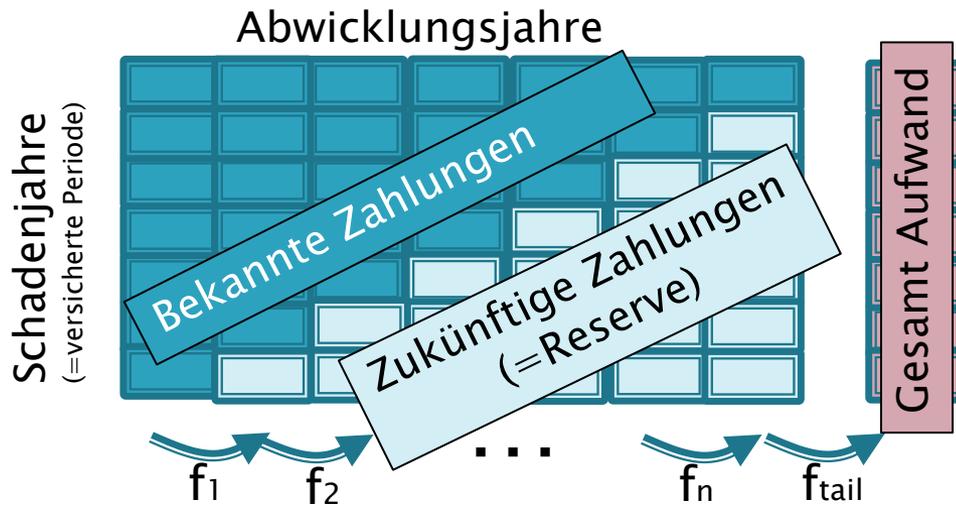
Ziel: per Stichtag (z.B. per 31.12.2018) eine Schätzung des **Gesamtschadensaufwands** für Schäden im 2018.

Herausforderungen:

- Bekannte Schäden (RBNS): Aufwand unsicher
- Noch nicht gemeldete Schäden (IBNyR): Anzahl und Höhe unbekannt

Methoden der Reservierung

- ▶ Z.B. Chain Ladder Method
(auf kumulierten Zahlungs- oder Aufwandsdreiecken)



- **Ziel:** Schätzung der Abwicklungsfaktoren f_j aus bekannten Daten
- **Annahme:** f_j 's sind (pro Abwicklungsjahr) in jedem Schadenjahr gleich
- **Wichtig:** für genaue Schätzung braucht es **homogene Portfolien**

- ▶ Bornhuetter Ferguson
- ▶ Frequency/Severity
- ▶ weitere

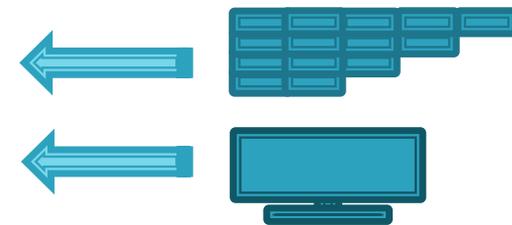
Agenda

1. Was ist Machine Learning?
2. Herausforderungen in der Reservierung
3. **Wie kann Machine Learning in der Reservierung helfen?**
4. Fazit/persönliche Einschätzung

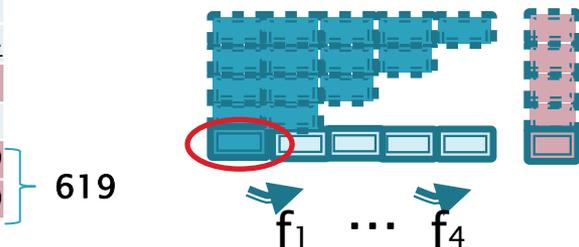
Genauere Schätzung durch bilden von homogeneren Gruppen

- ▶ Mögliche Aufgabe für ML Algorithmus:
Finde aus Schadeninformation ein **Split Kriterium** für bestehendes Portfolio, welches signifikant andere Abwicklungsfaktoren liefert.

geschätzte CL Faktoren		f1	f2	f3	f4
bestehend	Total Portfolio Haftpflicht	1.9	1.3	1.1	1.05
Split Kriterium durch ML	Fälle mit Anwalt	1.8	1.4	1.2	1.1
	Fälle ohne Anwalt	2.0	1.2	1.0	1.0



	Zahlungen				
	Jahr 0	Jahr 1	Jahr 2	Jahr 3	Jahr 4
Total Portfolio Haft	200	380	494	543	571
Fälle mit Anwalt	150	270	378	454	499
Fälle ohne Anwalt	50	100	120	120	120



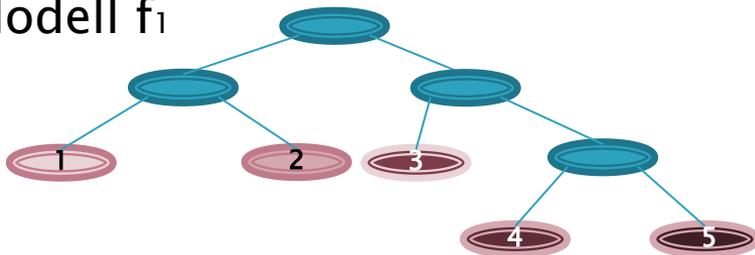
619

+8% Aufwand
+13% Rückstellungen

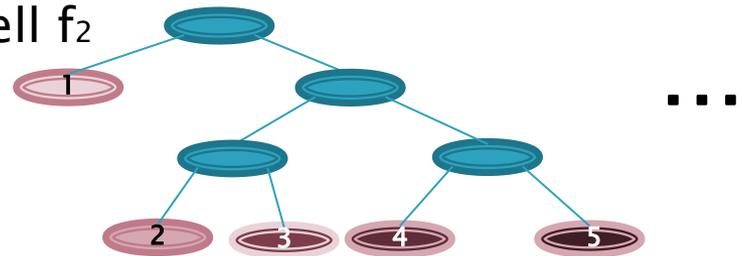
Was wenn wir die Gruppierungsbedingung vermindern?

- ▶ Untersuche Abwicklungsfaktoren **einzel**n (zuerst f_1 , dann f_2 , etc.)
- ▶ Separiere durch ML-Algorithmus anhand der Schadenkriterien die Einzelschäden, sodass **für den einzelnen Faktor** eine homogene Gruppe entsteht
 - **Modell für jeden einzelnen Faktor**

Modell f_1



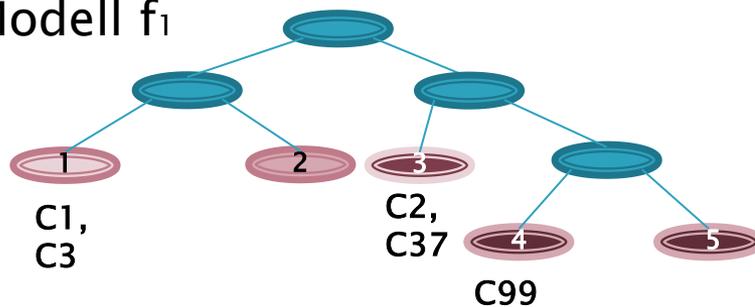
Modell f_2



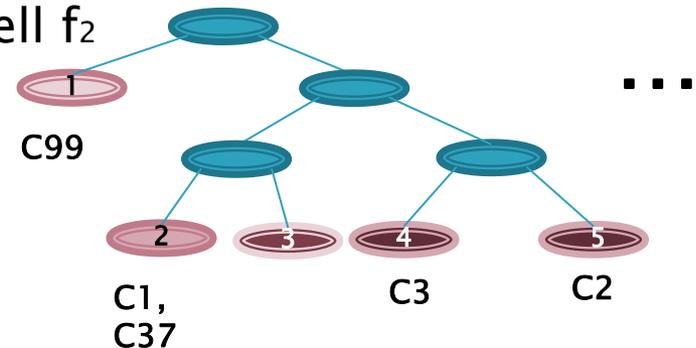
Was wenn wir die Gruppierungsbedingung vermindern?

- ▶ Separiere durch ML-Algorithmus anhand der Schadenkriterien die Einzelschäden, sodass für den Faktor eine homogene Gruppe entsteht
 - Einzelschäden (c1,c2, ...) sind für jeden Faktor/ jedes Modell in einer verschiedenen Gruppe

Modell f₁



Modell f₂



- (+) Genauigkeit der Schätzung könnte steigen
- (-) Interpretierbarkeit verringert sich

Agenda

1. Was ist Machine Learning?
2. Herausforderungen in der Reservierung
3. Wie kann Machine Learning in der Reservierung helfen?
4. **Fazit/persönliche Einschätzung**

Fazit und persönliche Einschätzung 1 / 3

- ▶ Machine Learning (ML) kann bei vielen **statistischen Fragestellungen** eingesetzt werden.
-> insbesondere bei Analyse von **grosse Datenmengen**
- ▶ Das Bilden von **homogenen Gruppen** ist in der klassischen Nichtleben Reservierung zentral.
- ▶ **ML kann z.B. für diese Gruppenbildung** (für einzelne Faktoren oder für alle zusammen) **eingesetzt werden**
- ▶ Es sind auch **weitere Varianten** als die oben besprochenen Beispiele in der Reservierung anwendbar
 - Variation der Zielgrösse (z.B. Frequenzschätzung)
 - Variation der ML Algorithmen

Fazit und persönliche Einschätzung 2/3

- ▶ Durch ML Analysen kann das **Verständnis der Schaden-**
daten verbessert werden
-> evtl. auch für Claims Dep. oder Pricing relevant
- ▶ Gute Kenntnisse in **angewandter Statistik** sowie
IT/Programmierung werden immer wichtiger
-> Haben wir Aktuare diese Kenntnisse?
- ▶ **Kalibrierung des Modells** ist von grosser Bedeutung
-> «Jeder Maschine ist nur so gut, wie sein Bediener.»
- ▶ **«Actuarial judgement»** bleibt wichtig!
-> **Blindes Vertrauen auf Resultat wäre fatal**

Fazit und persönliche Einschätzung 3/3



«Can be big help.... ... but handle with care!»

Vielen Dank!

Backup

Präsentationen/Papers zum Thema

Präsentationen

- ▶ *Ein Anwendungsbeispiel für Machine Learning*, B. König, SAV Mitgl.–Versammlung 2018
- ▶ *Machine Learning in Non-Life Pricing*, C. Buser, SAV Mitgliederversammlung 2017
- ▶ u.v.m.

Papers:

- ▶ *Case Study French Motor TPL Claims*, A. Noll, R. Salzmann, M.V: Wüthrich, Nov. 2018
- ▶ *Machine learning in individual claims reserving*, M.V. Wüthrich; Nov. 2016
- ▶ *Neural Networks Applied to Chain-Ladder Reserving*, M.V. Wüthrich, Jul. 2018
- ▶ u.v.m.

Vorlesungen/Skripts:

- ▶ *Data Analytics for Non-Life Insurance Pricing* , M.V.Wüthrich und C.Buser, Feb. 2019
- ▶ *Statistical ML and Data Analytic Methods for Risk and Insurance*, G.Peters; Dec. 2017
- ▶ *Computational Statistics*, P. Bühlmann und M. Mächler , Oct. 16