

Müller-Peters, Horst (Ed.); Schmidt, Jan-Philipp (Ed.); Völler, Michaela (Ed.)

Proceedings

Revolutionieren Big Data und KI die Versicherungswirtschaft? 24. Kölner Versicherungssymposium am 14. November 2019

Forschung am iwvKöln, No. 7/2020

Provided in Cooperation with:

Technische Hochschule Köln – University of Applied Sciences, Institute for Insurance Studies

Suggested Citation: Müller-Peters, Horst (Ed.); Schmidt, Jan-Philipp (Ed.); Völler, Michaela (Ed.) (2020) : Revolutionieren Big Data und KI die Versicherungswirtschaft? 24. Kölner Versicherungssymposium am 14. November 2019, Forschung am iwvKöln, No. 7/2020, Technische Hochschule Köln, Institut für Versicherungswesen (iwvKöln), Köln, <https://nbn-resolving.de/urn:nbn:de:hbz:832-cos4-8996>

This Version is available at:

<https://hdl.handle.net/10419/226612>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.



<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.de>

Forschung am ivwKöln
Band 7/2020

Revolutionieren Big Data und KI die Versicherungswirtschaft?

24. Kölner Versicherungssymposium am 14. November 2019

Herausgeber Prof. Horst Müller-Peters, Prof. Dr. Jan-Philipp Schmidt, Prof. Dr. Michael Völler

ivwKöln

Institut für Versicherungswesen

Fakultät für Wirtschafts-
und Rechtswissenschaften

Technology
Arts Sciences
TH Köln

Vorwort

Die Frage, ob Big Data und Künstliche Intelligenz (KI) die Versicherungswirtschaft revolutionieren, beschäftigt schon seit einiger Zeit unsere Gesellschaft sowie im Besonderen die Versicherungsbranche. Die Fortschritte in jüngster Vergangenheit in der KI und bei der Auswertung großer Datenmengen sowie die große mediale Aufmerksamkeit sind immens. Somit waren Big Data und Künstliche Intelligenz auch die diesjährigen vielversprechenden Themen des 24. Kölner Versicherungssymposiums der TH Köln am 14. November 2019: Das ivwKöln hatte zum fachlichen Austausch eingeladen, ein attraktives Vortragsprogramm zusammengestellt und Networking-Gelegenheiten für die Gäste aus Forschung und Praxis vorbereitet. Der vorliegende Proceedings-Band umfasst die Vortragsinhalte der verschiedenen Referenten.

Do Big Data and Artificial Intelligence (AI) change the insurance industry? This question bothers our society for some time already and especially the insurance industry. The most recent progress of AI as well as the amazing insights from data analytics are astonishing. Therefore, Big Data and AI were the major topics of our annual Cologne insurance symposium (24. Kölner Versicherungssymposium) at TH Köln on November 14 in 2019. The ivwKöln organized professional networking possibilities as well as an attractive program for fellows from research and insurance practice. These proceedings summarize the content of the various contributions.

Inhaltsverzeichnis

Seite

Vorwort		2
Inhaltsverzeichnis		3
Abbildungsverzeichnis		4
Autorenverzeichnis		6
1. Prof. Dr. Björn Bloching	Wie Smart Data und KI die Gesellschaft revolutionieren	9
2. Prof. Dr. Jan-Philipp Schmidt	Chancen und Herausforderungen für die Versicherungswirtschaft durch Künstliche Intelligenz	15
3. Prof. Horst Müller-Peters	Schreckgespenst oder Heilsbringer? Big Data und Künstliche Intelligenz aus Sicht der Bürger und Kunden	18
4. Prof. Dr. Michael Völler	Von Kragenechsen und Mistkäfern: Big Data und KI in der Marktbearbeitung	26
5. Dr. Andreas Becks	Raus aus dem Labor, rein in die Geschäftsprozesse – Praxisbeispiele und Anforderungen für Künstliche Intelligenz in der Versicherung	36
6. Dr. Thomas Zabel	Altes im neuen Gewand?! – KI und Data Analytics im Versicherungssektor	46
7. Dr. Thomas Körzdörfer	Telematik bei der HUK-COBURG: Big Data, Big Insights?	54
8. Dr. Christoph Carl Kling	Selbstlernende KI zur Unterstützung des Underwritings in der Industrierversicherung	62

Abbildungsverzeichnis

Seite

Abbildung 1	Die Digitalisierung macht unsere Gesellschaft besser	9
Abbildung 2	Die Schattenseiten der Digitalisierung sind vielfältig	10
Abbildung 3	Europa muss ein globaler Akteur im Digitalbereich werden	12
Abbildung 4	Es gibt viele Fragen, die wir beantworten müssen – einige Denkanstöße	13
Abbildung 5	Narrative rund um „Big Data“	20
Abbildung 6	Datenwissen	21
Abbildung 7	Wahrgenommene Handlungsfreiheit („Können“)	22
Abbildung 8	Fairness – Mindestanforderungen an Big Data und KI	23
Abbildung 9	Neue Rollen für die Versicherungswirtschaft	24
Abbildung 10	Die 3Vs von Big Data	26
Abbildung 11	Schwache Künstliche Intelligenz	27
Abbildung 12	Die vier Kernkompetenten einer KI	28
Abbildung 13	Die vier Kernkompetenten in der Marktbearbeitung	28
Abbildung 14	Unterstützung durch KI	29
Abbildung 15	Hammond’s Periodic Table of AI	30
Abbildung 16	Verzahnung der Stärken von Mensch und Maschine	31
Abbildung 17	Fünf-Stufen-Modell der Entscheidungsautomation	32
Abbildung 18	Beispiele von Startups zur Unterstützung des Marktprozesses	32
Abbildung 19	Selbstverstärkender Kreislauf	34
Abbildung 20	KI bei Versicherungen - Potenziale für die gesamte Wertschöpfungskette	37
Abbildung 21	Echtzeit-Schadenbearbeitung (vereinfachter Geschäftsprozess)	38
Abbildung 22	Was braucht es, um KI in der Versicherung erfolgreich zu operationalisieren?	38
Abbildung 23	Der analytische Lebenszyklus: entwickeln, anwenden, überprüfen	40

Abbildung 24	Data Ops: Jeder macht das, was er am besten kann	42
Abbildung 25	Maschinelles Lernen interpretierbar machen – Zielgruppen	43
Abbildung 26	Erklärungsansätze für die Effektivität von Algorithmen	44
Abbildung 27	Meilensteine der KI/ML-Historie	48
Abbildung 28	Kundenerwartungen im Digitalen Zeitalter und entsprechende Antworten	51
Abbildung 29	Voraussetzungen für die Anwendung von Künstlicher Intelligenz	52
Abbildung 30	Der Unterschied zwischen klassischer Datenhaltung und „Big Data“	54
Abbildung 31	Aktive Fahrer im Telematik Plus Baustein	55
Abbildung 32	Straßenabdeckung in Köln von Fahrern im Telematik-Plus Programm	56
Abbildung 33	Darstellungen in der HUK Mein Auto App	57
Abbildung 34	Unfallhäufigkeit und Häufigkeit des Auftretens eines bestimmten Merkmals	58
Abbildung 35	Relative Unfallhäufigkeit in Abhängigkeit vom Fahrwert	59
Abbildung 36	Steigerung des Fahrwerts und Senkung des Unfallrisikos	60

Autorenverzeichnis



Warum Europa die Digitale Revolution anführen sollte

Prof. Dr. Björn Bloching ist Senior Partner und leitet das globale Geschäft im Bereich „Digitalisierung“ bei Roland Berger. Er ist Gründer des Roland Berger Digital Hub „Spielfeld“ in Berlin. Hier werden in industrie- und branchenübergreifenden Projekten Lösungen für die digitalen Herausforderungen und Themen von Kunden erarbeitet. Er verfügt über 20 Jahre Beratungserfahrung und ist ein ausgewiesener Experte für die Bereiche Big Data und Smart Data sowie Marketing und Branding. Zusätzliche Beratungsthemen umfassen Aufgabenstellungen in Wissenschaft, Bildung, Kultur und Profi-Sport sowie Stadtentwicklung und Tourismus. Er ist Autor der renommierten Fachbücher wie „Data User – Wie Kundendaten die Wirtschaft revolutionieren“ und „Smart Data – Datenstrategien, die Kunden wirklich wollen und Unternehmen wirklich nützen“.



Chancen und Herausforderungen für die Versicherungswirtschaft durch Künstliche Intelligenz

Prof. Dr. Jan-Philipp Schmidt ist Professor für Aktuarwissenschaften am Institut für Versicherungswesen (ivwKöln) der TH Köln und unterrichtet in mathematischen und statistischen Fächern. Er ist Mitglied der Deutschen Aktuarvereinigung sowie stellvertretender Vorsitzender im Vorstand der Deutschen Gesellschaft für Versicherungs- und Finanzmathematik e.V. Zuvor war er für das Institut für Finanz- und Aktuarwissenschaften (ifa) in Ulm als Unternehmensberater und Aktuar tätig. Zu seinen fachlichen Schwerpunkten gehören aktuarielle Themen der Lebensversicherung sowie der Privaten Krankenversicherung.



Schreckgespenst oder Heilsbringer? Big Data und Künstliche Intelligenz aus Sicht der Bürger und Kunden

Prof. Horst Müller-Peters ist Professor für Betriebswirtschaftslehre, Marketing und Kundenverhalten am Institut für Versicherungswesen der Technischen Hochschule Köln und Co-Leiter der dortigen Forschungsstelle Versicherungsmarkt. Zuvor war er Vorstandsvorsitzender des Marktforschungs- und Beratungsunternehmens psychonomics AG. Er ist Mitglied verschiedener Beiräte und Gremien der Branche, Herausgeber der Fachportale marktforschung.de, dataanalyst.eu und consulting.de, und hat zahlreiche Beiträge zu Marktforschung, Risiko- und Versicherungspsychologie sowie zum Kundenverhalten im Kontext der Digitalisierung publiziert.



Von Kragenechsen und Mistkäfern: Big Data und KI in der Marktbearbeitung

Prof. Dr. Michaela Völler ist Professorin am Institut für Versicherungswesen (ivwKöln) der TH Köln und lehrt dort Marketing, Strategie und Innovation. Sie ist Mitgründerin und Leiterin der Kölner Forschungsstelle Versicherungsmarkt und beschäftigt sich intensiv mit Innovation und Digitalisierung in der Versicherungswirtschaft, insbesondere mit marktnahen Fragestellungen und dem veränderten Konsumentenverhalten. Im Jahr 2017 war sie Mitglied der Taskforce zum Aufbau des InsurLab Germany, das von Stadt Köln, TH Köln, Universität zu Köln und IHK Köln initiiert wurde. Seit 2018 gehört sie dem Advisory Board des InsurLab Germany an. Als Kernmitglied der BCG Praxisgruppe Versicherungen hat sie im Laufe ihrer Beraterkarriere zahlreiche Projekte für deutsche und internationale Versicherungsunternehmen durchgeführt.



Raus aus dem Labor – rein in die Geschäftsprozesse: Praxisbeispiele und Anforderungen für Künstliche Intelligenz in der Versicherung

Dr. Andreas Becks berät zusammen mit seinem Team aus Versicherungsexperten, Datenwissenschaftlern und Lösungsarchitekten Versicherungskunden zum Einsatz des KI-Ökosystems von SAS. Sein Schwerpunkt liegt auf datenbasierter Innovation auf der einen Seite und der Industrialisierung von KI auf der anderen Seite. Seit 20 Jahren entwickelt Dr. Becks innovative Lösungen für datenbasierte Entscheidungen, Informationsvisualisierung und KI-Anwendungen in verschiedenen Branchen. Er war bei SAS in verschiedenen Fach- und Führungspositionen für Customer Experience, BI und Analytics tätig. Darüber hinaus ist er Referent bei Veranstaltungen, Blogger und Autor von Fachartikeln. Vor seiner Tätigkeit bei SAS war er in verschiedenen leitenden Positionen in den Bereichen Forschung und Entwicklung, als Business- und Lösungsarchitekt sowie im strategischen Produktmanagement eines Softwareunternehmens tätig. Er ist diplomierte Informatiker, promovierte in Künstlicher Intelligenz an der RWTH Aachen und erwarb einen MBA an der Universität St. Gallen.



Altes in neuem Gewand?! – KI und Data Analytics im Versicherungssektor

Dr. Thomas Zabel ist Bereichsleiter Markt- und Kundenanalyse Abteilung Kommunikation der LVM Versicherung. Er verantwortet dort die Teams Marktforschung und Data Mining. Im Mittelpunkt beider Teams stehen Analysen hinsichtlich Markt- und Kundenverhalten. Unterschiedliche mathematische Methoden werden für die Analysen verwendet und haben zum Ziel, Markt- bzw. Kundenpotenziale für die Unternehmung bzw. für den Vertrieb offen zu legen. Die Mitarbeiter beider Teams arbeiten in vielen fachübergreifenden Projekten. Thomas Zabel hat Wirtschaftsinformatik an der WWU Münster studiert und am Institut für Wirtschaftsinformatik im Forschungsgebiet Künstliche Intelligenz promoviert. Er ist verheiratet, hat zwei Kinder und lebt mit seiner Familie in Münster.



Telematik bei der HUK-COBURG: Big Data, Big Insights?

Dr. Thomas Körzdörfer leitet die Arbeitsgruppe Informationsmanagement im Aktuariat Komposit der HUK-COBURG und ist damit verantwortlich für alle Big Data und Data Analytics Aufgaben im Komposit-Umfeld. Zu seinem Aufgabengebiet gehören unter anderem die Leitung des Data Science Centers sowie die Verantwortung für die Data Analytics Tätigkeiten des Aktuariats, wie z.B. die Analyse von Telematik Fahrdaten, Bild- und Texterkennung, automatisierte Betrugserkennung sowie datenbasiertes Bestandskundenmanagement. Thomas Körzdörfer hat in Theoretischer Physik promoviert und hatte von 2012 bis 2018 eine Juniorprofessur an der Universität Potsdam inne. Neben seiner Tätigkeit im Aktuariat Komposit der HUK-COBURG hält er dort nach wie vor eine Privatdozentur.



Selbstlernende KI zur Unterstützung des Underwritings in der Industrieversicherung

Dr. Christoph Carl Kling ist Data Scientist mit Schwerpunkt Dokumentenanalysen. Für seine Arbeit im Bereich der Wahrscheinlichkeitsmodelle wurde er mehrfach ausgezeichnet. Nach dem Studium der Informatik promovierte er bei Steffen Staab an der Universität Koblenz-Landau, anschließend arbeitete er im Team Data Science des GESIS – Leibniz-Institut für Sozialwissenschaften in Köln. Er war als Freiberufler im Bereich Web-Programmierung tätig und verfügt über Gründungserfahrung im Bereich Data Science. Seit 2018 ist er Mitgründer des Kölner Startups DocuDiet und dort unter anderem für die KI-Entwicklung zuständig. DocuDiet wurde 2019 für einen Platz im InsurLab Germany-Accelerator und im Future Champions Accelerator ausgewählt.

1. Wie Smart Data und KI die Gesellschaft revolutionieren

Prof. Dr. Björn Bloching

Die zwei Seiten der Digitalisierung

Die sogenannte „digitale Revolution“ kann viele positive Veränderungen für unsere Gesellschaft bewirken. Allen voran wird sie uns helfen, die zentralen Herausforderungen der Menschheit zu meistern – zum Beispiel den Klimawandel, die Probleme alternder Gesellschaften oder die drohende Ressourcenknappheit.



Abbildung 1: Die Digitalisierung macht unsere Gesellschaft besser
Foto: Maxiphoto/iStock

Betrachtet man die Prognosen der UN bis 2050, so wird die Weltbevölkerung von derzeit rund 7,5 Milliarden auf 9,7 Milliarden Menschen wachsen. Bereits heute lebt die Mehrheit in städtischen Gebieten, und die Urbanisierung wird weiter fortschreiten. Nur "vernetzte Städte" können mit großen Einwohnerzahlen und massivem Bevölkerungswachstum fertig werden. So glauben Experten der Global Sustainability Initiative, dass intelligente digitale Energiesysteme das Zehnfache der von ihnen verursachten CO₂-Emission einsparen könnten¹. Auch Produktionsprozesse werden effizienter und entlasten den Menschen durch die Vernetzung von Produkten, Wertschöpfungsketten und Geschäftsmodellen. Die vierte industrielle Revolution wird so eingeläutet.

Außerdem wird die Digitalisierung das Gesundheitswesen revolutionieren: Mit neuen Sensoren, künstlicher Intelligenz und digitalen Kommunikationsmitteln kann die medizinische Versorgung auch an den entlegensten Orten gewährleistet werden. Unsere aktuelle Studie "Future of Health" hat gezeigt, dass das Marktvolumen für digitale Produkte und Dienstleistungen bereits 2025 bei bis zu 38

¹ <https://smarter2030.gesi.org/> (Stand 11.12. 2019)

Milliarden Euro in Deutschland und etwa 155 Milliarden Euro in der EU liegen wird. KI wird künftig vor allem in der Diagnose, Überwachung und Prävention eine große Rolle spielen, 20 Prozent der ärztlichen Leistungen könnten durch KI ersetzt werden². Smarte Datenstrategien sollen den medizinischen Fortschritt zudem beschleunigen. Das Digitale-Versorgungs-Gesetz sieht vor, dass pseudonymisierte Daten zu Soziodemographie und Behandlungen der Versicherten in Zukunft direkt in den Forschungsdatenzentren des Bundesgesundheitsministeriums zu F&E-Zwecken genutzt werden können.

Des Weiteren fördert die Digitalisierung Bildung und Demokratie. Digitale Lösungen können den rund 50 Millionen Kindern weltweit, die heute keinen Zugang zur Schule haben, Bildung ermöglichen. Außerdem können soziale Netzwerke genutzt werden, um demokratische Bewegungen zu organisieren, politische Diskussionen zu fördern und funktionierende Zivilgesellschaften zu bilden.

Digitalisierung kann also – richtig angewendet – dazu beitragen, eine bessere Zukunft für den Planeten zu schaffen. Aber wie jede bahnbrechende Technologie hat auch die Digitalisierung Schattenseiten. Digitale Technologien können dafür eingesetzt werden, Bürger zu überwachen, Mobbing zu fördern oder politische Wahlen zu manipulieren. Und sie können die herrschende Ungleichverteilung von Einkommen und Vermögen weiter verschärfen.



Abbildung 2: Die Schattenseiten der Digitalisierung sind vielfältig
Foto: NicoElNino/iStock

Bereits jeder dritte Jugendliche ist laut Unicef bereits Opfer von Cybermobbing geworden³ und alle 16 Sekunden findet ein Cyber-Angriff irgendwo auf der Welt statt⁴. Zudem wird in den sozialen Medien

² <https://www.rolandberger.com/de/Publications/Digitalisierung-im-Gesundheitswesen-Handeln-statt-sondieren.html> (Stand 11.12. 2019)

³ <https://unicef.at/news/einzelansicht/unicef-umfrage-ueber-ein-drittel-der-jungen-menschen-in-30-laendern-sind-cyber-mobbing-opfer/> (Stand 11.12. 2019)

⁴ <https://www.wp.de/staedte/ennepetal-gevelsberg-schwelm/alle-16-sekunden-gibt-es-einen-cyberangriff-id21472265.html> (Stand 11.12. 2019)

mit den Ängsten anderer gespielt, das Recht auf Meinungsverschiedenheit ignoriert oder es werden "Fake News" verbreitet. In einer kürzlich von der Monmouth University in New Jersey durchgeführten Umfrage gaben 52% der Befragten an⁵, dass sie glauben, dass Online-Nachrichtenquellen regelmäßig gefälschte Nachrichten veröffentlichen.

Technologie kann auch Arbeitsplätze zerstören und führende Digitalunternehmen wie Google, Amazon, Facebook oder Alibaba könnten globale Monopole aufbauen. Algorithmen der KI basieren häufig auf der "utilitaristischen Ethik" und treffen ihre Entscheidungen allein auf der Grundlage von Kosten-Nutzen-Analysen. Dies birgt die Gefahr, grundlegende Menschenrechte außer Acht zu lassen. Zudem können Sensoren und neue Technologien wie Gesichtserkennung Alpträume à la Orwells "Big Brother" schnell Realität werden lassen. In "Social Scoring"-Systemen werden Menschen nach ihrem Verhalten in der Öffentlichkeit bis hin zu ihrer Kreditwürdigkeit – und sogar ihrer "Treue zu politischen Systemen" – bewertet.

Und was passiert mit all den Daten der digitalen Revolution? Jeden Tag werden mittlerweile 2,5 Trillionen Bytes digitale Daten⁶ generiert – alleine Google verarbeitet 3,5 Milliarden Suchanfragen pro Tag. Daten sind das Öl für jede Branche, denn sie werden genutzt, um Kundenbedürfnisse besser zu verstehen, smarte Entscheidungen zu treffen und Prozesse effizienter zu gestalten. Daten sind auch die Grundlage für künstliche Intelligenz, die unsere Gesellschaft revolutioniert wie einst die Dampfmaschine. Diese selbstlernenden Systeme verarbeiten Daten zielführend, so dass Prozesse in den verschiedensten Bereichen automatisch ablaufen können. Doch wer hat die Macht über diese Daten? Bis 2030 werden laut Expertenmeinung 30% aller weltweit gespeicherten Daten in chinesischen Händen sein. Auch die USA sind gleichermaßen aktiv: Bob Goodlatte, Vorsitzender des Justizausschusses des US-Repräsentantenhauses, sagte 2018, dass "Google in der Lage ist, so viele Daten über seine Nutzer zu sammeln, dass sogar die NSA vor Scham rot werden würde"⁷.

Wir müssen die Risiken der Digitalisierung ernst nehmen, denn wir wollen keine Zukunft, in der die Demokratie durch ein System ersetzt wurde, das von Technologien, Monopolen und wenigen "Big Brother"-Regierungen kontrolliert wird.

Unsere Welt braucht eine globale digitale Gesellschaft, die auf den grundlegenden Werten und Konzepten basiert, die über Jahrhunderte hinweg Gesellschaften zusammengehalten haben. Das sind „Grundwerte und –konzepte“, die von brillanten Denkern wie John Locke entwickelt wurden. Er prägte die Idee des "Liberalismus" und einer vom Volk kontrollierten Regierung. Oder Rousseau, der über die Frage nach dem „richtigen Leben“ und der „Selbstverwirklichung“ aller Lebewesen schrieb. Immanuel Kant, der die erste wirkliche Moraltheorie entwickelte, die nicht mit dem Christentum, sondern dem „kategorischen Imperativ“ und dem Konzept des „ewigen Friedens unter den Nationen“ verbunden war. Simone de Beauvoir für ihren Einfluss auf die feministische Theorie. Edith Stein für den Kampf um Verständnis zwischen Juden und Christen. John Rawls, der in Harvard arbeitete und 1971 seine "Theory of Justice" veröffentlichte – eine der einflussreichsten Theorien über eine faire Gesellschaft. Francis Bacon, für seine Ideen über die Bedeutung von Wissen. Diderot und d'Alembert, für die Idee der Wissensverbreitung und, zusammen mit Wilhelm von Humboldt, für die Idee der universellen Bildung. Gotthold Ephraim Lessing, für seine Vorstellungen von Toleranz in seinem Gleichnis von den drei Ringen. Bernard Mandeville und Adam Smith für ihre Ideen über ein Wirtschaftssystem, das eher

⁵ https://www.monmouth.edu/polling-institute/documents/monmouthpoll_us_040218.pdf/ (Stand 11.12. 2019)

⁶ <https://blog.wiwo.de/look-at-it/2018/03/21/25-trillionen-bytes-daten-pro-tag-erzeugt-speicherkapazitaet-von-36-millionen-ipads/> (Stand 11.12. 2019)

⁷ <https://www.sueddeutsche.de/digital/facebook-google-macht-wettbewerb-europa-1.4262647> (Stand 09.01. 2020)

individuellen als kollektiven Interessen entspricht. Und schlussendlich Marx, für seine Idee von sozialer Fairness.

All diese Personen stammen zwar aus dem Westen, aber sie bauten ihre Theorien und Philosophien auf vielen Quellen auf, viele von ihnen aus dem Nahen und Fernen Osten. Weil die Grundwerte, die unsere Welt zu einem besseren Ort machen, universell sind.

Europas Rolle in der vierten digitalen Revolution

Warum sollte Europa die vierte industrielle Revolution anführen? Wir sind uns alle einig, dass Europa einen langen Weg zurückgelegt hat, um eine Gesellschaft zu werden, die ihre humanistischen Grundwerte lebt und atmet. Mit der Charta der Grundrechte hat die Europäische Union einen klaren Rahmen für uns Europäer geschaffen, um die Zukunft unserer Gesellschaften positiv zu gestalten und den Herausforderungen der Digitalisierung aktiv zu begegnen. Heute steht Europa zwischen den USA und China unter Druck. Wir sind digitale Nachzügler und müssen jetzt aufwachen! Nur mit einer starken digitalen wirtschaftlichen Position können wir Partner sein, die auf Augenhöhe mit globalen Großmächten zusammenarbeiten.



Abbildung 3: Europa muss ein globaler Akteur im Digitalbereich werden – einige Maßnahmen sollten wir jetzt ergreifen

Foto: AlexyPnferov/iStock

So stark unsere Werte auch sein mögen, sie reichen nicht aus, um uns in Zukunft erfolgreich zu machen. Wir brauchen einen klaren Plan mit strengen Maßnahmen und einen starken Umsetzungsprozess. (1) Wir brauchen einen einheitlichen europäischen digitalen Markt, einschließlich Israel mit mutigen und weitreichenden Entscheidungen. (2) Wir müssen die Praktiken ausländischer Technologieriesen verstehen, die auf die Schaffung von Mono- oder allenfalls Duopolen ausgelegt sind, und bestmöglich eindämmen. (3) Gleichzeitig müssen wir europäischen Unternehmen helfen, digitale Marktführer zu werden. (4) Wir sollten uns auch auf das sogenannte "Internet of Need" konzentrieren – im Gegensatz zum "Internet der Desire", welches wir bereits an die USA und China verloren haben. Mit dem "Internet of Need" meine ich das digitale Rückgrat unserer gesamten globalen Infrastruktur, von der Energieerzeugung über Logistik, Fertigung, Landwirtschaft, Wohnungsbau, Gesundheit und Mobilität. Hier haben wir unsere Stärken und hier wird die nächste Welle digitaler Innovationen stattfinden. (5)

Europa muss viel mehr Geld für die digitale Technologie und ihre Umsetzung ausgeben. So ist beispielsweise die deutsche Initiative für Künstliche Intelligenz ein Tropfen auf den heißen Stein, verglichen mit dreistelligen Milliardensummen, die die chinesische Volksrepublik und ihre Provinzen und Städte in solche Projekte investiert hat. (6) Schlussendlich brauchen wir weit mehr vom Unternehmergeist der USA und der "Leapfrogging"-Mentalität Chinas. Um Peter Thiel zu zitieren, Mitbegründer von PayPal: "Wenn du das erste Mal mit Deinem Produkt auf den Markt kommst und Du schämst dich nicht, dann bist Du zu spät"⁸.

Fazit

Unsere Wissenschaftler, Top-Manager und politischen Führungskräfte beginnen zu verstehen, dass die nächste Phase der digitalen Revolution völlig neue transparente Antworten auf viele kritische Fragen erfordert. Die wichtigsten sind unten angeführt.



Abbildung 4: Es gibt viele Fragen, die wir beantworten müssen – einige Denkanstöße
Foto: Flory/iStock

Menschenwürde: Inwieweit sollten wir uns in die "Unvollkommenheit" des Menschen einmischen? Wie können wir die Schaffung reiner Monopole verhindern? Wie sollten wir mit dem Konflikt zwischen "Universalethik" und "utilitaristischer Ethik" umgehen?

Freiheit: Wie können wir einen "menschenzentrierten" Ansatz für Daten etablieren, bei dem jeder selbst entscheiden kann, wie und wo seine Daten verwendet werden?

Gleichstellung: Wie können wir sicherstellen, dass in Zukunft alle Menschen auf der Welt eine Art digitale Gerechtigkeit erleben und nicht ausgebeutet werden?

Demokratie und Partizipation: Können wir Prinzipien des "Social Scoring" nutzen, um eine bessere Gesellschaft zu schaffen – ohne "nonkonformistisches" Verhalten auszuschließen? Oder sind wir damit

⁸ https://www.capital.de/wirtschaft-politik/deutschland-braucht-einen-ueberzeugenden-zukunftsentwurf?article_onepage=true (Stand 09.01. 2020)

auf dem direkten Weg in den Überwachungsstaat? Wie gehen wir mit datengesteuerten Analysen um, die im Widerspruch zur herrschenden Meinung stehen? Brauchen wir eine moralische Autorität, um die Gültigkeit unserer Analyseergebnisse zu überprüfen?

Redefreiheit: Wie können wir die Meinungsfreiheit gewährleisten und gleichzeitig Cybermobbing und die unkontrollierte Verbreitung irreführender Informationen verhindern?

Diese und viele andere Antworten müssen wir finden auf dem Weg in die vierte industrielle Revolution. Denn, um es mit den Worten des Innovationsexperten Dave Boddin zu sagen: "Das Wichtigste in der Digitalisierung ist das Nichtvergessen der Menschlichkeit".⁹

⁹ <https://www.erfolgsentwicklung.ch/f%C3%BCr-unternehmen/kmu-digitalisierung-und-faktor-mensch/> (Stand 09.01. 2020)

2. Chancen und Herausforderungen für die Versicherungswirtschaft durch Künstliche Intelligenz

Prof. Dr. Jan-Philipp Schmidt

Abstract

Künstliche Intelligenz ist derzeit ein beliebtes und viel diskutiertes Thema in der Versicherungsbranche. Die Auswirkungen bewertet die Fachwelt unterschiedlich. Teilweise ist sogar von einer Revolution die Rede. Aktuell kann jedoch niemand mit absoluter Sicherheit ihre genauen Auswirkungen und Folgen benennen. In diesem Beitrag geht es um eine kurze Erläuterung sowie einen Überblick darüber, was Künstlichen Intelligenz bedeutet. Außerdem wird kurz aufgezeigt, welche Chancen und Herausforderungen sich hierdurch speziell für die Versicherungswirtschaft ergeben.

Einordnung der Begriffe der Künstlichen Intelligenz und des Maschinellen Lernens

Was ist Künstliche Intelligenz (KI)? Eine Antwort auf diese Frage ist aus unterschiedlichen Gründen schwierig: Einerseits ist „Intelligenz“ aufgrund der Vielschichtigkeit des Begriffs schwierig zu definieren, andererseits kommt „Künstliche Intelligenz“ aktuell in vielen verschiedenen Disziplinen mit unterschiedlichem Fokus zum Einsatz, so dass eine Einschränkung auf einen einzelnen Bereich nicht dem Umfang gerecht wird. Eine sehr allgemeine Definition gibt Max Tegmark (Tegmark 2017). Er definiert zunächst Intelligenz als „die Fähigkeit, komplexe Ziele zu erreichen“. Unter „Künstlicher Intelligenz“ versteht er dann „nichtbiologische Intelligenz“. So betrachtet kann die Kalkulation einer Versicherungsprämie durch einen Tarifrechner bereits als Künstliche Intelligenz bezeichnet werden. Aber auch auf andere Ziele ausgerichtete Algorithmen – vom Schachspiel durch Computer bis zur automatisierten Produktempfehlung im Internet – können somit als Künstliche Intelligenz bezeichnet werden. Die Definition von Tegmark ist nicht immer hilfreich, da sie extrem weit gefasst ist und dadurch Missverständnissen in Diskussionen über konkrete Anwendungsbereiche Vorschub leistet. Trotzdem sei sie hier aufgrund ihres universellen Charakters als Definition genannt.

Grundsätzlich wird zwischen starker und schwacher Künstlicher Intelligenz unterschieden: Starke Künstliche Intelligenz umfasst im Allgemeinen Ansätze, die versuchen, den Menschen in all seinen Fähigkeiten zu übertreffen. Häufig werden dann auch Bewusstsein oder Empathie als erforderliche Merkmal einer solchen starken KI genannt (Buxmann und Schmidt 2018). So weit ist die KI-Forschung bis dato noch nicht (Lenzen 2018). Demgegenüber sind die aktuell in der Versicherungswirtschaft diskutierten und umgesetzten KI-Algorithmen immer der schwachen Künstlichen Intelligenz zuzuordnende Beispiele (BaFin 2018, Swiss Re 2019). Hierbei werden Algorithmen für partiell abgegrenzte Problemstellungen entwickelt. Schwache KI könnte man somit als ein auf eine bestimmte Aufgabe zugeschnittenes Expertensystem ansehen.

In Algorithmen der KI kann die „Lernfähigkeit“ des Algorithmus eine wesentliche Anforderung sein. In diesem Kontext redet man dann vom „maschinellen Lernen“. Es geht beim maschinellen Lernen um Entscheidungen und Vorhersagen treffende Algorithmen auf Basis von Erfahrungsdaten. Maschinelles Lernen kommt in der Versicherungsbranche zum Einsatz, wenn für das jeweilige Problem eine große Datenbasis (z.B. auf Basis von Vergangenheitsdaten) zur Verfügung steht. Beeindruckende Erfolge des maschinellen Lernens in jüngster Vergangenheit stammen aus dem Bereich des Schachspiels. Die Firma DeepMind hat einen Algorithmus entwickelt, der lediglich die Spielregeln des Schachs kennt und zusätzlich gegen sich selbst spielen kann (Silver et al. 2018). Im Anschluss generiert dieser Schachcomputer durch Schachspiele gegen sich selbst Erfahrungsdaten und erlernt das Schachspiel in Perfektion. Dieser Algorithmus übertrifft die besten Schachcomputer und führt zu ungeahnten

Erkenntnissen im Schachspiel (Silver et al. 2018). Der Algorithmus ist ein Paradebeispiel für das maschinelle Lernen. Dieser Erfolg treibt aktuell aber gleichzeitig auch die Fantasie bezüglich Anwendungen außerhalb des Schachspiels, wie zum Beispiel in der Versicherungswirtschaft.

Voraussetzungen für Künstliche Intelligenz

Drei Faktoren begünstigen die aktuellen Entwicklungen rund um das Thema Künstliche Intelligenz: Erstens stehen günstig Rechenkapazitäten zur Verfügung, die, zweitens, sehr viele Daten verarbeiten können und, drittens, werten verbesserte Algorithmen die Daten aus (Brynjolfsson und McAfee 2014). Entscheidend für den Erfolg der Anwendung von Algorithmen ist jedoch auch das fachliche Wissen über konkrete Anwendungsfälle. Der interdisziplinäre Charakter des Versicherungsgeschäftes überträgt sich hier auf die Entwicklung von Künstlicher Intelligenz in dieser Branche.

Nicht jedes Projekt zur Künstlichen Intelligenz ist von Erfolg gekrönt. In vielen Anwendungen sind zwar die drei vorgenannten Faktoren vorhanden, jedoch liefern Algorithmen nicht die gewünschten Vorhersagen in zufriedenstellender Qualität. Ein Beispiel aus jüngster Vergangenheit ist der Versuch, Grippe-Wellen auf Basis von Suchmaschinen-Anfragen und auf Basis von Zeitreihenanalysen vorherzusagen (Lazer et al. 2014). Aber auch ein Blick in die Versicherungsunternehmen zeigt, dass hier nicht jedes Projekt erfolgreich beendet werden konnte.

Chancen für die Versicherungswirtschaft

Was bedeutet das nun für die Wertschöpfung bei Versicherungsunternehmen? Hier werden zwei Bereiche genannt, in denen maschinelles Lernen erfolgsversprechend ist.

Der erste Bereich betrifft die zahlreichen technischen Prozesse in den Versicherungsunternehmen. Charakteristisch für viele Prozesse ist es, dass sie größtenteils standardisiert sind. Außerdem liegen hier Daten über einzelne Entscheidungen im Prozessverlauf der Vergangenheit vor, die (mit entsprechendem Aufwand bedingt durch die Datenaufbereitung) in der Regel auch verfügbar sind. Ein Beispiel ist der Schadenregulierungsprozess in der Schaden-/Unfallversicherung oder in der Krankenversicherung: Täglich wird über eine Vielzahl an Schäden entschieden, ob es zu einer Regulierung kommen kann. Dabei fließt enormes Fachwissen über die vertraglichen Leistungen, über den juristischen Kontext, über die Schadenhistorie des Kunden ein. KI wird hier heutzutage bereits eingesetzt, um genau diesen Prozess zu unterstützen, so dass es im Ergebnis zu Kosteneinsparungen kommen kann (Hahn und Zwiesler 2018).

Der zweite Bereich betrifft die Kundenschnittstelle und den Vertrieb. Hier kann künstliche Intelligenz in unterschiedlicher Art und Weise unterstützen. Der naheliegende Fall ist es, anhand von Vergangenheitsdaten zu lernen, bei welchen Kunden Cross- und Upselling möglicherweise am Vielversprechendsten sind. Das führt zu Umsatz- und – sofern das Geschäft profitabel ist – auch zu Gewinnsteigerungen. Möglich ist auch der umgekehrte Fall, nämlich der Fall, dass profitable Kunden gehalten werden sollen. Auch hier kann Künstliche Intelligenz wichtige Entscheidungen vorbereiten und unterstützen.

Herausforderungen für die Versicherungswirtschaft

Was sind die Herausforderungen, um Künstliche Intelligenz gewinnbringend im Unternehmen einzusetzen? Digitalisierungs-Themen und Künstliche Intelligenz sind ohne die Akzeptanz im Management und ohne Einbettung in den Ziele-Kanon des Unternehmens zum Scheitern verurteilt.

Eine wichtige Voraussetzung für erfolgreiche KI-Projekte sind unter anderem das fachliche versicherungsspezifische Know-how und die im Zeitverlauf in den jeweiligen Unternehmen

angesammelte Erfahrung der Mitarbeiter, um die Algorithmen an der richtigen Stelle mit den richtigen Daten zu versorgen und die Ergebnisse der Algorithmen richtig zu interpretieren und zu bewerten. Die Themen Statistik und Datenverarbeitung werden in den Unternehmen erheblich an Bedeutung gewinnen.

Die Qualifikationen in den Unternehmen werden sich ändern: Data Engineers, die die Big Data Infrastruktur entwerfen, Data Scientists, die die Algorithmen entwickeln sowie Data Analysten, die das Wissen in den Fachabteilungen nutzbar machen werden zukünftig in den Unternehmen Schlüsselpositionen besetzen. Wirtschaftsprüfer prüfen Bilanzen und Geschäftsberichte. Wer prüft die Algorithmen? Möglicherweise gibt es demnächst auch einen Data Science Revisor, der die Algorithmen prüft. Nicht jedes KI-Projekt wird einen sofortigen Erfolg darstellen. Die Erfahrung lehrt, dass hier „Try & Error“ – wie in vielen Bereichen des Lebens – zugelassen sein sollten.

Nach erfolgreicher Umsetzung eines KI-Projekt in einem Versicherungsunternehmen wartet eine weitere Herausforderung, denn Menschen tendieren zu Daten- und Technikgläubigkeit. So wie Menschen, die im Straßenverkehr den Aussagen ihres Navigationsgeräts mehr geglaubt haben, als dem Blick auf die Straße und die in der Folge in Flüsse gefahren sind, entsteht ein ähnliches Problem bei der blinden Anwendung von KI. Das Ergebnis von KI-Algorithmen ist häufig mit Unsicherheit verbunden. Das kritische Hinterfragen der KI-Ausgaben bleibt im Aufgabenbereich der zuständigen Menschen im Versicherungsunternehmen.

Fazit

Die Wertschöpfung in den Unternehmen wird sich durch Künstliche Intelligenz weiter verändern. Allerdings erfolgt dieser Wandel aktuell nicht ad hoc, sondern die Umsetzung – z. B. in den Prozessen – entwickelt sich schrittweise und muss dabei zunächst verschiedene Hindernisse (auch bezüglich der Akzeptanz und des Verständnisses) überwinden. In jedem Fall ist es sinnvoll, Mitarbeiterinnen und Mitarbeiter in den Wandel einzubeziehen, um die Vorteile durch Investitionen in Künstliche Intelligenz an den richtigen Stellen in den Unternehmen gewinnbringend nutzbar zu machen.

Literatur

BaFin. Big Data trifft auf künstliche Intelligenz, 2018.

Brynjolfsson, E., und A. McAfee. The Second Machine Age: Wie die nächste digitale Revolution unser aller Leben verändern wird. Plassen, 2014.

Buxmann, P., und H. Schmidt. Künstliche Intelligenz: Mit Algorithmen zum wirtschaftlichen Erfolg. Springer, 2018.

Hahn, L., und H.-J. Zwiesler. Wie können Versicherer ihre Daten intelligent nutzen? Versicherungswirtschaft heute, 15.03.2018.

Lazer, D., et al. "The Parable of Google Flu: Traps in Big Data Analysis." Science 343.6176 (2014): 1203-1205.

Lenzen, M. Künstliche Intelligenz: Was sie kann & was uns erwartet. C.H. Beck, 2018.

Tegmark, M. Leben 3.0: Mensch sein im Zeitalter Künstlicher Intelligenz. Ullstein, 2017.

Silver, D., et al. "A General Reinforcement Learning Algorithm that Masters Chess, Shogi, and Go through Self-play." Science 362.6419 (2018): 1140-1144.

Swiss Re. Sigma-Studie: Advanced Analytics, 2019.

3. Schreckgespenst oder Heilsbringer?

Big Data und Künstliche Intelligenz aus Sicht der Bürger und Kunden

Prof. Horst Müller-Peters

Digitale Vernetzung, Big Data und Künstliche Intelligenz sind bereits heute in unseren Alltag eingezogen und greifen in ihrer Anwendung unmittelbar ineinander. Dabei lässt sich Vernetzung als die *Quelle*, Big Data als der geförderte *Rohstoff* und die verwendeten Algorithmen – bzw. im Falle selbstlernender Algorithmen die Künstliche Intelligenz – als *Motor*, der aus den Daten Werte schafft, verstehen¹⁰.

Dabei schreitet die Technik weiterhin rasant voran: In Bezug auf die *Datenquellen* (z.B. durch omnipräsente Sensoren in Folge des „Internet of Things“ oder durch die zunehmende Messbarkeit von Bildern, Stimmen, Emotionen und in Zukunft möglicherweise sogar Gedanken), in Bezug auf die *Algorithmen* (siehe die massiven Investitionen, die derzeit – vielfach staatlich gefördert – in die Fortentwicklung der KI fließen) sowie bezüglich der realisierbaren *Rechenleistung* (Stichwort Edge Computing sowie Quantencomputing). Damit stehen wir immer noch erst am Anfang einer Entwicklung, die sowohl für den Einzelnen als Bürger oder Verbraucher als auch für die Wirtschaft, die handelnden Unternehmen und die Gesellschaft als Ganzes zu massiven Umbrüchen führen wird.

Gerade die Versicherungswirtschaft wird von diesem Wandel betroffen sein. Einerseits ist sie dank immaterieller Produkte und großer Datenmengen für den Einsatz von Big Data und KI geradezu prädestiniert. Andererseits wird sich ihr Geschäftsumfeld und die Wettbewerbssituation nachhaltig ändern, wenn Dienstleistungen immer mehr in digitalen Ökosystemen eingebettet sind und sich die Grenzen zwischen Branchen zunehmend auflösen. Dabei besteht die Gefahr, dass Versicherer den direkten Zugang zum Kunden verlieren und von Unternehmen, die themenübergreifend und kontinuierlich im Kundenkontakt stehen - seien es BMW oder Tesla, Paypal, Facebook, Google oder Amazon - zum reinen Zulieferer von Risikotransfer degradiert werden. Andererseits ergibt sich durch die neuen Technologien aber auch die Chance, die eigene Wertschöpfung auszubauen und so eine ganz neue, umfassendere Rolle für den Kunden zu entwickeln. Dies würde bedeuten, die bisherige, vorrangige Rolle des Schadenregulierers zu ersetzen oder zu ergänzen um eine oder mehrere der folgenden Rollen:

1. *„Retter“ oder „Schadenmanager“*: Ist ein Schaden eingetreten, tritt neben den eigentlichen finanziellen Schadenausgleich zunehmend das *„Management“* des Schadens, also z.B. die Unterstützung bei oder auch weitgehende Organisation von Reparaturen oder medizinischen Therapien. Mit zunehmender Vernetzung ergeben sich weitergehende Möglichkeiten, sowohl die Schäden zu erkennen als auch die Maßnahmen zu koordinieren und zu begleiten.
2. *„Coach“ oder „Schadenverhüter“*: Ebenso ermöglichen Vernetzung und die Analyse großer Datenbestände den Versicherern, schon vorab Risiken zu erkennen und durch Aufklärung, Verhaltensfeedbacks oder konkrete Präventionsmaßnahmen zu minimieren. Aufklärung und Feedback auf Basis von Verhaltensdaten erfolgt heute schon beispielsweise im Rahmen von telematischen Kfz-Policen oder im Kontext des Vitality-Programms der Generali Versicherung. Weitere Präventionsmaßnahmen sind zum Beispiel die Installation von Sensoren im Haushalt, regelmäßige Gesundheitschecks oder auch ein laufendes Gesundheitsmonitoring per Smartwatch oder Fitness-Tracker.

¹⁰ Vgl. Wess, S.: Mit Künstlicher Intelligenz immer die richtigen Entscheidungen treffen. In Buxmann, P., Schmidt, H. (Hrsg.): Künstliche Intelligenz: Mit Algorithmen zum wirtschaftlichen Erfolg. Springer, 2019, S. 157

3. *„Kontrolleur“ oder „Motivator“*: Wenn Risiken gemessen und erkannt werden, dann ist auch eine unmittelbare Einflussnahme auf das Verhalten des Versicherungsnehmers durch positive oder negative Sanktionen nicht mehr weit. Dies kann zum Beispiel über die Bepreisung erfolgen, aber auch in weitergehenden Handlungsvorschriften oder Verboten, welche wiederum durch Sensoren und Vernetzung überprüft werden können.

Bedingung für einen solchen Rollenwandel ist aber neben den technischen Anforderungen eine entsprechende Akzeptanz beim Kunden und in der Gesellschaft.

Daher haben wir im Herbst 2018 eine Befragung von 1.000 Bürgern durchgeführt mit dem Ziel, die Akzeptanz von Big Data & Co für die Gesellschaft im Allgemeinen und für die Versicherungswirtschaft im Speziellen abzuschätzen:

1. Welche Folgen erwarten die Bürger für Politik, Wirtschaft und Gesellschaft?
2. Welche Auswirkungen erwarten sie für das eigene Leben?
3. In welchem Umfang sind sie als Kunden bereit, Daten mit ihrem Versicherer zu teilen, und sich so – im Sinne der neuen Rollenbilder der Branche – zugunsten von Unterstützung, Einsparungen oder auch Risikominderung vermessen, überwachen oder sogar auch steuern zu lassen?

Die Befragung wurde im Rahmen eines umfassenderen Forschungsprojektes zu Big Data durchgeführt, das vom Goslar Institut für verbrauchergerechtes Versichern gefördert wurde und dessen Ergebnisse als Buch im Springer Verlag publiziert sind¹¹. Im Folgenden sind wesentliche Ergebnisse aus der Befragung in Kurzform zusammengefasst.

Negatives Fernbild, positives Nahbild

In den Köpfen der Bürger überwiegt eine skeptische bis ablehnende Grundeinstellung gegenüber Big Data, KI und maschinellen Entscheidungen. Risiken werden gegenüber Chancen deutlich überbetont. Insbesondere bezüglich sozialer, gesellschaftlicher und volkswirtschaftlicher Auswirkungen dominieren die Bedenken. In der Summe ist die Wahrnehmung von Big Data in hohem Maße von einem dystopischen „Big-Brother“-Narrativ bestimmt.

¹¹ Knorre, S., Müller-Peters, H., Wagner, F.: Die Big-Data-Debatte. Chancen und Risiken der digital vernetzten Gesellschaft. Springer 2020. Das Buch kann auch online unter dem Link <https://www.springerprofessional.de/die-big-data-debatte/17123958> abgerufen werden.

Wenn Sie einmal insgesamt an Nutzen und Risiken bei der Erfassung und Verarbeitung persönlicher Daten denken, welcher der folgenden Vergleiche erscheint Ihnen dabei treffend? Ist das wie ein ...

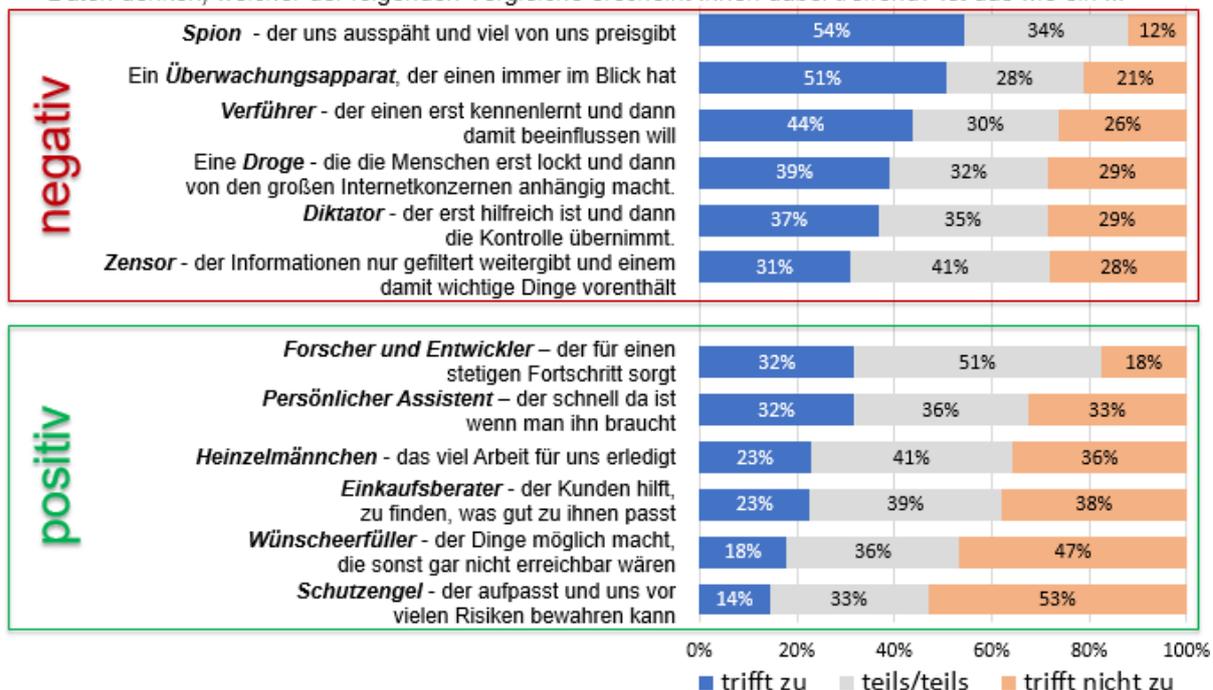


Abbildung 5: Narrative rund um „Big Data“. Wir haben die Befragten um Auskunft gebeten, wie weit sie positive und negative Analogien zum Einsatz von Big Data für zutreffend halten. Die meistgenannten Begriffe Spion, Überwachungsapparat, Verführer, Droge und Diktator verdeutlichen die große Skepsis, die dem Thema aus der ‚Fernsicht‘ entgegenschlägt. Positive Erzählungen, die den konkreten Nutzen neuer Anwendungen in die Vorstellungswelt der Menschen transportieren könnten, folgen erst weit danach.

Diese negative Einschätzung ändert sich aber, wenn anhand ganz konkreter Anwendungsfelder der Nutzen von Big Data verdeutlicht wird. Zahlreiche von uns abgefragte Anwendungen in den Lebenswelten Mobilität, Wohnen und Gesundheit werden mehrheitlich begrüßt. Das gilt besonders, wenn die Sicherheit erhöht wird oder wenn lästige Tätigkeiten des Alltags automatisiert oder erleichtert werden. Wenn der Nutzen der Anwendung ersichtlich wird, tritt auch die Sorge vor Überwachung in den Hintergrund. Zugleich möchte der Bürger aber auch nicht zum ‚Objekt‘ der Algorithmen degradiert werden: Klassifizierungen (also sogenannte ‚Scorings‘) oder gar automatisierte Entscheidungen werden mehrheitlich abgelehnt. Auch Anwendungen im Marketing – z.B. durch ‚Microtargeting‘, dynamische Preissetzung oder der Kundenbetreuung über Chatbots, wird mit hoher Skepsis begegnet.

Sorgloses Verhalten

Insgesamt finden die grundlegenden Befürchtungen zu Big Data kaum Niederschlag im alltäglichen Handeln. Obwohl der Schutz persönlicher Daten den meisten Menschen nach wie vor als bedeutsam erscheint, verhalten sich die Bürger als Konsumenten unachtsam bzw. sorglos. Das Internet wird intensivst und über unterschiedlichste Geräte genutzt. Damit sind die User über zahlreiche Dienste und Devices im ‚Netz‘ der Anbieter und hinterlassen dort umfassende Datenspuren. Dabei werden insbesondere – ungeachtet der vorhandenen volkswirtschaftlichen und datenschutzrechtlichen Bedenken – die bekannten „Internetgiganten“ genutzt. Die Reichweite und der Funktionsumfang dieser globalen Player überkompensieren ‚Nähe‘ und vielfach höhere Datenschutzstandards nationaler Wettbewerber. Auch mögliche Datenschutzmaßnahmen werden zwar durchaus genutzt,

die große Mehrheit verhält sich in dieser Beziehung aber allenfalls ‚pragmatisch‘ (negativ formuliert ließe sich auch sagen: ‚leicht fahrlässig‘), nicht einmal jeder zehnte Nutzer ließe sich als konsequent ‚datenschutz-aktiv‘ bezeichnen.

In der Summe zeigen sich demnach besorgte Bürger, aber sorglose Verbraucher.

Defizite im „Wissen“, „Können“ und im „Wollen“

Als Begründung für diese Diskrepanz finden sich einerseits Defizite im *Wissensstand*: So ist zwar ein digitales Grundwissen durchaus vorhanden, Lücken bestehen aber gerade zu Fragen von Big Data, Privacy und Aspekten der digitalen Vernetzung.

Könnten Sie einem Bekannten erklären, was mit den folgenden Stichworten gemeint ist?

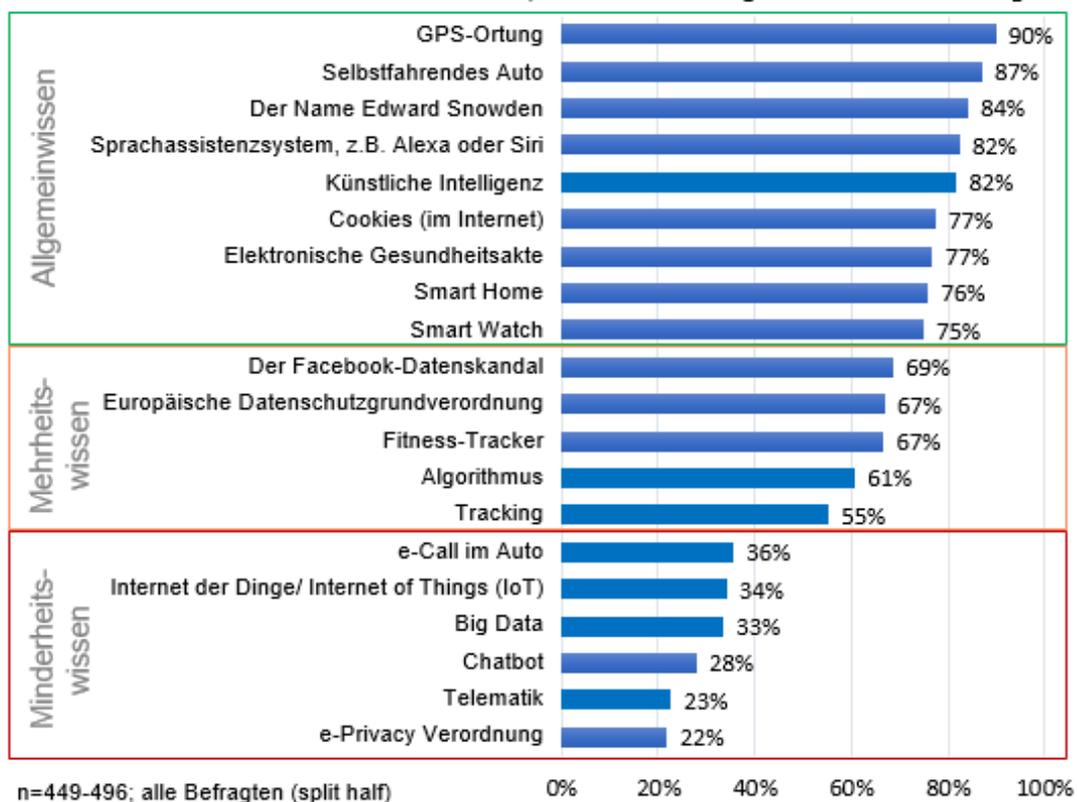


Abbildung 6: Datenwissen

Zugleich fühlen sich die User durch digitale Monopole sowie der Komplexität der Thematik in ihrer Handlungsfreiheit eingeschränkt („Können“).

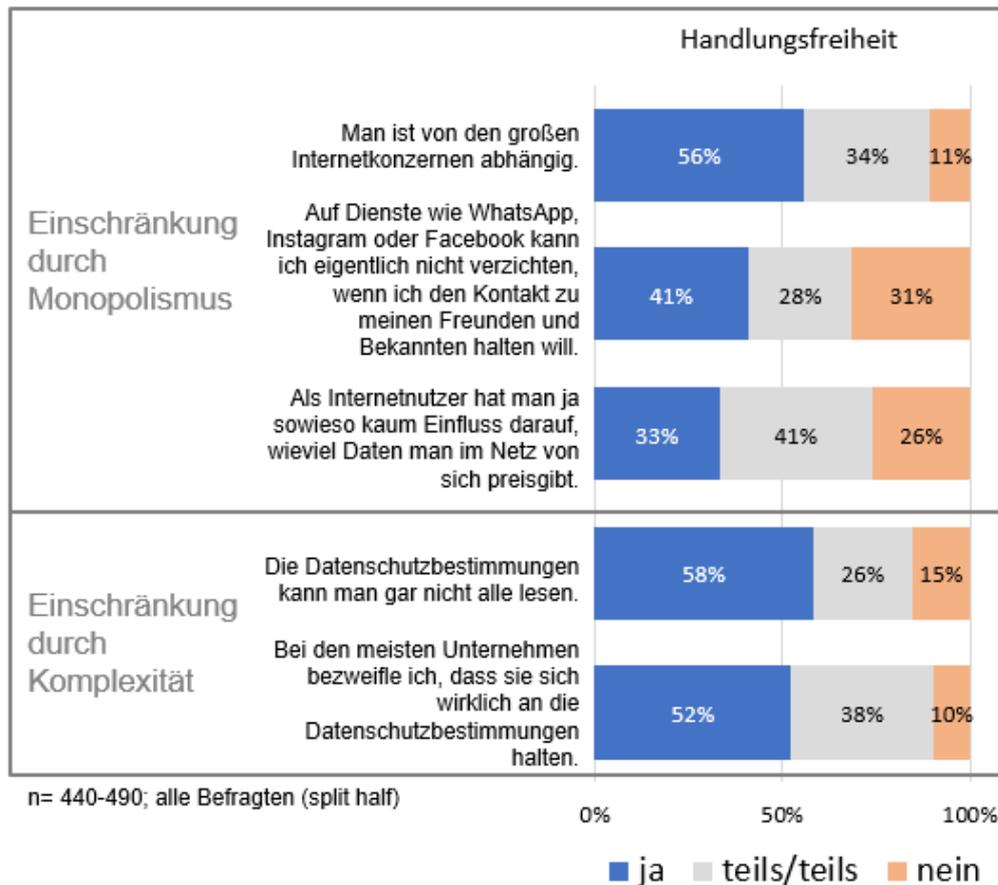


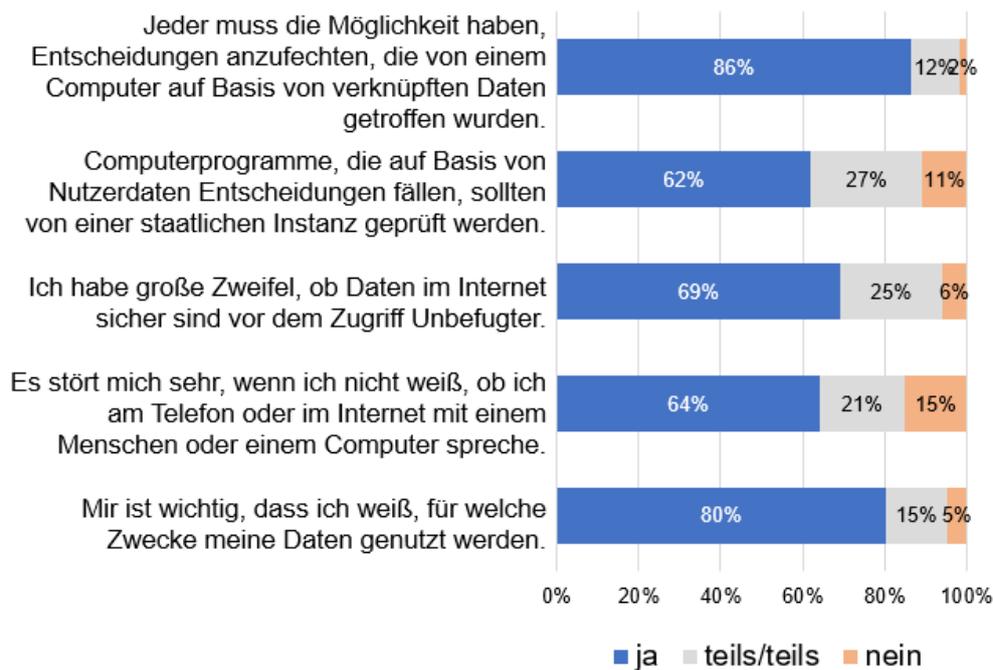
Abbildung 7: Wahrgenommene Handlungsfreiheit („Können“)

Und schließlich fehlt eine ausreichende Motivation („Wollen“), sich auch im Alltag um Fragen des Datenschutzes respektive der Privatsphäre – z.B. durch die nur selektive Zulassung von Cookies, die Aktualisierung von Passwörtern oder dem Lesen von Datenschutzbedingungen - zu kümmern.

Erwartungen an Datenpolitik und Datensysteme

Die Erwartungen an die Politik sind dagegen durchaus hoch. Bürger befürworten ein persönliches Eigentum an den eigenen Daten, sind skeptisch gegenüber allen Arten automatisierter Entscheidungen und sind nur sehr begrenzt bereit, dass die Politik den Datenschutz zugunsten der internationalen Wettbewerbsfähigkeit der Wirtschaft hintenanstellt.

Zudem herrscht ein breiter Konsens bezüglich der Grundanforderungen an datengestützte Systeme, nämlich Fairness und Nachvollziehbarkeit. Dies impliziert Transparenz, Vertrauen oder Kontrolle sowie Diskriminierungsfreiheit, Neutralität, Datenqualität und Datensicherheit. (Insbesondere die Forderung nach Datenqualität und Transparenz stellen den Einsatz unstrukturierter Daten und selbstlernender Algorithmen vor eine große Hürde).



n=479-501; alle Befragten (split half)

Abbildung 8: Fairness – Mindestanforderungen an Big Data und KI

Neue Paradigmen in der politischen Diskussion betonen Datensouveränität statt Datenschutz, freiwillige Datenethik der Unternehmen anstelle strikter Regulierung, sowie Open-Data-Ansätze anstelle oder ergänzend zum klassischen Wettbewerbsrecht. Die Konzepte von Datenschutz versus eigenverantwortlicher Datensouveränität des Einzelnen schließen sich aus Sicht unserer Befragten nicht aus, sondern werden gleichermaßen geteilt. Dennoch ist den meisten der Gedanke eher fremd, Daten im Sinne einer Ware zu ‚tauschen‘ (auch wenn dies faktisch schon breite gesellschaftliche Realität ist) oder gar zu ‚verkaufen‘ oder zu ‚spenden‘. Ist der gesellschaftliche Nutzen aber offensichtlich (wie im Fall der medizinischen Forschung gegeben), erhöht sich die Bereitschaft zur Datenüberlassung ganz erheblich.

Zugleich fordern die Bürger überwiegend eine enge staatliche Regulierung des Umgangs mit Daten. Der eigentlich gegenteilige Gedanke einer weitgehend freiwilligen Selbstverpflichtung der Unternehmen findet zwar ebenfalls eine recht breite Akzeptanz, dürfte aber im Detail stark vom Vertrauen in ebenjene abhängen. Auch ein Eingriff des Staates gegen die Marktmacht der ‚Internetgiganten‘ wird in Mehrheit unterstützt. Dabei findet auch das recht neue Modell der ‚Open Data‘, bei dem der Wettbewerbsvorsprung von Monopolisten durch erzwungenes Data-Sharing beschnitten wird, um Innovation und Wettbewerb zu stärken, mehr Zustimmung als Ablehnung – und könnte bei intensiverer Kommunikation durchaus ‚mehrheitsfähig‘ werden.

Rollenwandel für die Versicherungswirtschaft?

Die Versicherungswirtschaft könnte auf Basis von Daten und Vernetzung neue Rollen in der Gesellschaft übernehmen, indem sie sich – wie schon eingangs beschrieben – vom Kostenerstatter wandelt zum ‚Retter‘ oder ‚Schadenmanager‘ zum ‚Coach‘ oder ‚Schadenverhüter‘ sowie zum ‚Kontrolleur‘ oder ‚Motivator‘. In der Summe zeigen sich die Befragten diesen neuen Rollen gegenüber

durchaus aufgeschlossen. Deutlich zurückhaltender ist die persönliche Bereitschaft zur laufenden Übermittlung der notwendigen Daten, zum Beispiel durch Sensoren, Wearables oder auch durch den Arzt. Inwieweit ein Angebot – und auch die damit verbundene Weitergabe der Daten – im Einzelfall befürwortet wird, hängt mehr von dessen konkreter Ausgestaltung ab als von der dahinterstehenden Rolle. Gleiches gilt für die Frage, ob der Einsatz eher in der Lebenswelt Mobilität, Wohnen oder Gesundheit vorstellbar ist. Und selbst der Grad der Überwachung, der mit dem jeweiligen Angebot verbunden ist, tritt hinter die Attraktivität des jeweiligen Nutzenversprechens zurück.

Akzeptanz nach Rolle und nach Sparte

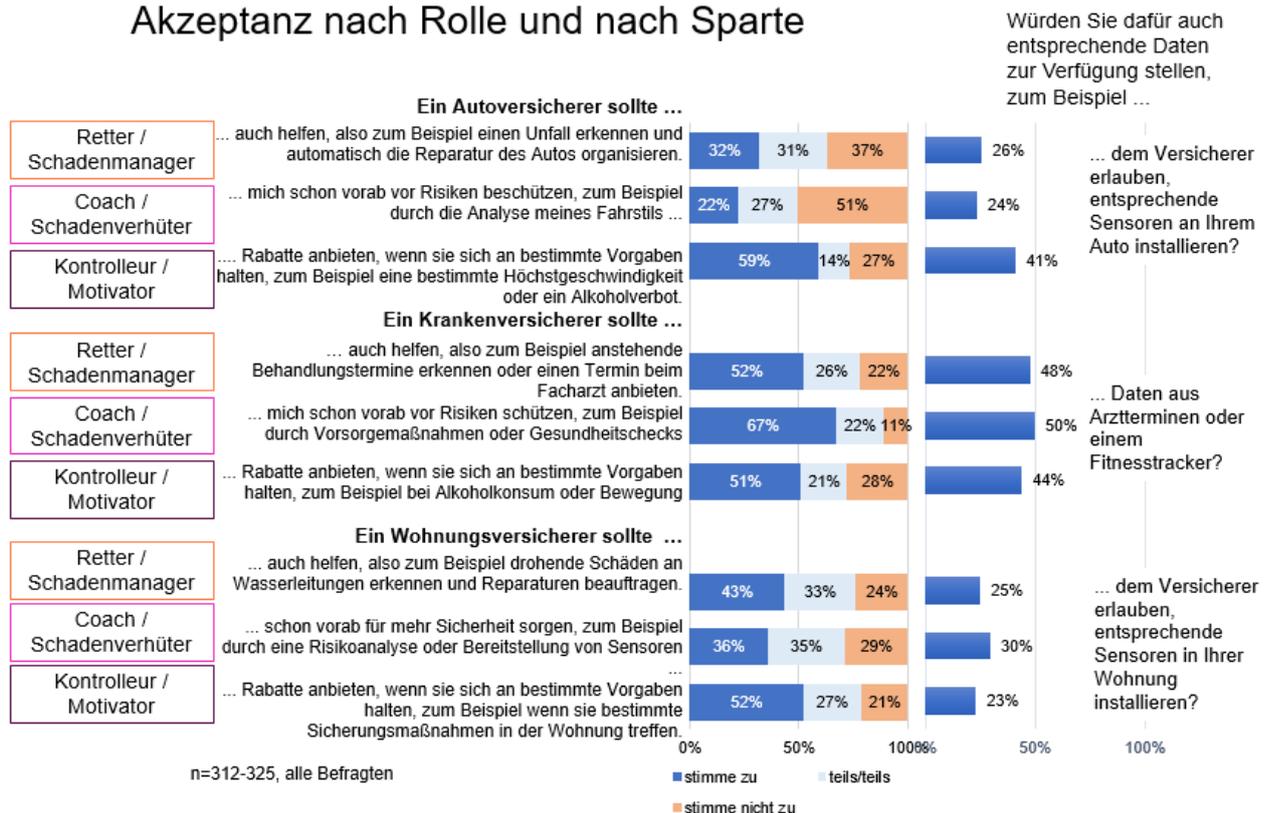


Abbildung 9: Neue Rollen für die Versicherungswirtschaft

In Summe lässt sich eine insgesamt hohe Bereitschaft der Bürger respektive Kunden erkennen, neue, erweiterte Rollen der Versicherer anzunehmen.

Fazit: Bürgerschreck und Hoffnungsträger – und eine Chance für die Assekuranz

Im Gesamtbild der Ergebnisse verdichtet sich das Paradoxon: Die Bürger fordern Datenschutz, beklagen übermächtige Konzerne und fühlen sich in ihrer Freiheit beschränkt – aber handeln nicht danach, sondern folgen ‚brav der Herde‘. Sie fürchten Big Data, aber sind gerne bereit, die aus der Vernetzung resultierenden Potenziale in ihre Lebenswelten einzulassen. Die Antwort auf die Frage, ob Big Data und KI eher als ‚Bürgerschreck‘ oder als ‚Hoffnungsträger‘ zu sehen sind, muss also lauten: Sowohl als auch!

Das Nutzer-Paradox steht diametral zum Ideal eines aufgeklärten und souveränen Datenbürgers. Ein politischer Paradigmenwechsel könnte in Teilen dazu beitragen, Brücken zwischen den empfundenen Risiken und den erhofften Chancen zu bauen. Ebenso kann die Etablierung positiver gesellschaftlicher ‚Erzählungen‘ als Ergänzung zur bislang dominierenden Big-Brother-Dystopie helfen, das bestehende

Schwarz-Weiß-Bild zu überwinden. Wesentliche Grundbedingungen dazu sind – neben dem eigentlichen Nutzen der Anwendungen – Fairness und Sicherheit der Systeme sowie Transparenz und Vertrauen in die Akteure. Für die Versicherungswirtschaft ergibt sich – unter Beachtung dieser Bedingungen – die Chance, einerseits durch eine Ausweitung ihrer Rolle eine zentralere Position im Bewusstsein ihrer Kunden einzunehmen (und so zugleich die Kundenbeziehung zu festigen und ihren „Share of Wallet“ auszubauen), und sich gleichzeitig als vertrauenswürdiger Partner im Umgang mit den persönlichen Daten zu etablieren.

4. Von Kragenechsen und Mistkäfern: Big Data und KI in der Marktbearbeitung

Prof. Dr. Michael Völler

Eine gute und große Datenbasis ermöglicht Lernprozesse, sowohl früher in der analogen als auch heute in der digitalen Welt. Je mehr der Schneider über seinen Kunden weiß, seine Körpermaße, seine Stoff- und Farbvorlieben, seinen Beruf und seinen Lebenswandel, seine Erreichbarkeit und seine zeitliche Verfügbarkeit, desto passgenauer kann er ihn bedienen und zufriedenstellen. Je größer und besser die Datenbasis ist, desto leichter können verbesserte Produkte und optimierte Prozesse abgeleitet werden. Je größer die Datenmengen und je besser die Datenqualität ist, desto mehr lernt ein Algorithmus und desto hilfreicher sind seine Ergebnisse. So treibt der technologische Fortschritt die Weiterentwicklung der Datenbasis an, und die verfügbare Datenbasis treibt wiederum den KI-Hype an.

Der Begriff Big Data beschreibt den „Einsatz großer Datenmengen aus vielfältigen Quellen mit einer hohen Verarbeitungsgeschwindigkeit zur Erzeugung wirtschaftlichen Nutzens“ (Bitkom 2012, S. 21).

Big Data überschreiten die Prozessorleistung konventioneller Datenbanksysteme (vgl. Dumbill 2013, S. 1). Sie zeichnen sich durch die 3Vs „Volume“, „Velocity“ und „Variety“ aus (vgl. Dumbill 2012, S. 10ff, Weber/Burchardt 2017, S. 27):

- Volume (deutsch Umfang): Es handelt sich um sehr große Datenmengen, die durch neue technologische Möglichkeiten wie Sensoren und speziell IoT anfallen und durch Cloud-Technologie gespeichert werden können.
- Velocity (deutsch Geschwindigkeit): Sie fallen in hoher Geschwindigkeit an und können dank der modernen Prozessorleistung mit hoher Geschwindigkeit verarbeitet werden.
- Variety (deutsch Vielfalt): Sie liegen in vielfältigen Datentypen aus vielfältigen Datenquellen vor und sind nicht auf strukturierte Daten beschränkt.

Erinnerung: Big Data zeichnen sich durch 3Vs aus.

V **olume**
➔ Verfügbarkeit sehr großer Datenmengen & enorme Speicherkapazitäten in der Cloud

elocity
➔ Geschwindigkeit, mit der Daten anfallen & Echtzeit-Verarbeitung (enorme Rechenleistung)

ariety
➔ Vielfalt an Typen & Quellen von Daten

Eine (gute und große) Datenbasis ermöglicht Lernprozesse: Big Data treiben somit den KI-Hype an.

Bildquelle: Markus Vogelbacher, pixelio.de

14.11.2019

© Prof. Dr. Michael Völler
Forschungsstelle Versicherungsmarkt
Institut für Versicherungswesen

ivwKöln
Institut für
Versicherungswesen

Technology
Arts Sciences
TH Köln

Abbildung 10: Die 3Vs von Big Data

Einige Autoren führen ein viertes V, nämlich „Veracity“ (deutsch Richtigkeit), an, um das Problem der Ungewissheit bestimmter Daten zu unterstreichen (vgl. Schroeck et al. 2012, S. 4). Die Zuverlässigkeit

der Daten und ihre damit verbundene Aussagekraft müssen bei datenbasierten Entscheidungen berücksichtigt werden.

Mit Künstlicher Intelligenz soll wirtschaftlicher Nutzen aus Big Data gezogen werden. (Schwache) KI umfasst smarte Mensch-Maschine-Interaktion und -Kollaboration zur effektiven Unterstützung von Problemlösungen zu einzelnen von Menschen formulierten Problemstellungen (vgl. Weber/ Burchardt 2017, S. 29). Es geht also beim Einsatz von KI nicht darum, Menschen überflüssig zu machen, sondern sie bei bestimmten, abgegrenzten Problemstellungen intelligent zu unterstützen. Unmenschliche oder unangenehme Arbeiten können zugleich vermieden werden.

Erinnerung: KI bezeichnet die Eigenschaft eines IT-Systems, "mensenähnliche" intelligente Verhaltensweisen zu zeigen.

(Schwache) KI umfasst

smarte Mensch-Maschine-Interaktion und -Kollaboration
zur **effektiven Unterstützung von Problemlösungen**
zu einzelnen von Menschen formulierten Problemstellungen.

= Menschen intelligent unterstützen
≠ Menschen überflüssig machen

Vgl. Weber/Burchardt (2017), S.29

14.11.2019

© Prof. Dr. Michaela Völler
Forschungsstelle Versicherungsmarkt
Institut für Versicherungswesen

ivwKöln
Institut für
Versicherungswesen

Technology
Arts Sciences
TH Köln

Abbildung 11: Schwache Künstliche Intelligenz

Das vereinfachte Modell einer modernen KI umfasst vier Kernfähigkeiten, die hierfür eingesetzt werden (vgl. Purdy & Daugherty 2016, S.10f, Weber & Burchardt 2017, S. 31f):

1. Sense (dt. Wahrnehmen)
2. Comprehend (dt. Verstehen)
3. Act (dt. Handeln) und
4. Learn (dt. Lernen)

Auf den ersten Blick erinnern die drei ersten Punkte an das EDV-Grundprinzip „Input – Process – Output“ (Eingabe – Verarbeitung – Ausgabe), jedoch gehen die KI-Kernkomponenten darüber hinaus. Der wesentliche Unterschied besteht darin, dass die KI sowohl in der Trainingsphase als auch im laufenden Betrieb aus Fehlern und durch Feedback lernt (Learn) und somit ihre Verarbeitung anpassen kann (Comprehend). Somit können bessere Ergebnisse als bei starren, fest programmierten Verfahren (Process) erzielt werden.

Aber auch der Input und der Output sind im KI-Modell weiter gefasst. Mit „Sense“ wird den Aspekten „Volume“ und „Variety“ aus der 3V-Charakterisierung von Big Data Rechnung getragen. Riesige

Datenmengen und verschiedenste Datenarten bilden den Ausgangspunkt für den Algorithmus. Der Input ist nicht länger auf EDV-Daten beschränkt, sondern umfasst die vielfältigsten Formate.

Die Ausgabe (Output) deckt ebenfalls ein breiteres Spektrum an Möglichkeiten ab. Es können nicht nur strukturierte Daten erzeugt werden wie schon beim traditionellen EDV-Prozess, sondern beispielsweise auch Prozesse und Geräte intelligent gesteuert werden.

Die vier Kernkomponenten einer KI gehen über das EDV-Grundprinzip Input-Process-Output hinaus.

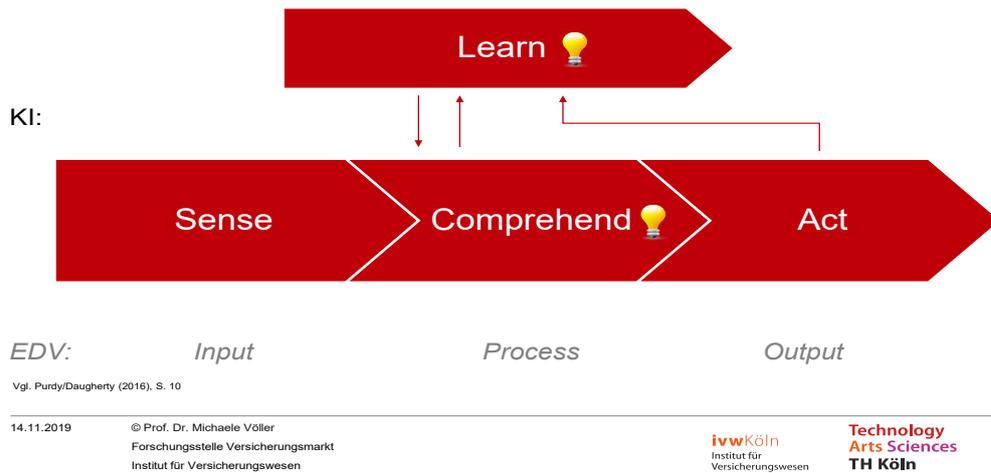


Abbildung 12: Die vier Kernkomponenten einer KI

Diese vier Kernfähigkeiten sollten sich natürlich auch im Alltag einer guten Marktbearbeitung jenseits von KI-Anwendungen wiederfinden. Im Idealfall geht es auch hier um Wahrnehmen, Verstehen, Handeln und Lernen anstatt um bloße Eingabe, starre Verarbeitung und Ausgabe.

Wenig erstaunlich: Die vier Kernkomponenten finden sich auch im Alltag einer guten Marktbearbeitung wieder.

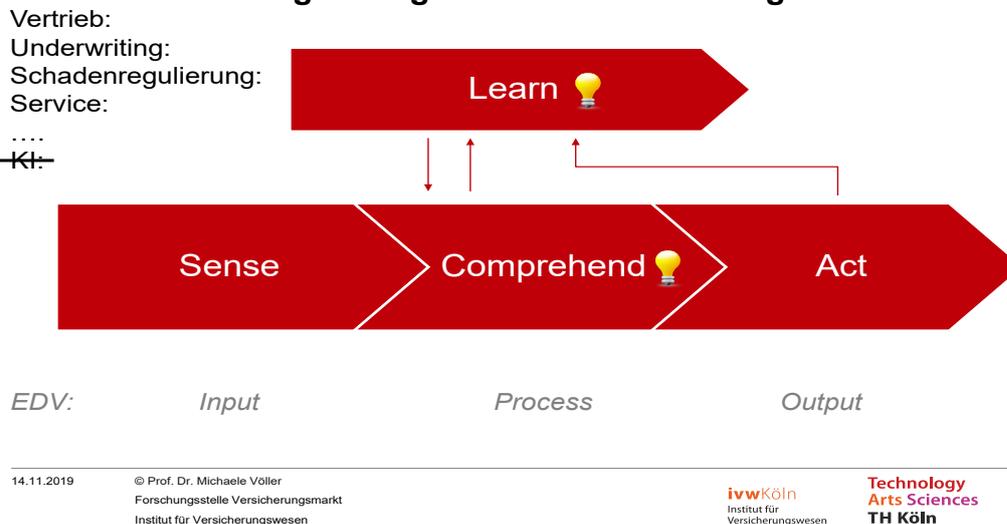


Abbildung 13: Die vier Kernkomponenten in der Marktbearbeitung

Beispiele aus den verschiedensten Bereichen eines Versicherungsunternehmens illustrieren dies. Je mehr ein Vermittler über den Kunden wahrnimmt und versteht, desto besser kann er ihn betreuen, aus seinen Reaktionen lernen und seine Angebote und Unterstützungsleistungen weiter verfeinern. Je mehr eine Underwriterin über das Risiko erfährt und versteht, desto fundiertere Underwriting-Entscheidungen kann sie treffen und sie mit zunehmenden Erfahrungen kontinuierlich verbessern. Je mehr Daten in der Schadenregulierung gewonnen und verstanden werden, desto effizienter und treffsicherer wird reguliert und Betrug vermieden. Die Erfahrungen fließen zudem auch hier in die stetige Verbesserung des Prozesses ein. Je mehr Datenpunkte ich zu einem Kunden sammle, auswerte und anwende, desto besser kann ich ihn begeistern. Fehler, die zunächst aufgrund von Nichtwissen, geringer Erfahrung oder lückenhaften Daten auftreten, können durch Lerneffekte zunehmend vermieden werden.

Moderne KI-Anwendungen können den Menschen bei diesen Aufgaben unterstützen. Durch KI-Einsatz kann das Potenzial entlang der vier Kernkomponenten in der Marktbearbeitung gehoben werden. Im Bereich der Wahrnehmung (Sense) kann die Maschine den Menschen unterstützen, riesige Datenmengen und unterschiedlichste Datenarten in kürzester Zeit zu erfassen und auszuwerten. Big Data und ihre 3V sind mit menschlicher Intelligenz allein nicht beherrschbar, so dass eine maschinelle Unterstützung erforderlich ist. Die verarbeitende Komponente (Comprehend) wird um KI-Methoden erweitert, um datengetriebene Erkenntnisse zu generieren. Innerhalb der KI-Methoden sind das Machine Learning, bei dem Algorithmen aus Daten lernen, ohne dass jeder Einzelfall programmiert wurde, und das Deep Learning, das Machine Learning mit großen neuronalen Netzen, besonders populär, da sie den Grundgedanken des Lernens (Learn) unterstützen.

Durch KI-Anwendungen kann das Potenzial entlang der vier Kernfähigkeiten in der Marktbearbeitung genutzt werden.

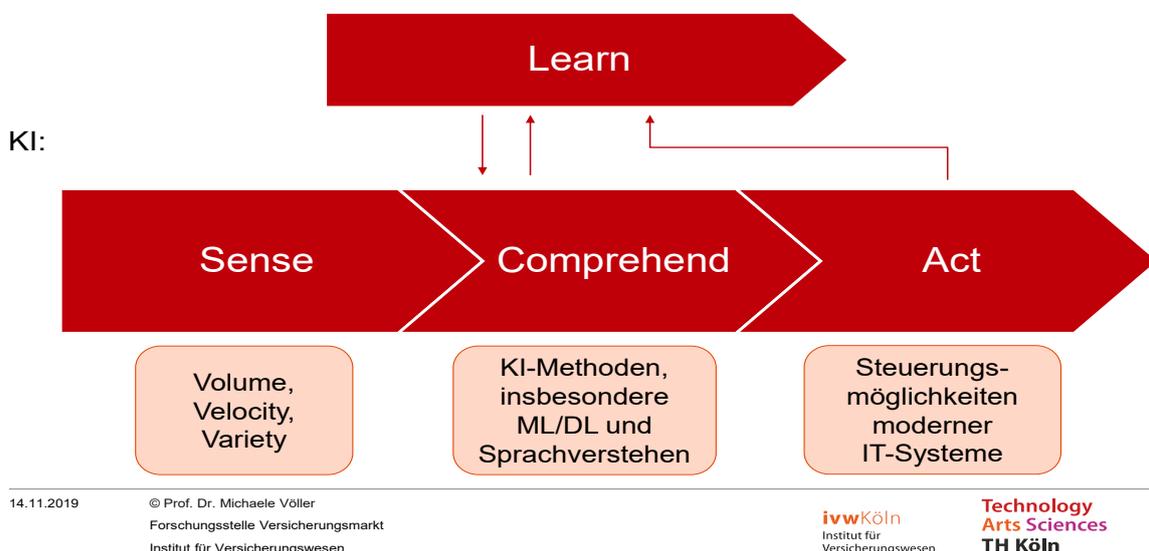


Abbildung 14: Unterstützung durch KI

Das Handeln (Act) umfasst alle Steuerungsmöglichkeiten moderner IT-Systeme, insbesondere die intelligente Steuerung von Prozessen und Geräten.

KI leistet allerdings oft nur einen Beitrag in klar definierten Bereichen und führt nicht zwangsläufig zur Vollautomatisierung. Der Bitkom-Präsident Achim Berg machte dies unlängst im September 2019

deutlich: „Die Vorstellungen von Künstlicher Intelligenz sind oft von Science-Fiction-Romanen und -Filmen geprägt. (...) KI erschließt heute in erster Linie Möglichkeiten für die Automatisierung von klar definierten Aufgaben, in vielen anderen Bereichen steckt KI noch in den Kinderschuhen.“¹²

Im Sinne solcher Anwendungen für klar definierte Aufgaben existieren unterschiedlichste KI-Funktionalitäten. Beispielhaft für die verschiedenen Übersichten von KI-Bausteinen sei hier auf Kristian Hammonds „Periodentafel der KI“ (Hammond 2016, S. 15) verwiesen. Hammond gruppiert die KI-Elemente in die Gruppen „Assess“ (Bemessen), „Infer“ (Schlussfolgern) und „Respond“ (Reagieren), die mit den zuvor erläuterten Komponenten „Sense“, „Comprehend“ und „Act“ korrespondieren. Lernen versteht er als Schlussfolgerungsprozess¹³, so dass die Komponente „Learn“ in seiner Periodentafel unter „Infer“ subsummiert wird.

Auch wenn die Übersicht aus heutiger Sicht nicht komplett und in mancherlei Hinsicht nicht perfekt sein mag, so zeigt sie doch gut die Vielfalt der KI-Funktionalitäten entlang des Prozesses. Etablierte Unternehmen und Startups nutzen einzelne oder eine Kombination von KI-Elementen. Der Begriff „KI“ taucht daher in der Praxis in höchst unterschiedlichen Kontexten und für höchst unterschiedliche Anwendungsszenarien auf.

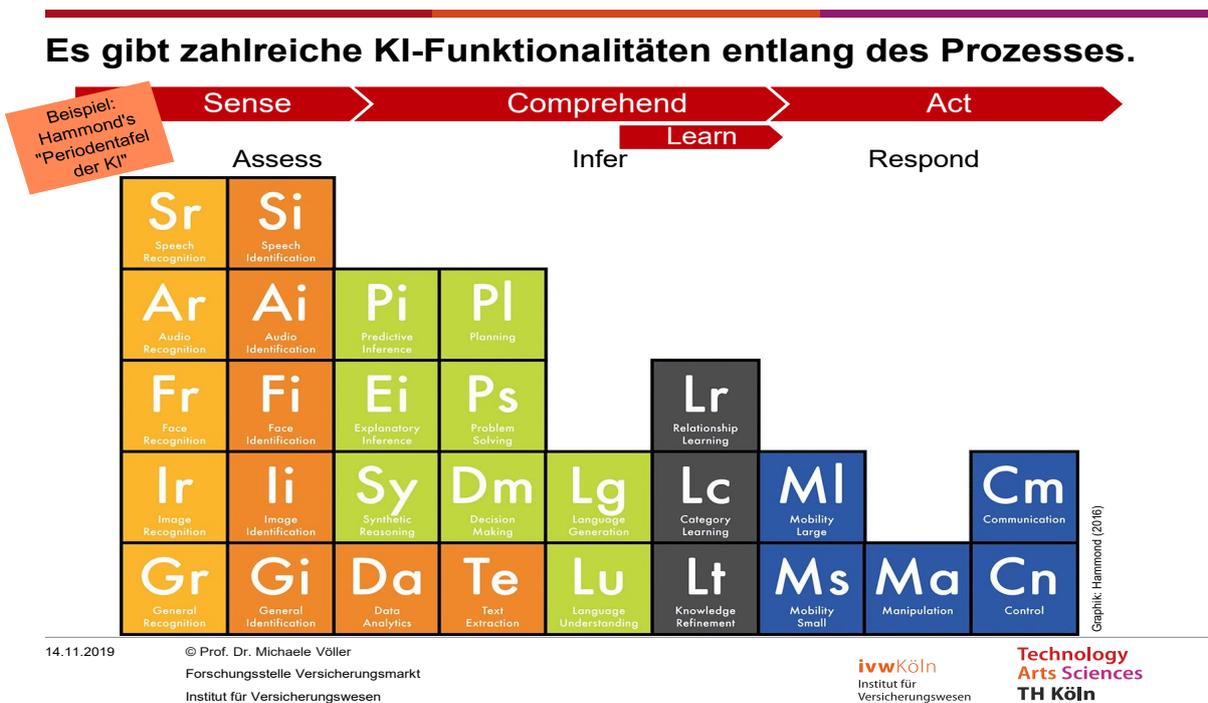


Abbildung 15: Hammond's Periodic Table of AI

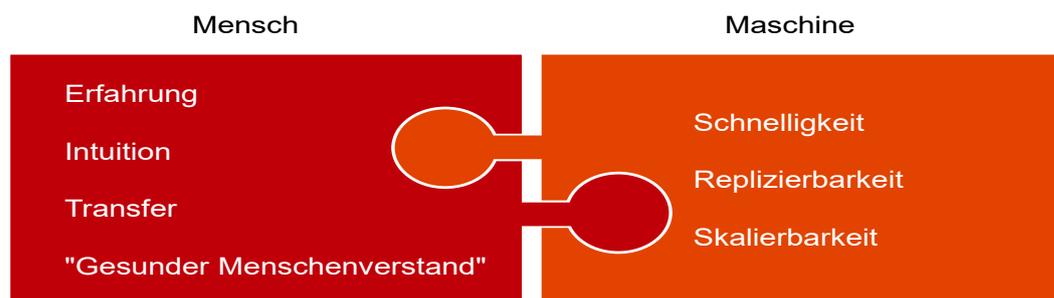
Es gilt somit, die relevanten und nutzenstiftenden KI-Elemente bewusst auszuwählen und in smarterer Weise für die zu lösende Problemstellung einzusetzen. Mensch und Maschine haben unterschiedliche Stärken. Es hängt daher vom Einsatzszenario ab, was die Maschine leisten und wie weit die Maschine übernehmen kann. Für nichtstandardisierte, kritische Fälle ist der Mensch im Vorteil, da er

¹² Bitkom, Pressemitteilung „KI kann viel, aber längst nicht alles“ vom 19. September 2019, <https://www.bitkom.org/Presse/Presseinformation/KI-kann-viel-aber-laengst-nicht-alles> (Zugriff am 6. Oktober 2019)

¹³ „Learning is an inference process“, Hammond 2016, S. 12

Entscheidungen auf Basis seiner Erfahrungen, Intuition und „gesundem Menschenverstand“ trifft und Gelerntes auf neue Problemstellungen und Kontexte übertragen kann. Für unkritische, standardisierte Fälle, die entsprechend in hoher Zahl auftreten, ist die Maschine aufgrund ihrer Schnelligkeit und Skalierbarkeit mit replizierbaren Ansätzen überlegen. Eine optimale wertschöpfende Mensch-Maschine-Interaktion verzahnt die unterschiedlichen Stärken im vorgegebenen konkreten Anwendungsszenario.

Wertschöpfende Mensch-Maschine-Interaktionen verzahnen die unterschiedliche Stärken in konkreten Einsatzszenarien.



14.11.2019

© Prof. Dr. Michaela Völler
Forschungsstelle Versicherungsmarkt
Institut für Versicherungswesen

ivwKöln
Institut für
Versicherungswesen

Technology
Arts Sciences
TH Köln

Abbildung 16: Verzahnung der Stärken von Mensch und Maschine

Im Fünf-Stufen-Modell der Entscheidungsautomation (Bitkom 2017, S. 14) verlagert sich die Entscheidungsfindung immer stärker vom Menschen zur Maschine hin. Das Verhältnis von Mensch zu Maschine ist so einzupendeln, dass für das konkrete Anwendungsszenario der größte Nutzen, also die besten Entscheidungen resultieren.

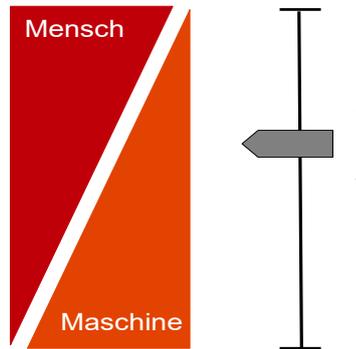
Auf den niedrigen Stufen führt die Interaktion zwischen Mensch und Maschine zu einer „Augmentation“ kognitiver Tätigkeiten. Für wenig automatisierbare Einsatzszenarien können KI-Anwendungen Informationen und Entscheidungshilfen generieren, die dem Menschen eine bessere Entscheidung und damit ein besseres Ergebnis ermöglichen. Die Rolle des Menschen bleibt hier zweifellos hoch. Durch die Interaktion und das menschliche Feedback kann zwar ein kontinuierliches Lernen der KI und eine Verbesserung der Algorithmen erfolgen, jedoch führt dies insbesondere für kritische Fälle nicht zur Vollautomatisierung.

Bei automatisierbaren Einsatzszenarien, für unkritische und standardisierte Fälle, können höhere Automationsstufen erreicht werden, bestenfalls eine „Automation“ bestehender kognitiver Aktivitäten. Letztlich bleibt aber auch hier der „Mensch in der Schleife“ („Human-in-the-loop“, vgl. Amershi et al. 2014) und behält eine wichtige Rolle als Qualitätssicherer und Kontrolleur.

Die angestrebte Automationsstufe hängt maßgeblich vom Einsatzszenario ab und sollte bewusst festgelegt werden. Selbst wenn die Entscheidung prinzipiell weitgehend auf die Maschine verlagert werden könnte, könnten ethische Gründe gegen eine hohe Automatisierung sprechen.

Das Verhältnis von Mensch und Maschine ist so einzupendeln, dass die Entscheidungen zu guten Resultaten führen.

- 0. Mensch entscheidet
- 1. Assistiertes Entscheiden
- 2. Teilweises Entscheiden
- 3. Geprüftes Entscheiden
- 4. Delegiertes Entscheiden
- 5. Autonomes Entscheiden



14.11.2019

© Prof. Dr. Michaela Völler
Forschungsstelle Versicherungsmarkt
Institut für Versicherungswesen

ivwKöln
Institut für
Versicherungswesen

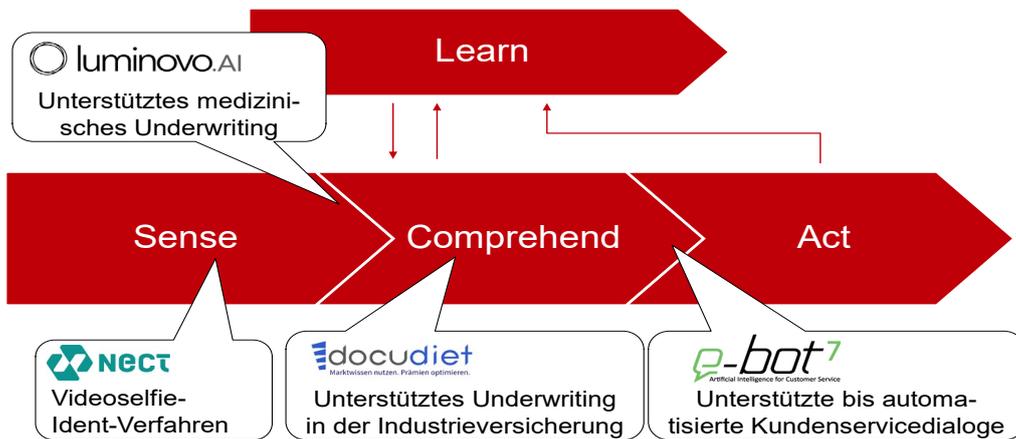
Technology
Arts Sciences
TH Köln

Abbildung 17: Fünf-Stufen-Modell der Entscheidungsautomatization

Auch ohne Vollautomatisierung können KI-Anwendungen Marktprozesse verbessern, sowohl aus Kunden- als auch aus Anbietersicht. Zur Illustration werden nachfolgend vier Beispiele von Startups aus dem Accelerator-Programm 2019 des Insurlab Germany angerissen, die KI-basierte Lösungen entwickelt haben.

KI-Lösungen können Marktprozesse verbessern – sowohl aus Kunden- als auch aus Anbietersicht.

Beispiele



14.11.2019

© Prof. Dr. Michaela Völler
Forschungsstelle Versicherungsmarkt
Institut für Versicherungswesen

ivwKöln
Institut für
Versicherungswesen

Technology
Arts Sciences
TH Köln

Abbildung 18: Beispiele von Startups zur Unterstützung des Marktprozesses

Nect bietet ein KI-basiertes Videoselfie-Ident-Verfahren an, das nach eigenen Angaben „das Onboarding von Nutzern in digitale Geschäftsbereiche durch eine einfache und dabei sichere Identitätsfeststellung“¹⁴ ermöglicht. Unter anderem wird hierbei das KI-Element Facerecognition

¹⁴ <https://nect.com/> (Zugriff am 3. Dezember 2019)

eingesetzt. Für den Nutzer stellt das Identverfahren eine bequeme Lösung dar, die den herkömmlichen Verfahren in Verfügbarkeit und Schnelligkeit überlegen ist. Perspektivisch könnten Unternehmen ihren Kunden mit dem Nect-Identifizierungsverfahren über Gesichtserkennung zudem einen rechtssicheren und nutzerfreundlichen Login ermöglichen, der Passwörter für geschützte Bereiche verzichtbar macht.

Luminovo AI¹⁵ entwickelt „maßgeschneiderte KI-Lösungen und Tools für Geschäftskunden“¹⁶. Luminovo AI unterstützt beispielsweise medizinisches Underwriting unter Einsatz von KI-Funktionalitäten wie Document Classification, Document Mining und Data Extraction (sowohl zu Risiken als auch zu Verbesserungen des Gesundheitszustandes). Nach Freigabe durch den Kunden können Gesundheitsfragen im Formular automatisch befüllt werden, um anschließend eine Risikobewertung und ein Policenmatching durchzuführen. Für den Kunden besteht der Vorteil einerseits in einer Reduktion seines Aufwandes und der Erhöhung der Bequemlichkeit, da er die Gesundheitsfragen nicht mehr selbst ausfüllen muss, und einer Verminderung seines Risikos, relevante Informationen nicht anzugeben. Andererseits können Kunden, die bislang als nicht versicherbar eingestuft wurden, durch eine breitere zur Verfügung gestellte Datenbasis ein angepasstes Produkt oder sogar Zugang zum Standard-Versicherungsschutz erhalten. Nicht nur die Underwriting-Entscheidungen, sondern auch die Produktentwicklung werden somit auf Seiten des Unternehmens bereichert.

Docudiet bietet einen „KI-basierten Assistenten, der Underwritern von Industrieversicherern hilft, Prämien durch Visualisierung des vorhandenen Marktwissens besser zu bewerten“¹⁷. Da es sich hier um individuelle Deckungen, also nicht standardisiertes Geschäft handelt, bewegt sich Docudiet im Bereich der assistierten Entscheidungen.¹⁸

e-bot7 „steigert die Effizienz im Kundenservice“¹⁹ durch assistierte Kundenservicedialoge. Die Lösung basiert auf komplexen NLP-Algorithmen, die zunächst mit historischen Kundendialogen angelehrt werden. Im laufenden Betrieb analysiert die Maschine eingehende Nachrichten, leitet sie an die richtige Abteilung weiter und macht dem Service-Mitarbeiter auf Basis der Trainingsdaten einen intelligenten Antwortvorschlag. Der Mitarbeiter kann im Sinne des assistierten Entscheidens zwischen den Optionen „Accept“, „Adapt“ oder „Next“ wählen und gibt der Maschine damit zugleich Feedback zu ihrem Antwortvorschlag. So wird das System im laufenden Betrieb weiter optimiert und falsche Antworten an den Kunden vermieden. Insbesondere für sich häufig wiederholende Fragen kann die Antwort ab einem gewählten Konfidenzniveau automatisiert gegeben werden, so dass die Servicemitarbeiter entlastet werden.

¹⁵ <https://insurlab-germany.com/en/luminovo-tailoring-deep-learning-solutions-to-the-insurance-sector/> (Zugriff am 3. Dezember 2019)

¹⁶ <https://insurlab-germany.com/de/16-start-ups-werden-teil-des-insurlab-germany-accelerator-programm-2019/> (Zugriff am 3. Dezember 2019)

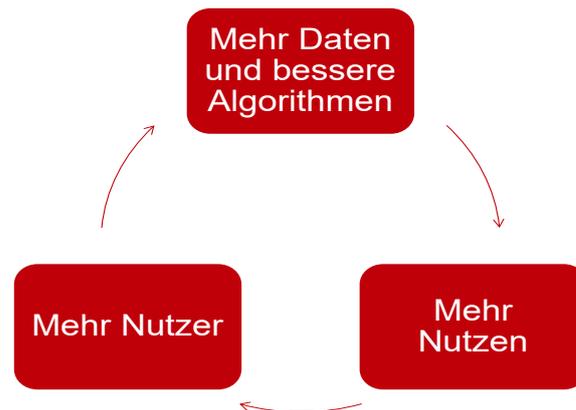
¹⁷ „Docudiet develops an AI-based wizard that helps underwriters of industrial insurers to better evaluate premiums by visualizing existing market knowledge.“ <https://insurlab-germany.com/en/accelerator-2/> (Zugriff am 3. Dezember 2019)

¹⁸ Weitere Details finden sich im Beitrag „Selbstlernende KI zur Unterstützung des Underwritings in der Industrieversicherung“ von Christoph Carl Kling in diesen Proceedings.

¹⁹ <https://e-bot7.de/ueber-uns/> (Zugriff am 3. Dezember 2019)

Gelingt es einem Unternehmen, Big Data und KI für eine konkrete Problemstellung zur Verbesserung der Marktbearbeitung in einem wahrnehmbaren Bereich einzusetzen, so entsteht ein selbstverstärkender Kreislauf. Mehr Daten und bessere Algorithmen erhöhen den Nutzen aus Sicht des Kunden (und damit letztlich auch des Unternehmens) im Sinne von besseren Services, Produkten, Prozessen oder Kosten. Mehr Nutzen auf Kundenseite führt zu mehr Nachfrage und damit mehr Nutzern, die wiederum mehr Daten erzeugen. Dies treibt den Kreislauf von vorne an.

Ein selbstverstärkender Kreislauf entsteht: Mehr Daten und gute Algorithmen erzeugen mehr Nutzer, mehr Nutzer mehr Daten.



14.11.2019

© Prof. Dr. Michael Völler
Forschungsstelle Versicherungsmarkt
Institut für Versicherungswesen

ivwKöln
Institut für
Versicherungswesen

Technology
Arts Sciences
TH Köln

Abbildung 19: Selbstverstärkender Kreislauf

Dies setzt jedoch voraus, dass KI tatsächlich eingesetzt wird, um einen besonderen und spürbaren Mehrwert zu generieren, und nicht nur als „Marketing-Label“ genutzt wird. Viele Unternehmen am Markt werben aktuell damit, KI-basierte Lösungen einzusetzen. Bei genauerer Betrachtung nutzen viele allerdings gar keine KI-Methoden im engeren Sinne, sondern allenfalls starre regelbasierte Ansätze in unbedeutenden Einsatzbereichen. Damit sind Lerneffekte nur begrenzt möglich und Mehrwerte entsprechend beschränkt. Der Ergebnisbeitrag der als KI beworbenen Lösungen ist letztlich irrelevant.

Ein Vergleich mit dem Tierreich liegt da nahe: In Australien und Neuguinea lebt die Kragenechse, die ihre Halskrause schirmartig aufstellen kann. Der Kragen lässt die Echse größer erscheinen als sie ist, dahinter bleibt sie dennoch klein und unterlegen. Eine „Alibi-KI“, die nur als Marketing-Label genutzt wird, hat eine ähnliche Wirkung wie der Kragen.

Eine Mistkäferart hingegen, der *Ontophagus taurus*, ist auf den ersten Blick unscheinbar, kann aber gewaltige Kräfte entwickeln. Es kann das 1141-Fache seines Eigengewichts ziehen (Knell & Simmons 2010)²⁰. Wünschenswert wäre es daher, wenn wir unter den „KI-Tierchen“ am Markt mehr Mistkäfer als Kragenechsen finden könnten.

²⁰ <https://www.sciencedaily.com/releases/2010/03/100323212158.htm> (Zugriff am 17. September 2019)

Literatur

Amershi, Saleema; Cakmak, Maya; Knox, William Bradley; Kulesza, Todd (2014): Power to the People: The Role of Humans in Interactive Machine Learning. *AI Magazine*, Vol. 35 No. 4, S. 105-120. [DOI: 10.1609/aimag.v35i4.2513]

Bitkom (2012): Big Data im Praxiseinsatz – Szenarien, Beispiele, Effekte (Leitfaden).
Abgerufen am 2. Oktober 2019 von
<https://www.bitkom.org/sites/default/files/pdf/noindex/Publicationen/2012/Leitfaden/Leitfaden-Big-Data-im-Praxiseinsatz-Szenarien-Beispiele-Effekte/BITKOM-LF-big-data-2012-online1.pdf>

Bitkom (2017): Künstliche Intelligenz verstehen als Automation des Entscheidens (Leitfaden).
Abgerufen am 6. Oktober 2019 von
<https://www.bitkom.org/sites/default/files/file/import/Bitkom-Leitfaden-KI-verstehen-als-Automation-des-Entscheidens-2-Mai-2017.pdf>

Dumbill, Edd (2012): What is Big Data? In: Dumbill (Hrsg.): *Planning for Big Data – A CIO’s Handbook to the Changing Data Landscape*. O’Reilly, Sebastopol, pp. 9-16.

Dumbill, Edd (2013): *Making Sense of Big Data*. Big Data Vol. 1, No. 1, pp 1-2, Mary Ann Liebert, Inc., publishers, New Rochelle, New York. [DOI: 10.1089/big.2012.1503]

Hammond, Kristian (2016): *The Periodic Table of AI*.
Abgerufen am 26. August 2018 von
http://ai.xprize.org/sites/default/files/xprize_artificial_intelligence_periodic_table.pdf

Knell, Robert J.; Simmons, Leigh W. (2010): Mating tactics determine patterns of condition dependence in a dimorphic horned beetle, *Proceedings of the Royal Society B* (2010), Vol. 277, Issue 1692, S. 2347-2353 [DOI: 10.1098/rspb.2010.0257]

Purdy, Mark; Daugherty, Paul (2016): *Why Artificial Intelligence is the Future of Growth*.
Abgerufen am 20. Juni 2019 von
https://www.accenture.com/t20170524t055435__w_/ca-en/_acnmedia/pdf-52/accenture-why-ai-is-the-future-of-growth.pdf

Schroeck, Michael; Shockley, Rebecca; Smart, Janet; Romero-Morales, Dolores; Tufano, Peter (2012): *Analytics: The real-world use of big data: How innovative enterprises extract value from uncertain data*.
Abgerufen am 6. Oktober 2019 von
<https://www.ibm.com/downloads/cas/E4BWZ1PY>

Weber, Mathias; Burchardt, Aljoscha (Bitkom/DFKI) (2017): *Künstliche Intelligenz – Wirtschaftliche Bedeutung, gesellschaftliche Herausforderung, menschliche Verantwortung*.
Abgerufen am 6. November 2019 von
https://www.dfki.de/fileadmin/user_upload/import/9744_171012-KI-Gipfelpapier-online.pdf

5. Raus aus dem Labor, rein in die Geschäftsprozesse – Praxisbeispiele und Anforderungen für Künstliche Intelligenz in der Versicherung

Dr. Andreas Becks

Ganz klar: Durch Digitalisierung und die Möglichkeiten der KI ändert sich die Versicherungswelt gerade grundlegend. Die Rolle von Versicherungen wird sich weiterentwickeln von „verstehen und schützen“ zu „vorhersagen und verhindern“, wie es etwa die Geneva Association, ein führender internationaler Think Tank der Versicherungsbranche, in ihrem aktuellen Forschungsbericht „Insurance in the Digital Age²¹“ formuliert. Dabei entstehen nicht nur neue Geschäftsfelder, wie etwa die Versicherung von Cyberrisiken. Das lange propagierte Ideal der Kundenzentrierung bekommt neuen Auftrieb. Kunden erwarten eine durchgängige und konsistente Betreuung entlang des gesamten Versicherungslebenszyklus – und zwar nicht nur hinsichtlich der Kommunikation, sondern auch bei der Schadensmeldung und -abwicklung. Produkte werden viel individueller und werden sich stärker am tatsächlichen Verhalten der Versicherten orientieren („Pay as you ...“). Entsprechend individuell wollen Kunden und Interessenten auch in ihrer Customer Journey und der Betreuung angesprochen werden: Der hybride Kunde entscheidet je nach „Laune“, über welchen analogen oder digitalen Kanal er mit seiner Versicherung Kontakt aufnehmen oder Schadensfälle abwickeln möchte.

Potenziale für die gesamte Wertschöpfungskette

Konsistente Ansprache über Kanäle hinweg und die Verbindung der heute noch oft anzutreffenden Online- und Offline-Welten ist schon für sich genommen ein guter Business Case. Durch konsistente Produktempfehlungen lässt sich der Jahresbeitrag gegenüber einer „klassisch“ betreuten Standardgruppe in der Praxis signifikant steigern. Das ist allerdings erst der Beginn eines optimierten Kundendialogs: Handlungsempfehlungen (z.B. welche Information benötigt der Kunde wann und über welchen Kanal) und die richtige Frage an Interessenten oder Kunden zur richtigen Zeit erhöhen Konversionsraten, Kundenbindung und -zufriedenheit.

Auch im modernen Schadensbearbeitungsprozess lässt sich der Kunde mit Hilfe vieler automatisierter Teilprozesse konsequent in den Mittelpunkt stellen. Verkürzte Durchlaufzeiten und bessere Customer Experience führen dabei zu höherer Kundenzufriedenheit und erheblichen Kosteneinsparungen (siehe Abschnitt „Innovation in der Schadenbearbeitung“).

Und nicht zuletzt die zahlreichen internen Prozesse einer Versicherung ändern sich durch die Digitalisierung, und es entstehen beachtliche Möglichkeiten, Kosten einzusparen und kundenfreundlicher zu werden. Aktuarate nutzen maschinelles Lernen und automatisierte Entscheidungen, um ein genaueres und dynamisches Pricing umzusetzen. Durch eine agile Methodik und maschinelles Lernen können Tarifmodelle schneller und präziser entwickelt sowie Ratemaking-Prozesse verbessert werden. Automatisierte Operationalisierungsstrecken helfen, Tarife schneller in Produktion (also in den Markt) zu bringen und Echtzeit-Preisoptimierungen durchzuführen.

Potenziale für einen wertsteigernden Einsatz von KI gibt es also entlang der gesamten Wertschöpfungskette. Abbildung 20 gibt hierzu nochmal einen Überblick. Dieser Beitrag beleuchtet, was es dazu braucht, die Vision einer umfassenden

²¹https://www.genevaassociation.org/sites/default/files/research-topics-document-type/pdf_public/insurance_in_the_digital_age_01.pdf

Digitalisierung und einer konsistenten und fairen Kundenerfahrung umzusetzen. Schauen wir uns dazu ein Anwendungsbeispiel genauer an.

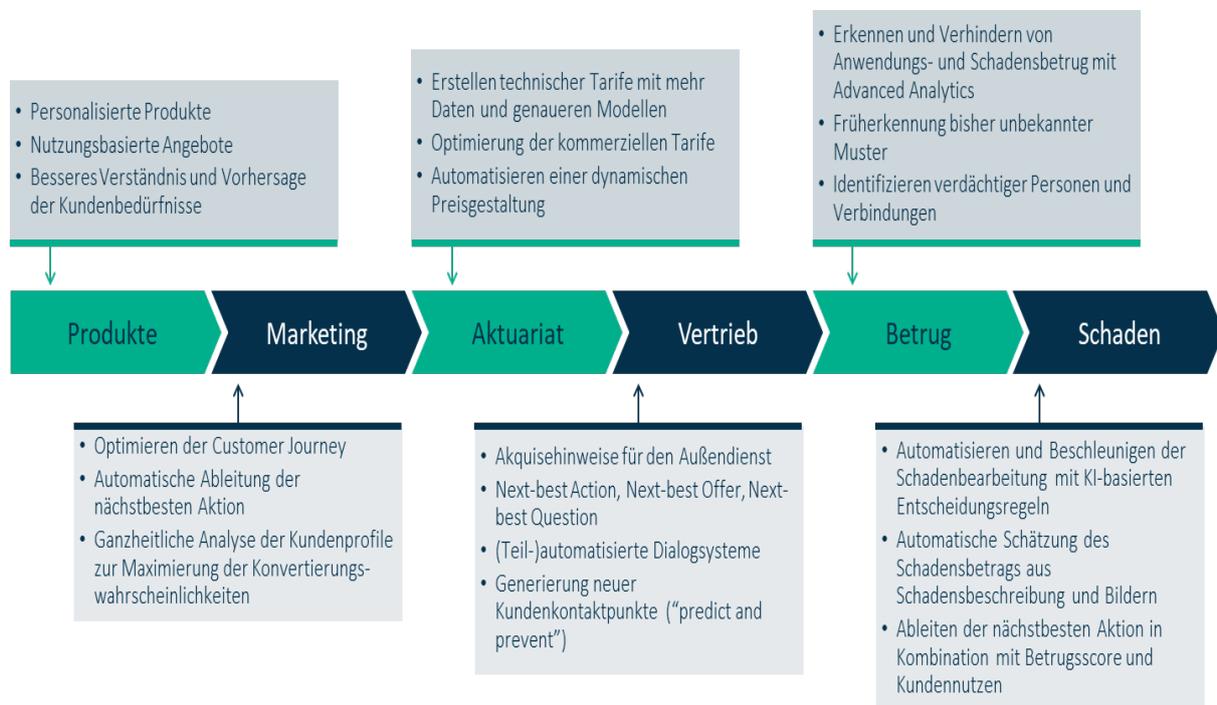


Abbildung 20: KI bei Versicherungen - Potenziale für die gesamte Wertschöpfungskette

Innovation in der Schadenbearbeitung

In der Schadenbearbeitung konvergieren verschiedene und heute häufig leider getrennt betrachtete „Entscheidungsbereiche“. Ein führender europäischer Versicherer, der seinen Schadensbearbeitungsprozess innoviert hat, hat auch hier den Kunden konsequent in den Mittelpunkt gestellt. Wie sieht der Prozess nun aus? Was sieht der Kunde und was passiert hinter den Kulissen?

Im Falle eines Unfalls nutzt der Kunde die Versicherungs-App, um den Schaden online zu melden. Zunächst werden wichtige Eckpunkte abgefragt, etwa ob es Verletzte gibt oder um welches versicherte Fahrzeug es sich handelt. Dann formuliert der Kunde eine Schadenbeschreibung und reicht eventuell noch ein Foto des Schadens ein. Am Ende der Schadenmeldung wird der passende Service angeboten: Falls das Fahrzeug noch fahrtauglich ist werden zum Beispiel die nächstgelegenen Vertragswerkstätten angezeigt oder im anderen Fall ein Abschleppdienst beauftragt und ein Taxi gerufen.

Im Hintergrund läuft eine Vielzahl von Entscheidungen ab: Mit der Schadenbeschreibung, den Vertragsinformationen und der Kenntnis zahlreicher historischer Fälle findet zunächst eine Abschätzung der Betrugswahrscheinlichkeit statt. Gleichzeitig wird ein Kostenmodell berechnet, das den vermuteten Schaden beziffert und zum Beispiel die Art der Beschädigung, das Alter des Fahrzeugs, Marke und Modell sowie Hinweise auf Fahrgestellschäden berücksichtigt. Von besonderem Interesse ist auch, ob es sich wahrscheinlich um einen Totalverlust handelt. Alle diese Teilaspekte führen schließlich zu der Entscheidung, wie mit diesem Schaden umzugehen ist. Der Service für den Kunden hängt in der Ausprägung auch vom strategischen Kundenwert ab und eventuelle freiwillige Zusatzleistungen können das Kundenerlebnis positiv beeinflussen („Claims is where the promise becomes true“).

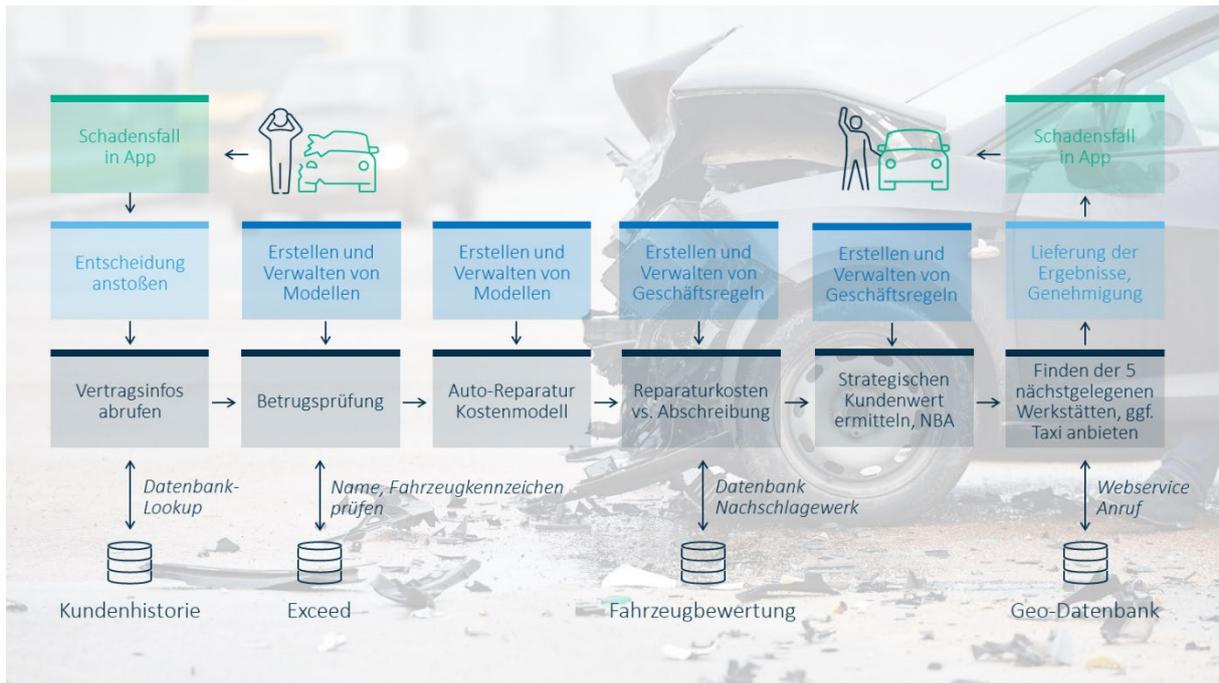


Abbildung 21: Echtzeit-Schadenbearbeitung (vereinfachter Geschäftsprozess)

Erfolgsfaktoren

Was braucht es, um derartige Anwendungen von KI in der Versicherung erfolgreich zu operationalisieren? Natürlich braucht es Daten und ausgefeilte Datenanalysemethoden – und dies allein ist Gegenstand vieler umfassender Fachbeiträge über Anwendungsbeispiele und Methodik. In diesem Aufsatz soll das Augenmerk allerdings auf einige Herausforderungen und Lösungsansätze gelegt werden, die über eine Betrachtung des Analyseprozesses hinausgehen und mindestens ebenso erfolgskritisch sind wie Exzellenz in der Data Science-Abteilung. Abbildung 22 fasst die wesentlichen Erfolgsfaktoren zusammen, die im Rest dieses Beitrags näher diskutiert werden.

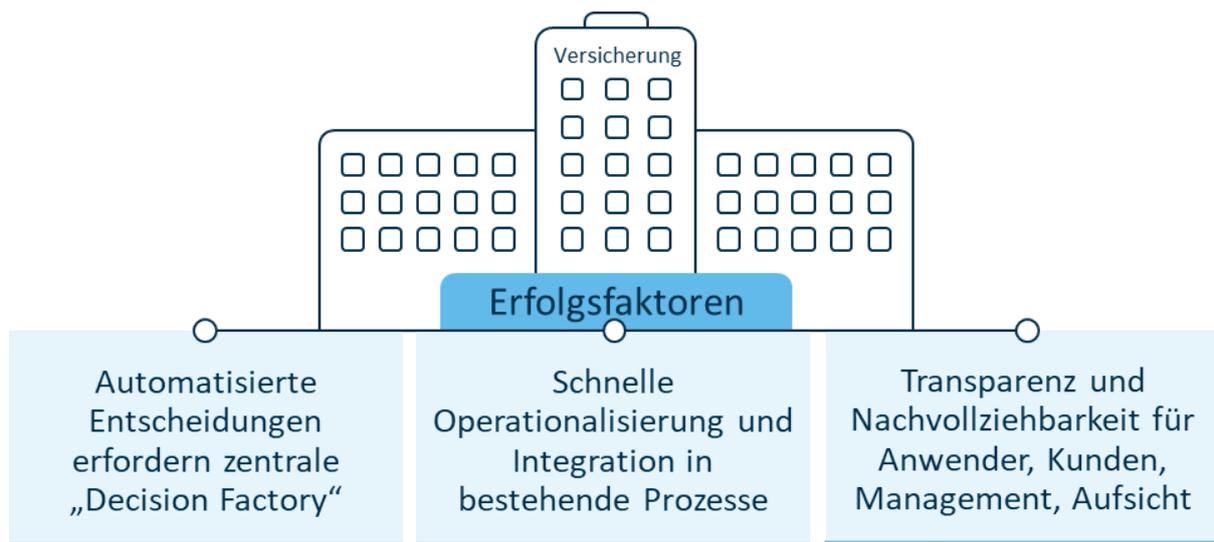


Abbildung 22: Was braucht es, um KI in der Versicherung erfolgreich zu operationalisieren?

Automatisierte Entscheidungen erfordern eine zentrale „Decision Factory“

Wie das Beispiel der Schadenbearbeitung zeigt, hängen die Entscheidungsbereiche immer zusammen: Erwartete Schadenhöhe, die notwendige Reservierung, Betrugsprävention und Kundenwert führen zu einer in diesem Gesamtkontext bestmöglichen Aktion.

Formal bestehen solche Entscheidungsstrukturen zum einen aus analytischen Modellen, also letztlich Algorithmen, die einen Score für den Kundenwert, eine Betrugswahrscheinlichkeit oder eben die wahrscheinliche Schadenhöhe prognostizieren. Zum anderen sagen Geschäftsregeln, was jeweils aus den einzelnen Scores und Wahrscheinlichkeiten folgt. Wenn z.B. der Schaden eher gering und die Betrugswahrscheinlichkeit niedrig ist, dann wollen wir Kunden mit hohem strategischem Wert besonders kulant behandeln und eine entsprechende Aktion triggern. Dieses Regelwerk ist silo-übergreifend: Schaden-, Marketing- und Betrugsaspekte spielen gleichermaßen eine Rolle und Abteilungsdenken sowie nicht orchestrierte Lösungsansätze pro Bereich stehen einem Erfolg im Wege. Vielmehr geht es darum, die Entscheidungslogiken ganzheitlich zu konzipieren und so umzusetzen, dass sie als Bestandteil vieler möglicher Anwendungen zur Verfügung gestellt und zentral gepflegt werden können. Denn wenn sich zum Beispiel die Betrugserkennungsalgorithmen verbessern, sollen alle Anwendungen, die darauf zugreifen, gleichermaßen profitieren und nicht jeweils händisch und individuell mit viel Aufwand angepasst werden müssen. Wer derartige Entscheidungslogiken konsistent und in hoher Qualität in seinen Systemen einsetzen will, sollte daher ein übergreifendes Repository an Modellen und Regelwerken bereitstellen, quasi eine zentrale „Entscheidungsfabrik“.

Wer arbeitet eigentlich in der zentralen Entscheidungsfabrik? Klar, die Algorithmen und Geschäftsregeln, aber wer baut und pflegt sie und wie werden solche Entscheidungsregeln überhaupt entwickelt? Abbildung 23 zeigt den dazu erforderlichen Kreislauf, den sogenannten „analytischen Lebenszyklus“. Ausgehend von der Geschäftsfrage (zum Beispiel: „Wie schätze ich die Schadenhöhe aufgrund einer Schadenbeschreibung ein?“) werden die erforderlichen Daten aus den Quellsystemen und der App definiert und geeignet aufbereitet. Schon das ist ein sehr kreativer Prozess, an dem neben den legendären Data Scientists und, je nach Anwendung, den Aktuaren auch relevante Fachbereichsmitarbeiter mitwirken, die Daten interpretieren und in den richtigen Kontext stellen können. Die Daten werden auf ihre Aussagekraft und Zusammenhänge untersucht (optimalerweise in engem Austausch mit denjenigen Fachbereichen, die sich mit der Materie gut auskennen), und schließlich werden mit angemessenen Verfahren der prädiktiven Analytik und des maschinellen Lernens Muster erkannt, die zur Vorhersage des sogenannten Targets, etwa der wahrscheinlichen Schadenhöhe, taugen. Am Ende dieses sehr kreativen und experimentellen Prozesses steht ein mathematisch zu bewertendes Modell, das möglichst gut auf neuen Daten zum Beispiel die am besten passende Schadenklasse vorhersagt.

Dieses Modell muss nun in einen Geschäftsprozess integriert werden. Das hat eine fachliche, eine statistische und eine technische Seite. Die fachliche Frage ist, in welcher Geschäftsregel dieses Modell zu Anwendung kommen soll. Die technische ist, wie die Regel (inklusive der Datenauswertung) denn im Zielsystem aufgerufen und zur Anwendung gelangen (das sogenannte Deployment). Diese beiden Aspekte werden unter dem Begriff „Operationalisierung“ zusammengefasst. Die statistische Perspektive ist, ob das Modell in der Praxis auch gute Vorhersagen macht. Vielleicht hat sich ja die Verteilung der Daten so geändert, dass ursprüngliche Annahmen nicht mehr stimmen und die Vorhersagekraft des Modells zu schlecht wird. Die Anwendung der Modelle und Regeln muss also kontinuierlich überwacht werden. Hier ist eine Model Governance erforderlich, die auch die Auditierbarkeit sicherstellt (wie wir im Abschnitt „Transparenz und Nachvollziehbarkeit“ näher besprechen). Die möglichst automatische Prüfung der statistischen Modelle auf ihre Vorhersagekraft sollte einen Alarm auslösen, falls ein analytisches Modell ausgetauscht oder nachtrainiert werden

muss (oder das Training sogar automatisch auslösen). Auf diese Weise bleiben die Modelle und Regeln der Entscheidungsfabrik möglichst lange wertvoll.

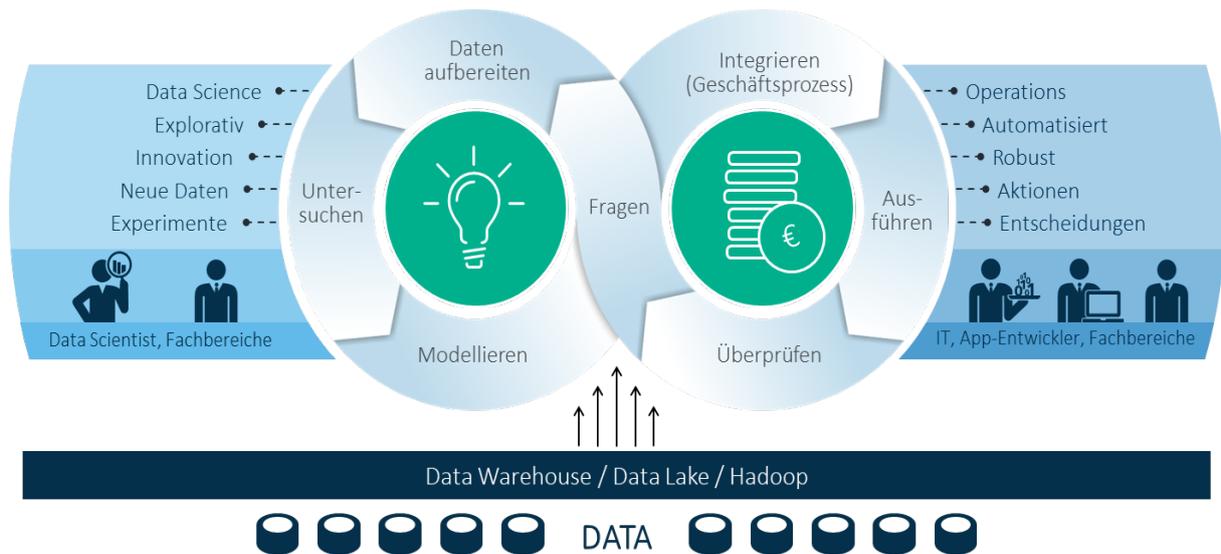


Abbildung 23: Der analytische Lebenszyklus: entwickeln, anwenden, überprüfen

Schnelle Operationalisierung und Integration in bestehende Prozesse.

Geschwindigkeit bei der Operationalisierung ist ein klarer Erfolgsfaktor. Neben dem strategischen Aspekt, dass eine Versicherung natürlich innovative Prozesse schnell in den Markt bzw. zur Anwendung bringen will, um Kosteneinsparungen zu realisieren oder Wettbewerbsvorteile zu materialisieren, gilt: Datengetriebene Entscheidungen sind wie Fisch - man verzehrt sie am besten frisch. Denn mit der Zeit ändern sich Daten und schon aus rein statistischen Gründen werden damit die Vorhersagen schlechter. Die Modelle verlieren also an Wert.

Der Sprung vom fertigen Modell in die Anwendung innerhalb einer (komplexen) Geschäftsregel stellt allerdings immer noch viele Unternehmen vor große Herausforderungen. Operationalisierung kostet dann zu viel Zeit (Achtung: ungekühlter Fisch!) und Ressourcen. Die Gründe sind hier organisatorischer und technischer Natur und liegen in der Komplexität der Aufgabe.

Komplexität entsteht, da hinter den vielen Entscheidungen, wie im Beispiel oben, viele analytische Modelle stehen. Und weil selbst bei einer einzelnen Entscheidung (z.B. Schadenhöhe) eine möglichst genaue Vorhersage angestrebt wird, werden hier in der Praxis schon alleine für eine einzelne Abschätzung mehrere und gegebenenfalls auf unterschiedlichen mathematischen Verfahren beruhende Modelle verwendet, z.B. ein individuelles Schadenmodell pro Fahrzeugtyp, davon je eines für die textbasierte Schadenbeschreibung, mehrere verschachtelte für das Foto. Skalierbarkeit des Deployments, also das zur Verfügung stellen der fertigen Modelle, ist also wesentlich – und dies erreicht man am besten durch Automatisierung.

Technisch müssen diese Modelle und Regeln von verschiedenartigen Anwendungen und in unterschiedlichen Zielsystemen lauffähig sein. Die Schadenbearbeitung wird vielleicht von einer App, der Webseite und dem Call-Center-System angestoßen, ein Kundenwert-Scoring findet vielleicht regelmäßig in der Kundendatenbank statt und die Telematikanwendung muss mit einem Datenstrom umgehen können. Über diese technischen Rahmenparameter sollten sich die Entwickler der Regeln möglichst wenig Gedanken machen müssen. Standardisierung und saubere Schnittstellen in einem analytischen Ökosystem sind hier ein Muss.

Und wie vermeidet man Ineffizienzen im Arbeitsprozess? Zur Agilität tragen eine klare Arbeitsteilung und agile Entwicklungsmethoden bei. Die zugrundeliegende Philosophie, Modelle und Geschäftsregeln schnell in Produktion zu bringen, ist auch unter dem Begriff DataOps bekannt. Unter der Prämisse, dass Daten zentral für disruptive Unternehmensanwendungen und Data Science und Maschinelles Lernen dazu ein wichtiges Paradigma sind, ist die Idee von DataOps, Produktivität durch einen agilen self-service Workflow zu erhöhen, bei dem sich jeder Beteiligte an seinen Kernkompetenzen orientiert. Optimalerweise sieht es dann so aus:

- Die IT sorgt dafür, dass das gesamte System und die Architektur skalierbar und effizient betreibbar sind. Dabei spielen Wiederholbarkeit der Prozesse, Automatisierung und Zuverlässigkeit des gesamten Ökosystems eine zentrale Rolle. Insbesondere sorgt die IT dafür, dass in allen Zielsystemen die entwickelten Modelle und Regeln durch eingebettete Prozesse oder Schnittstellen und mit einer zentral gemanagten Laufzeitumgebung ausgeführt werden können.
- Der Data Scientist entwickelt (unter Hilfe der zuständigen Fachbereiche) die prädiktiven Modelle und entscheidet, wann sie fit genug für den Praxiseinsatz sind. Dabei nutzt er nur die für den Anwendungszweck freigegebenen Daten, definiert durch die Zuständigen für Datenschutz. Einmal entwickelte Modelle können dann in die zentral gemanagte „Ausführungslandschaft“ geschoben werden, ohne sie technisch neu übersetzen zu müssen. Der Data Scientist konzentriert sich also nur auf die Modellentwicklung und kann das Resultat dann gleichermaßen für einen Scoring-Lauf in einer Datenbank, einer Datenstrom oder für den Aufruf durch eine externe Anwendung oder Webseite bereitstellen. Der praktische Einsatz der Modelle wird automatisiert überwacht und schlechter werdende Vorhersagemodelle automatisch nachtrainiert.
- Die Fachbereiche definieren, testen und verwalten selbständig Geschäftsregeln – denn sie wissen am besten, wie taktisch im Geschäftsprozess mit den Vorhersagen des Data Scientist (bzw. seines Modells) umgegangen werden soll. Sie bedienen sich dabei aus dem Katalog möglicher Vorhersagemodelle, die zentral verwaltet und qualitätsgesichert werden. Wenn die Regeln fit für den Einsatz sind, gibt der Verantwortliche aus dem Fachbereich diese zur Anwendung im Zielsystem frei.

Ein solches integriertes Ökosystem bietet also einfachen Zugriff auf analytische Modelle, Geschäftsregelwerke und Betriebsdaten für das Design, Testen und Bereitstellen von Entscheidungsflüssen. Die gemeinsame Umgebung für Data Scientists, IT und Business stellt gleichzeitig die Dokumentation der Entscheidungen sicher und prüft die Rückverfolgbarkeit und Kontinuität in einer gemeinsamen Umgebung. Gelingt die schnelle Entwicklung oder Anpassungen von Modellen und Geschäftsregeln und können diese auch zügig technisch zur Verfügung gestellt werden, heißt das nichts anderes als dass die gewonnenen Erkenntnisse schnell in Handlungen umgesetzt und damit Erträge erwirtschaftet werden können.

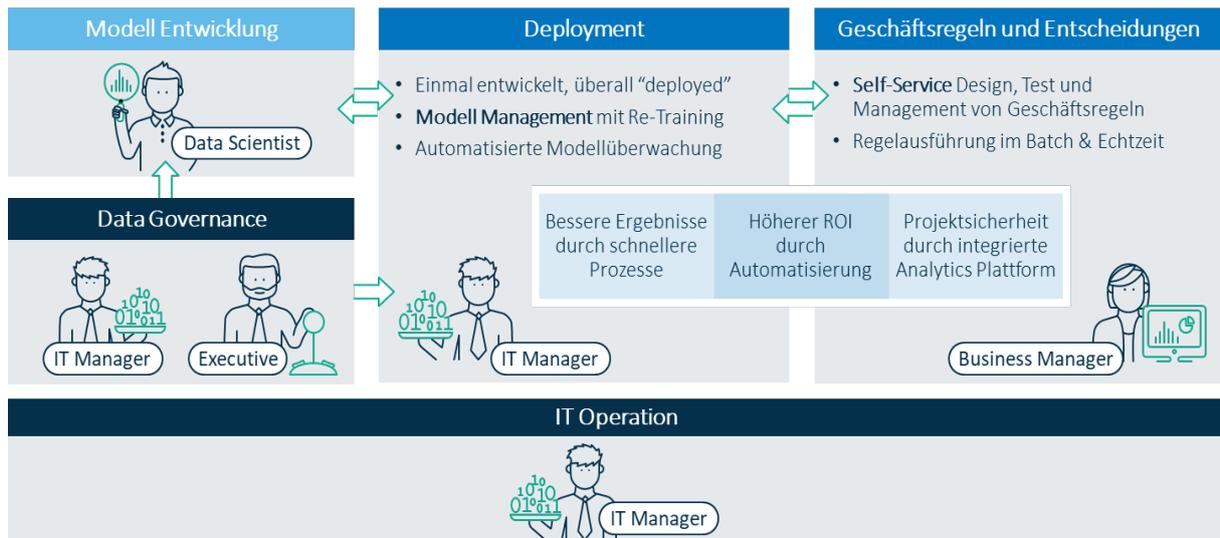


Abbildung 24: Data Ops: Jeder macht das, was er am besten kann

Transparenz und Nachvollziehbarkeit

Automatisierung von Entscheidungen bedeutet, dass gewissermaßen einem technischen Prozess eine Aufgabe übertragen wird, die bislang von ausgebildeten menschlichen Sachbearbeitern verantwortet wurde, die sich aber auch niemals der vollen menschlichen Kontrolle entziehen darf. Dies führt unmittelbar zu einem der derzeit wichtigsten Themen, die im Zusammenhang mit KI besprochen werden: Transparenz und Vertrauen in KI-basierte Entscheidungen. Vertrauen ist die notwendige Voraussetzung dafür, dass Anwendungen von KI erfolgreich sein können – Vertrauen in Daten, Modelle, unvoreingenommene Algorithmen, automatische Entscheidungsfindung. Dies ist sicher ganz allgemein eine ethische Frage. Es geht allerdings nicht nur auf übergeordneter Ebene um gesellschaftliche Akzeptanz. Aus einer im engeren Sinne betrieblichen Perspektive ist das Ziel sicherzustellen, dass Investitionen in KI den erwarteten Wert liefern, sich die Mitarbeiter auf KI-Anwendungen und vorgeschlagene Entscheidungen verlassen können, das Vertrauen der Kunden zu gewinnen und den Schutz der eigenen Marke sicherzustellen.

Welcher Versicherer möchte schon durch fragwürdige Entscheidungen (die KI-Systeme automatisiert mit extrem hoher Frequenz treffen können) und der Unfähigkeit, diese zu erklären, in die Schlagzeilen geraten. Denken Sie nur an das Beispiel von Apple Card: Das Unternehmen gewährte einem Kunden ein 20-fach höheres Kreditlimit als seiner Frau, obwohl das Paar steuerlich gemeinsam veranlagt und lange verheiratet ist und sein gesamtes Vermögen teilt. Apple Card geriet in Verdacht, Frauen zu diskriminieren und konnte die algorithmische Entscheidung nicht zeitnah erklären.²² Auch bei der Frage, ob ein Versicherer ein Risiko übernimmt, warum der Schaden auf die vorgeschlagene Weise reguliert werden soll oder welche Schlüsse aus Telematik-Daten einer KFZ-Police gezogen werden, stehen Transparenz und Nachvollziehbarkeit oben auf der Prioritätenliste.

Abbildung 25 stellt drei wichtige Interessensgruppen für Transparenz und Nachvollziehbarkeit vor: Der Datenwissenschaftler möchte die Funktionsweise seiner Vorhersagemodelle verstehen, damit er Ergebnisse erklären und Verfahren verbessern kann. Der Versicherte möchte bestimmte Entscheidungen nachvollziehen und wissen, ob er fair behandelt wird. Regulatoren und Gesetzgeber

²² <https://observer.com/2019/11/apple-card-application-process-gender-discrimination/>

wollen die Menschen schützen und sicherstellen, dass die Entscheidungen, die von den Modellen getroffen werden, fair und transparent sind.

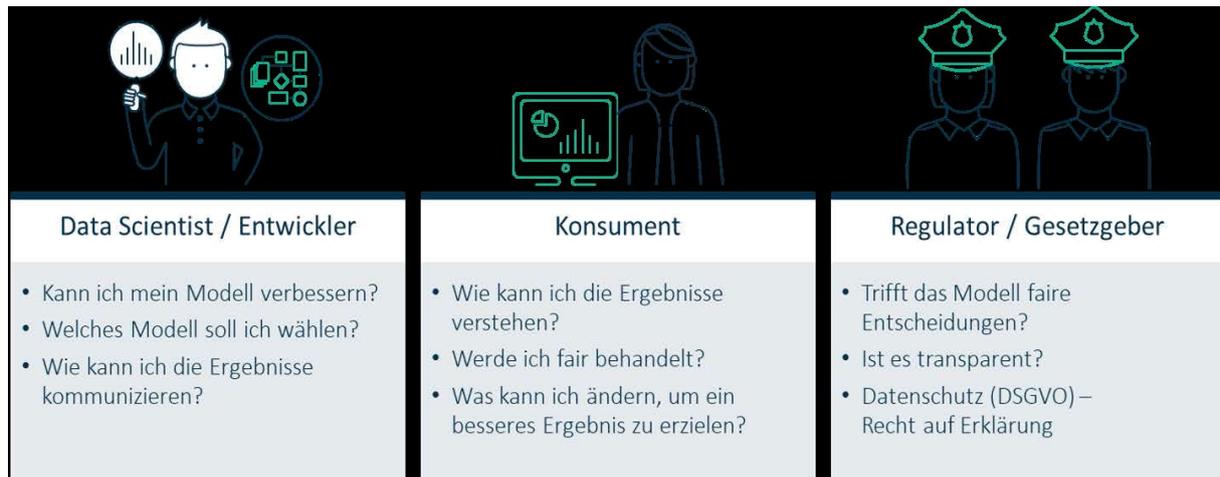


Abbildung 25: Maschinelles Lernen interpretierbar machen – Zielgruppen

Wie können wir uns aus Prozess- und Methodensicht der Frage der Nachvollziehbarkeit stellen? Wie bekommt ein Unternehmen die notwendige Transparenz hin? Was umfasst der Begriff „Governance“ in diesem Zusammenhang?

In seinem Bericht *The Automated Actuarial*²³ stellt Scott Shapiro von KPMG die „vier Säulen des Vertrauens“ dar. Seine Empfehlungen sind allgemeingültig und gelten durchaus nicht nur für Versicherungsmathematiker (auch wenn diese in besonderem Maße auf Transparenz und Nachvollziehbarkeit angewiesen sind). Die vier Säulen sind Qualität, Resilienz, Integrität und Effektivität. Und dazu sollten Unternehmen folgende Punkte beachten.

1. Zeigen Sie auf, welche Daten Sie in welcher **Qualität** verwendet haben. Alle Entscheidungen beruhen schließlich auf Daten. Und je weniger das eigene Unternehmen diese Daten unter Kontrolle hat, desto wichtiger ist eine klare Einschätzung, wo sie herkommen, wie sie entstanden und wie gut sie sind. Das ist insbesondere für die vielen „neuen“ Datenarten aus den Bereichen Telematik und IoT, aber auch für externe Daten aus offenen Quellen, für Bilder oder Texte wichtig.
2. Sie sollten sich die Frage stellen: Wie belastbar ist eigentlich mein analytischer Gesamtprozess (**Resilienz**)? Habe ich nur einen einmaligen Laborprozess? Oder ist meine Analyse auf Langfristigkeit ausgelegt? Hier gilt es, die Governance und Sicherheit entlang der gesamten analytischen Prozesskette – von den Daten bis zur automatisierten Entscheidung – sicherzustellen.
3. Stellen Sie die **Integrität** der Datenanalyse sicher. Dokumentieren Sie Prozesse und die Wahl Ihrer Methoden. Passen sie zur Fragestellung? Sind sie mathematisch angemessen? Können Sie das Vorgehen erklären und rechtfertigen?
4. Macht Analytics das, was sie soll (**Effektivität**)? Sind ihre Aussagen zuverlässig? Ist sie diskriminierungsfrei?

²³ <https://assets.kpmg/content/dam/kpmg/xx/pdf/2017/06/kpmg-the-automated-actuarial.pdf>

Der Gesamtkontext von Anwendungen, Daten, Prozessen und Methoden wird gerade in Politik (z.B. Datenethikkommission²⁴, EU High-Level Expert Group on AI²⁵), Forschung (z.B. FAT-ML Community²⁶) und einer breiten fachlichen Öffentlichkeit (z.B. Stuttgarter Zukunftssymposium²⁷) intensiv diskutiert. In den letzten fünf Jahren haben viele verschiedene Interessengruppen Prinzipien und Richtlinien für „ethische“ Künstliche Intelligenz herausgegeben²⁸, die vielfach einen sehr umfassenden (und nicht immer pragmatisch umzusetzenden) Ansatz verfolgen.

Auch für die Algorithmen des maschinellen Lernens an sich, denen ja häufig – gerne auch von erfahrenen Aktuaren – Undurchschaubarkeit attestiert wird, ist die Forschung dabei, diagnostische Instrumente für eine bessere Interpretierbarkeit zu entwickeln. Einige beispielhafte Fragestellungen und Verfahren zeigt Abbildung 26.

Mit einem auditierbaren analytischen Ökosystem, einer nachvollziehbaren Entscheidungsstrecke, sauberer Methodik und den richtigen Instrumenten zur Diagnose ungewollter Verzerrungen in den Entscheidungen können Einsatzhürden von KI in der Versicherung abgebaut werden.

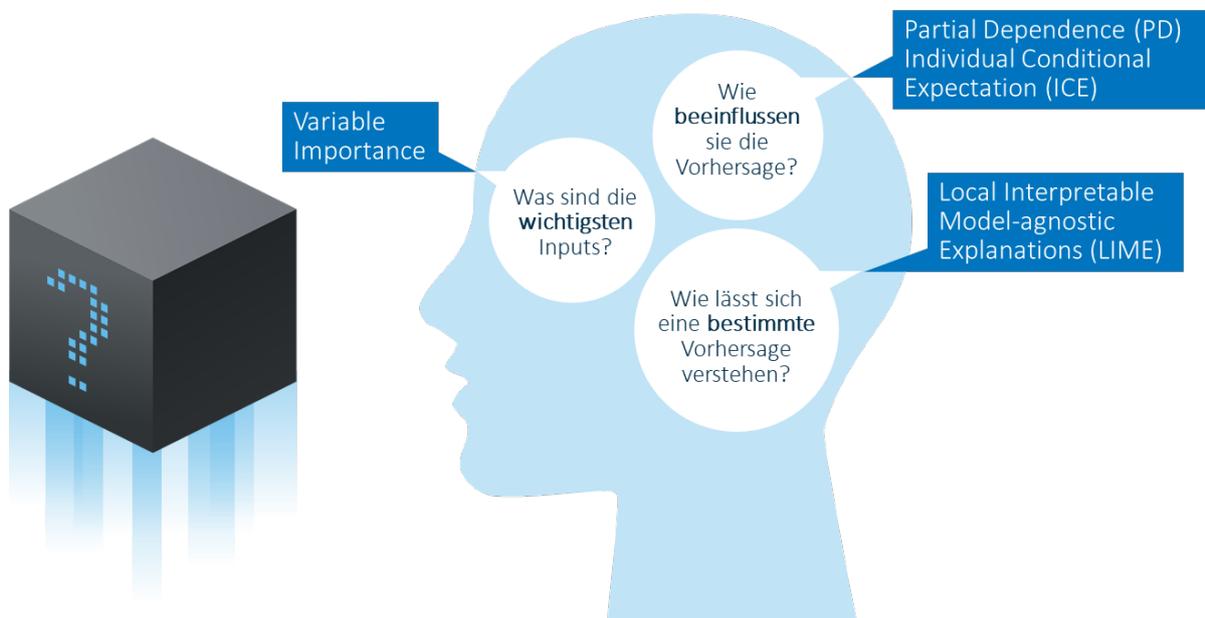


Abbildung 26: Erklärungsansätze für die Effektivität von Algorithmen

Fazit: Maschinelles Lernen in der Versicherung erfolgreich umsetzen

Maschinelles Lernen und Künstliche Intelligenz sind in der Praxis der Versicherungswirtschaft längst angekommen. Jetzt geht es darum zu skalieren und von einzelnen Leuchttürmen zu einer breiteren

²⁴ <https://www.bmi.bund.de/DE/themen/it-und-digitalpolitik/datenethikkommission/datenethikkommission-node.html>

²⁵ <https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai>

²⁶ <https://www.fatml.org/>

²⁷ <https://stuttgarter-zukunftssymposium.de/>

²⁸ Siehe z.B. The global landscape of AI ethics guidelines, Nature Machine Intelligence, Vol 1, September 2019, by Anna Jobin, Marcello Lenca and Effy Vayena

und erfolgreichen Nutzung von KI zu kommen. Dazu ist es notwendig, den Blick auch über Algorithmen hinaus zu werfen und sich Prozesse und Rahmenbedingungen anzuschauen, unter denen KI erfolgreich sein kann. Hierzu gehört zweifelsfrei die Tatsache, dass Silos einer intelligenten automatisierten Entscheidungsfindung im Wege stehen. Es gilt aber auch, nun schnell vom Labor in die Praxis zu kommen, denn ohne Operationalisierung verdient kein Unternehmen mit maschinellem Lernen Geld. Monetarisierung erfordert Erkennen und Handeln und Produktion und Automatisierung sind daher letzten Endes wichtiger, als im Labor das letzte Quäntchen Verbesserung aus den Algorithmen heraus zu kitzeln. Die wichtigsten Einsatzhürden sind heute nicht mehr Daten und Technik, sondern Vertrauen in das, was automatisiert entschieden wird, weil hier rechtliche und wirtschaftliche Risiken entstehen und die Reputation auf dem Spiel steht, wenn Entscheidungen schlecht und fragwürdig sind. Wer Transparenz, eine saubere Governance und Nachvollziehbarkeit entlang der gesamten Prozesskette sicherstellt baut auch diese Einsatzhürde ab.

6. Altes im neuen Gewand?! – KI und Data Analytics im Versicherungssektor

Dr. Thomas Zabel

In den letzten Jahren gewann das Thema Künstliche Intelligenz und Advanced Analytics immer mehr Gewicht in der geschäftlichen Praxis. Auch im menschlichen Alltag gibt es mehr und mehr Berührungspunkte mit Methoden und Techniken der künstlichen Intelligenz. Tägliche Gebrauchsgegenstände wie beispielsweise das Handy, welches bei vielen Menschen heute kaum noch aus dem Alltag und als Kommunikationsinstrument Nummer eins wegzudenken ist, verwenden Methoden der künstlichen Intelligenz, die heute als Standard von den Anwendern hingenommen werden. Das Forschungsfeld der künstlichen Intelligenz, welches noch vor zehn Jahren eher bei einer kleinen Personengruppe im Fokus stand, gilt mittlerweile als zentrale wirtschaftliche und gesellschaftliche Schlüsselkompetenz für die Zukunft von Arbeit, Gesundheit, Mobilität, Bildung, Produktion, Finanzen und vieles mehr.

Dieser Trend wird durch verschiedene Entwicklungen sowohl in der Gesellschaft als auch durch schneller wachsende Technikentwicklungen unterstützt. Informationen und Daten von Menschen stehen im Rahmen der schneller werdenden Digitalisierung den Unternehmen umfangreicher und in einer höheren Frequenz zur Verfügung. Diese sogenannten Data Lakes warten gerade darauf mittels Methoden der künstlichen Intelligenz und maschinellem Lernen verarbeitet, analysiert und für unterschiedliche Fragestellungen verwendet zu werden. Diese Ansätze der künstlichen Intelligenz bspw. Maschinellem Lernen stammen meist aus den 70er bzw. 80er Jahren des letzten Jahrhunderts und sind damit z.T. mehr als dreißig Jahre alt.

Auch Versicherungsunternehmen nutzen vermehrt diese Verfahren beispielsweise für die Fragestellungen Next Best Offer, Next Best Action, Stornoprognose, Betrugserkennung etc.

Die Frage, die sich stellt: Sind diese Ansätze neu und warum geraten diese Trends der Künstlichen Intelligenz erst heute bei den Versicherungsunternehmen in den Fokus und welchen Nutzen können Versicherungsunternehmen aus diesem Trend für sich gewinnen und umsetzen?

Um diese Frage beantworten zu können, wird zunächst der aktuelle Hype um das Thema KI beleuchtet und erklärt was eigentlich dahintersteckt.

Es gibt eine Vielzahl von Begriffsdefinitionen von Künstlicher Intelligenz. Aufgrund der sehr breiten interdisziplinären Aufstellung des Forschungsgebiets Künstlicher Intelligenz – KI umfasst u.a. die Forschungsgebiete (Neuro-) Informatik, Statistik, Wahrscheinlichkeitstheorie, Psychologie und Physik – gibt es keine eindeutige Definition hinsichtlich Künstlicher Intelligenz.

Bateller und Harris haben daher 2016 in „Turning AI into Business Value. Today“ versucht eine globalere Definition aufzustellen:

Die Automatisierung der menschlichen Entscheidungsfindung auf der Grundlage von Werkzeugen, die das menschliche Denken und Handeln ergänzen und ersetzen. Die Klasse dieser Werkzeuge heißt „Künstliche Intelligenz“.

Es gibt eine Vielzahl der Arten der Intelligenz. Man unterscheidet zwischen emotionaler, sozialer, sensormotorischer und kognitiver Intelligenz.²⁹ Die Ausprägung der Unterstützung von Künstlicher Intelligenz bei diesen Intelligenzarten ist sehr unterschiedlich.

Auf dem Gebiet der emotionalen Intelligenz leistet KI bislang fast nichts. Der Mensch kann sich in einen anderen Menschen hineinfühlen, Sympathie und Empathie, Mitgefühl, Mitleid, Trauer, Angst, Freude empfinden, Liebesgedichte schreiben, Zornausbrüche haben usw. Was KI heute allerdings schon in Ansätzen können, ist die sog. Sentimentanalyse, d.h. durch Beobachtung der menschlichen Körpersprache, also des Gesichts, der Gestik, Sprache usw. die Emotionen eines Menschen „lesen“.

Hinsichtlich sozialer Intelligenz - die Fähigkeit, in einer menschlichen Gruppe angemessen zu (re-)agieren, etwa eine Stimmung zu erkennen oder konstruktiv zu beeinflussen, z. B. den Teamgeist; Eine Fähigkeit, die meist bei Unternehmern aber auch Politikern stark ausgeprägt ist - kann KI bislang nichts leisten.

Bei der sensormotorischen Intelligenz ist der Mensch der KI noch überlegen, allerdings sind manche Maschinen in Bereichen einzelner Sensoren überlegen. Grundsätzlich ist das menschliche Auge sehr gut ausgebildet. Aber eine geeignete Videokamera kann etwa auch Licht im Infrarotbereich und UV-Bereich verarbeiten, was ein Mensch nicht kann. In der Akustik können Mikrofone wesentlich geringere Lautstärken oder in Frequenzbereichen aufnehmen als das menschliche Ohr. Stärker gilt dies noch bei Geruch- und Geschmackssinn, wo maschinelle Sensoren deutlich überlegen sind. Jedoch kann ein Mensch mittels Sensorfusion diese Sinneseindrücke kombinieren.

Bei der kognitiven Intelligenz ist die KI dem Menschen schon in vielen Bereichen überlegen. Zu diesem Bereich gehört bspw. das Schachspiel, das Spiel von Go und sonstige Brettspiele. Letztlich das Aufnehmen und Erlernen von Wissen, das Kombinieren aus diesem Wissen und das Schlussfolgern aus diesem Wissen. Das entspricht oft dem, was Menschen sich in einer akademischen Ausbildung aneignen.

Diese Einordnung von KI in den Arten der Intelligenz zeigt deutlich, dass der Begriff der starken KI eher ein utopischer Ansatz bleibt und unmöglich umzusetzen ist. Starke KI ist der Zustand, in dem eine Maschine im Grunde zu allem fähig ist, wozu ein Mensch ebenfalls in der Lage wäre. Vielmehr werden Methoden der künstlichen Intelligenz im Rahmen der schwachen Intelligenz eingesetzt. Dazu zählt die Übertragung einzelner Fähigkeiten auf Maschinen, bspw. Erkennen von Texten/Bildinhalten, Spracherkennung und das Spielen. Dies sind zumeist Fähigkeiten der kognitiven Intelligenz. Dabei können Verfahren des maschinellen Lernens - Beschreibung mathematischer Methoden, die einem System ermöglichen, Wissen aus Erfahrungen zu generieren - unterstützen.

Die Entwicklung und Anwendung des maschinellen Lernens gehen chronologisch weit zurück und haben eine Historie von circa siebzig Jahren. In der Abbildung 27 ist eine Auflistung der Meilensteine aus der KI bzw. ML-Geschichte zu entnehmen:

²⁹ Vgl. - *Künstliche Intelligenz: Overhyped oder unterschätzt?* - CeBIT future talk, 14. März 2016.

Robert Thielicke, Chefredakteur Technology Review, im Gespräch mit Prof. Dr. Wolfgang Wahlster, CEO Deutsches Forschungszentrum für Künstliche Intelligenz, DFKI

Künstliche Intelligenz – ... die letzten 70 Jahre!

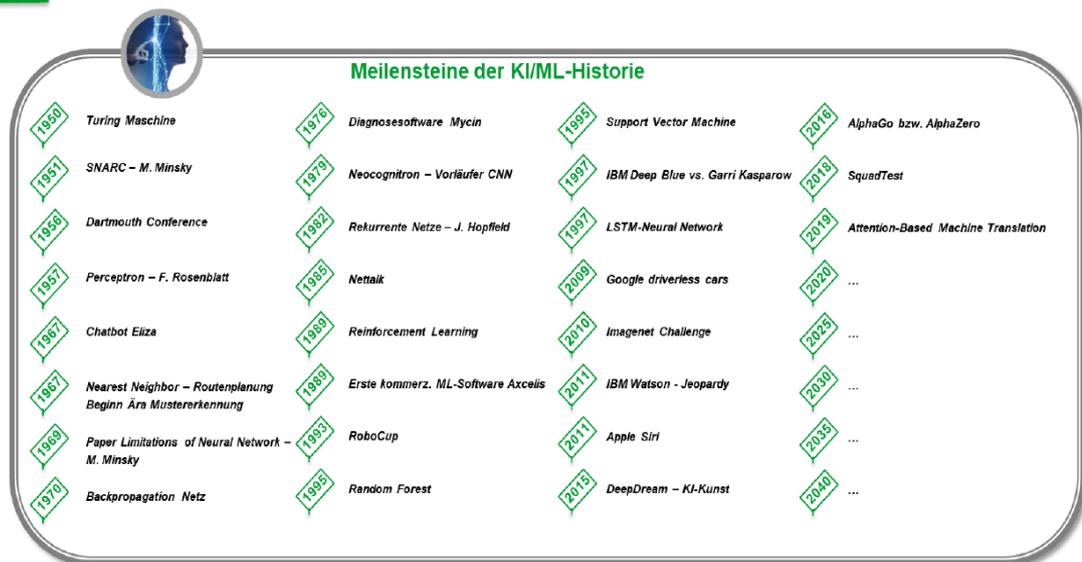


Abbildung 27: Meilensteine der KI/ML-Historie

Aus dieser Abbildung ist ein erster Meilenstein 1950 mit der Turing Maschine abzulesen. In seinem 23 seitigem Paper „Computing Machinery and Intelligence“ geht es um die Fragestellung, ob Maschinen denken können. Dazu entwickelt Alan Turing 1950 den nach ihm benannten Turing-Test, um herauszufinden, ob die Intelligenz eines Systems mit der eines Menschen zu vergleichen ist. Das ist ein erster Meilenstein der künstlichen Intelligenz-Forschung.

1951 gelingt Marvin Minsky der Bau des Neurocomputers Snarc, der seine Gewichte automatisch modifizieren kann, jedoch keine praktische Anwendung fand. Als Geburtsstunde der künstlichen Intelligenz als akademisches Fachgebiet gilt die Dartmouth Conference 1956 für Wissenschaftler und Studenten. 1957/1958 entwickeln F. Rosenblatt und C. Wightman den ersten erfolgreichen Neurocomputer, mit dem Namen Mark I Perceptron. 1959 formuliert Rosenblatt das Perceptron-Konvergenz-Theorem, welches sich als eine wesentliche Grundlage für weitere Forschungsentwicklung der Neuronalen Netze herausstellt. Heute in der Praxis weit verbreitete Verfahren wie Nearest Neighbor oder Backpropagation-Netze finden ihre Entstehung 1969 bzw. 1970.

Rekurrente Netze, die heute auch in Verfahren zur Spracherkennung und Unterschriftenerkennung zu finden sind, haben ihren Ursprung seit 1980. 1995 ist die Geburtsstunde des RandomForest und von der Methodik Support Vector Machine. Diese Verfahren sind sehr verbreitet bei der Anwendung von Klassifikations- bzw. Clusterfragestellungen.

Medienwirksamer und damit auch für Nicht-Fachspezialisten wahrnehmbarer ist das Duell IBM Deep Blue vs. Garri Kasparow 1997 zu erwähnen. Es ist der erste Sieg eines Computers gegen einen Schachweltmeister. 2011 gewinnt die KI IBM Watson das Jeopardy-Duell, welches ebenfalls sehr medienstark publiziert wird. Von da an gewinnt das Thema Künstliche Intelligenz mehr und mehr Einzug in Gesellschaft und Wirtschaft. Eine Vision ist und bleibt das Thema Autonomes Fahren, welches durch den Einsatz der Methoden Künstlicher Intelligenz umgesetzt werden kann. Weltweit führende Unternehmen wie beispielsweise *google* und *amazon* entwickeln ihre Techniken rund um das Thema Künstliche Intelligenz weiter und können so die steigende Datenflut als lukratives Geschäftsmodell für sich ummünzen.

Was macht künstliche Intelligenz so besonders?

Es gibt nicht nur einen Schlüsselfaktor, der durch künstliche Intelligenz bereitgestellt wird. Es sind mehrere, so dass es den Einsatz Künstlicher Intelligenz besonders macht. Ein Schlüsselfaktor ist sicherlich das Thema Bilder. KI ermöglicht Maschinen, Bilder zu erfassen, zu analysieren und zu erkennen. So ist es heute bereits möglich, in Millisekunden aus Fotos Personen, Gegenstände o.ä. mittels KI zu erkennen. Zudem sind Emotionen in der Bilderkennung möglich.

Ein weiterer Schlüsselfaktor der KI ist die Verarbeitung natürlicher Sprache. KI-Methoden ermöglicht Maschinen, Informationen in natürlicher Sprache zu verstehen und in natürlicher Sprache zu kommunizieren. Als Anwendungsbeispiele sind hier der Sprachdienst siri von apple bzw. alexa von amazon zu nennen. Aber auch Chatbots, die heute schon fast zum Alltag gehören, finden sich wieder.

Im Rahmen des Schlüsselfaktors Lernen lernen KI-Systeme aus Trainingsdaten, um Muster zu identifizieren, die sie zur Entscheidungsfindung leiten. So können beispielsweise aus Lernen aus der Vergangenheit Prognosemodelle für die Zukunft erstellt und diese dann operativ genutzt werden. Beispiele für diesen Schlüsselfaktor sind die o.g. Fragestellung Next Best Offer, Next Best Action, Stornoprognose, Betrugserkennung, etc.

Wichtig ist an dieser Stelle festzuhalten, dass künstliche Intelligenz aber keine universelle Methode für alle Anwendungsbereiche ist. Für jeden einzelnen Schlüsselfaktor werden unterschiedlichen Methoden aus dem Baukasten der Künstlichen Intelligenz verwendet. Daher ist es bei Analytik-Projekten wichtig, die Frage- bzw. Zielstellung im Vorfeld zu klären und zu definieren. Die Zielstellung ist wesentlich für die Auswahl der KI-Methodik. Viele KI-Projekt scheitern daran, dass man zwanghaft zu einer vorgegebenen KI-Methodik einen Anwendungsfall sucht. Dies führt meist dazu, dass der Anwendungsfall so abgeändert wird, dass dieser nicht mehr zur Realität passt. Dadurch verliert das Projekt seine Praxisrelevanz beim Kunden.

Künstliche Intelligenz in der Versicherungsbranche

Die Kernkompetenz von Versicherungen ist seit jeher die Anwendung statistischer Methoden und Verfahren. Für die Risikoeinschätzung und die damit verbundene Tarifikalkulation werden eine Vielzahl von Informationen gesammelt und mathematisch weiterverarbeitet. Diese Vorgehensweise ist im Rahmen der Prämienkalkulation in der Versicherungsbranche sehr verbreitet.

Andererseits nutzen Versicherungen aber nicht das volle Potenzial ihrer Daten und analytischen Fähigkeiten aus. Die o.g. Weiterentwicklungen im Umfeld der Künstlichen Intelligenz sind in den Unternehmungen z.T. nicht präsent bzw. das Know-how der aktuellsten Tools und Methoden fehlt. Zudem erschweren starre Konzernstrukturen Innovationen. Das Spartendenken und die damit fehlende Kundensicht – bspw. Schwierigkeiten bei der Integration von Datenquellen - sind ebenfalls Stolpersteine auf dem Weg zum Einsatz von KI bzw. Advanced Analytic.

Bedenken gegen gesetzliche Regeln zu verstoßen werden ebenfalls sehr häufig als Gegenargumente beim Einsatz von Künstliche Intelligenz angeführt. Kulturelle Gründe runden die möglichen Ursachen für den Nicht-Einsatz ab. „Culture eats Innovation“ – ein sehr verbreiteter Ausspruch trifft hier sehr gut zu. Unternehmenskulturen und Werte erschweren es in vielen Fälle sich innovativ und schnell in Analytik-Projekten aufzustellen. Die Methoden und Techniken der Künstlichen Intelligenz haben eine sehr kurze Halbwertszeit, so dass die Mitarbeiter, aber auch die Führungskräfte der Teams, sich immer wieder neu anpassen und lernen müssen. Dabei könnte ein unternehmensweites Changemanagement unterstützend wirken. Dieses Changemanagement muss aber dann entsprechend zur jeweiligen Unternehmenskultur passen.

Was erwartet der Kunde?

Die Erwartungshaltung der Kunden kann für die jeweilige Branche mittels einer Kundenbefragung abgefragt und formuliert. Aus diesen Umfragen ergeben sich meist folgende Erwartungen:

einfach & bequem, individuell & maßgeschneidert, überall & 24/7

einfach & bequem:

Kunden sind nicht nur in der Versicherungsbranche unterwegs und haben sich daher an selbsterklärende und medienbruchfreie Interaktionen mit den Waren- bzw. Dienstleistungsanbieter gewöhnt. Daher erwarten die Kunden, dass die (Kauf-)Prozesse so einfach wie möglich sein sollten. Kunden möchten nicht lange warten und viel Zeit investieren. Wichtig ist dem Kunden eine barrierefreie Interaktion mit dem Unternehmen.

individuell & maßgeschneidert:

Individualität spielt bei den Kunden eine sehr große Rolle. Produkte und Services sollen auf den einzelnen Kunden abgestimmt und maßgeschneidert sein. Dies erfordert eine gewisse Flexibilität hinsichtlich der Inhalte der Produkte bzw. Services um die unterschiedlichen Bedürfnisse der Kunden zu erfüllen. Produkte bzw. Dienstleistungen werden nicht ausschließlich als Gebrauchsgegenstände betrachtet. Jeden Tag teilen Kunden persönliche Informationen über eine Vielzahl von Kommunikationskanäle und zeigen somit ihre persönliche individuelle Note der Außenwelt.

überall & 24/7:

Im Zeitalter der Digitalisierung können Kunden überall eine Kaufentscheidung tätigen. Wo in der Vergangenheit die Entscheidung zum Kauf und damit der Kauf selbst im Ladenlokal bzw. Geschäft erfolgte, kann dieser Prozess heute mobil beispielsweise per Handy oder Tablet überall und damit auch 24 Stunden rund die Uhr – unabhängig von Öffnungszeiten – geschehen.

Viele Branchen sind diesen Kundenerwartungen in den letzten Jahren entgegengekommen und haben diese in ihren Verkaufsprozessen berücksichtigt. Dies gehört heute zum Alltag und stellt eher einen Hygienefaktor im Bezug des Verkaufs- bzw. Serviceprozesses dar. Werbeslogans „Bis 18 Uhr bestellt, Lieferung am nächsten Tag.“, „Kostenlose Rücksendung bei Nichtgefallen“ oder „Gestalten Sie Ihr Müsli individuell“ überraschen den Kunden heute nicht mehr.

Die Herausforderung der Unternehmen ist es diese Kundenerwartungen so zu erfüllen, dass die Prozesse für eine Vielzahl von Kunden automatisiert, aber trotzdem individuell und maßgeschneidert wirken und letztendlich das Geschäft ebenfalls wirtschaftlich und profitabel bleibt.

Dabei kann die Künstliche Intelligenz eine Antwort geben und kann eine Lösung darstellen, um diesen Kundenerwartungen gerecht zu werden. Die Umsetzung dieser Lösung wird durch drei Faktoren beeinflusst:

Faktor Daten – Faktor Technologie – Faktor Mensch

Kundenerwartungen im Digitalen Zeitalter und entsprechende Antworten



Abbildung 28: Kundenerwartungen im Digitalen Zeitalter und entsprechende Antworten

Künstliche Intelligenz basiert auf einer datengetriebenen Analysemethodik. Daher stellen Daten bzw. Informationen eine elementare Grundlage für die Entwicklung und Umsetzung von KI-Projekten dar. Zumeist müssen aus operativen Systemen (beispielsweise CRM-Systemen) die für die Fragestellung wichtigen Informationen extrahiert und bedarfsgerecht aufbereitet werden. Herausforderungen an dieser Stelle der Datenvorverarbeitung können der Datenzugang, die Datenmenge und die Datenqualität sein. Nicht alle Daten werden elektronisch gespeichert, sind z.T. auf Handzetteln oder aber auch in den Köpfen der Mitarbeiter abgelegt. Auch datenschutzrechtliche Rahmenbedingungen können dazu führen, dass gespeicherte Daten nicht verwendet werden dürfen. Bei der Datenvorverarbeitung ist der Umgang mit großen Datenmengen entscheidend. Wie speichere ich diese Daten, sind diese in Rohform für die Fragestellung relevant oder eher in einer aggregierten Form? Dabei spielt die Auswahl der Datenaufbereitungsmethodik eine wesentliche Rolle. Ein weiterer Aspekt an dieser Stelle ist die Datenqualität. Diese stellt eine Basisgrundvoraussetzung für die weiteren Schritte im Analyseprozess. Fehlende Datenqualität führt zu falschen Modellergebnissen, welche zu falschen Handlungsempfehlungen führen können. In der Praxis erfordert die Phase der Datensammlung und Datenaufbereitung einen Großteil der Projektarbeit. In vielen Projekten umfasst dieser Teil ca. 80% der Projektzeit. Nachzuholende Basisarbeiten im Datenumfeld verlangsamten die digitale Transformation der Versicherungswirtschaft.

Sind die drei o.g. Grundvoraussetzungen Technologie, Daten und Mensch erfolgreich erfüllt, ergeben sich bei der Umsetzung von KI-Projekte weitere Herausforderungen bzw. Voraussetzungen, die erfüllt sein müssen:

Voraussetzungen für die Anwendung von **Künstlicher Intelligenz**



Abbildung 29: Voraussetzungen für die Anwendung von Künstlicher Intelligenz

Außerhalb der rechtlich/politischen und gesellschaftlichen Voraussetzungen haben die Unternehmen einen Einfluss auf die organisatorischen, personellen und technischen Voraussetzungen und können unternehmensintern darauf einwirken.

Basis einer erfolgreichen Einführung von Künstlichen Intelligenz-Projekten ist die organisatorische Einordnung des Themas. Dazu zählt eine konzernweite KI-Strategie inkl. Zielsetzung, Investitions- und Risikobereitschaft, Flexibilität in prozessualer und personeller Hinsicht, angemessenes Change Management, Aufbrechen von „Silo-Denken“, intensiver abteilungsübergreifender Austausch und die Einbindung sämtlicher Interessensgruppen.

Neben den organisatorischen Voraussetzungen müssen auch personelle Voraussetzung geschaffen werden. Darunter fällt u.a. die Veränderungsbereitschaft der Mitarbeiter, die Akzeptanz für die bevorstehenden Änderungen, Ermittlung des Bedarfs in Hinblick auf die benötigten Qualifikationen (Know-how), grundlegende Bereitschaft zur Teilnahme an Weiter- und Fortbildungen, ggf. Einbezug externen Sachverständigen (Neueinstellungen und/oder externe Dienstleister), logische Nachbetrachtung der KI-Ergebnisse durch Fachexperten.

Um die Projekte umsetzen zu können müssen technische Voraussetzungen geschaffen sein. Hier sind unter anderem zu nennen: Verfügbarkeit adäquater Trainingsdaten in digitaler Form, Sicherstellung ausreichender Datenqualität (Richtigkeit, Aktualität, Anwenderfreundlichkeit etc.), Festlegung der Fehlertoleranz zur Beurteilung der Praxistauglichkeit, Etablierung von Schutzmechanismen (z.B. Vollmachten), Transparenz und Nachvollziehbarkeit (Stichwort Blackbox), angemessene Erfüllung datenschutzrechtlicher Anforderungen, allgemeine Verbesserung der IT-Infrastruktur und Personalkapazitäten.

KI-Einsatz – Umsetzung bei der LVM am Beispiel des Kundenwerts

Die LVM erstellt mittels Methoden des maschinellen Lernens (beispielsweise Decision Tree, Neuronale Netze, Support Vector Machine, Random Forest, Binär Logistische Regression, Boosting) Prognosen für die Fragestellung Cross Selling (Next Best Offer), Stornoverhalten der Kunden, Zahlungsausfallverhalten, Schaden und Betrug. Diese einzelnen Prognosekomponenten finden Einfluss in eine Gesamtbewertung der Kundenbeziehung.

Im Mittelpunkt steht der Business Case, d.h. die betriebswirtschaftliche spezifische Fragestellung. Erst in Abhängigkeit dieser Fragestellung erfolgt die Auswahl der Analyseverfahren.

Zusammenfassung:

- Ansätze und Methoden von künstlicher Intelligenz sind z.T. 70 Jahre alt
- Durch das rasante Wachstum der zur Verfügung stehenden Daten und der Möglichkeit diese mit bereitstehenden Rechnerkapazitäten zu verarbeiten, ist das Interesse an KI deutlich gewachsen
- KI benötigt Basisvoraussetzungen im Unternehmen
- „Einfache KI hat Vorfahrt“ – Weg vom „AI Claim“ - Ernten der „Low hanging fruits“

Der Weg dorthin – 5 Eckpfeiler für erfolgreiche Künstliche Intelligenz-Projekte:

1. Business Case definieren - Die passende Technologie ergibt sich zwangsläufig daraus
2. Die richtigen Daten nutzen - Datenqualität, Datenrelevanz und Prozesswissen sind Voraussetzung für erfolgreiche KI-Projekte
3. Gezielt KI-Wissen im Unternehmen aufbauen
4. KI-Kultur im Unternehmen schaffen – Rahmen bilden – Unterstützung der Mitarbeiter durch KI, statt diese zu ersetzen
5. Unterschiedliche Lösungs- und Bereitstellungsmodelle auch außerhalb der KI evaluieren – Erzielen von Quick-Wins

Fazit – „KI ist kein Allheilmittel zur Lösung aller Probleme“

7. Telematik bei der HUK-COBURG: Big Data, Big Insights?

Dr. Thomas Körzdörfer

Die Schlagwörter KI und Big Data sind derzeit in aller Munde. Ihre Popularität ist unter anderem Unternehmen wie Google, Facebook und Amazon zuzuschreiben, welche als Vorreiter auf diesem Gebiet innerhalb weniger Jahre bestehende Wirtschaftszweige komplett umgekrempelt haben. Auch Versicherungsunternehmen sind den Umgang mit großen Datenmengen gewöhnt, und sie sind seit jeher Experten im Umgang mit mathematischen Modellen und statistischen Auswertungen. Und weil auch die Versicherungsbranche modern sein will, wird heute jedes komplexere Modell, oder auch „maschinelles Lernverfahren“, gerne auch kurzerhand als „KI“ beworben und jede größere Ansammlung von Daten wird zu „Big Data“.

Aber selbst wenn diese Bezeichnungen inhaltlich weitgehend zutreffend sein mögen, so geht die hier häufig vorgenommene reine Umbenennung etablierter Strukturen und Prozesse doch an den wesentlichen Fragen vorbei: Was ist das eigentliche Erfolgsrezept von Firmen wie Google oder Facebook, in welchen KI und Big Data nicht nur als Mittel zum Zweck verwendet werden, sondern quasi zur DNA des Unternehmens gehören? In wie weit lässt sich dieses überhaupt auf die Versicherungsbranche übertragen? Welche neuen strukturellen, personellen, fachlichen und kommunikativen Herausforderungen ergeben sich daraus für etablierte Versicherungsunternehmen?

In der Praxis treten diese Herausforderungen sehr schnell zutage. Und dabei wird deutlich, dass sich mit „Big Data“ doch auch inhaltlich plötzlich ganz neue Fragestellungen für Aktuarien auftun, zu deren Beantwortung zum Teil ganz neue Skills und Herangehensweisen benötigt werden. Traditionell arbeiten Aktuarien mit Daten, welche von Kunden, Kundenberatern, Vermittlern oder Sachbearbeitern händisch in Formulare oder elektronische Erfassungsmasken eingetragen wurden. Dieser Prozess der Erfassung hat dann auch entsprechende Auswirkungen auf Qualität und Umfang der Daten. Dies bestimmt folgerichtig auch die tägliche Herausforderung für Aktuarien im Umgang mit diesen Daten, welche vorwiegend darin besteht, möglichst viele Erkenntnisse aus möglichst wenigen Daten zu gewinnen. Und auch wenn sich über die Jahre auf diese Weise sehr große Datenmengen bei den Versicherern ansammeln, so spiegelt die tägliche Herausforderung für den klassischen Aktuar damit eigentlich genau das Gegenteil dessen wieder, was den Umgang mit Big Data bestimmt.

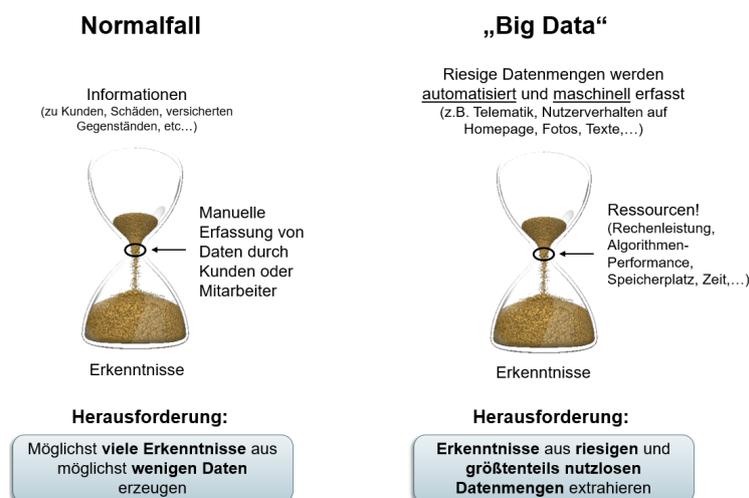


Abbildung 30: Der Unterschied zwischen klassischer Datenhaltung und „Big Data“ besteht nicht allein in der Menge der Daten, sondern vor allem in den Herausforderungen bei der Erfassung, Speicherung und Weiterverarbeitung der Daten sowie beim Erkenntnisgewinn. Der Umgang mit Big Data erfordert daher große Investitionen in Infrastruktur und in den Aufbau von Know-how.

In dem ständigen Bemühen der Versicherer, Prozesse kundenfreundlicher, schlanker und kosteneffizienter zu gestalten wird die umfangreiche, manuelle Erfassung von Daten in Zukunft sehr wahrscheinlich zunehmend zum Auslaufmodell. Stattdessen rückt die automatisierte, maschinelle Erfassung von Daten immer mehr in den Fokus der Versicherer. Sie interessieren sich beispielsweise zunehmend für die automatische Verarbeitung von Schadenfotos oder zu versichernden Gegenständen, mit der maschinellen Interpretation von Texten in Online-Chats oder Emails, der Dunkerverarbeitung von per OCR maschinell eingelesenen Rechnungen und Gutachten, und der Verwendung von Wetter-, Satelliten- und Telematik-Daten.

Vor allem zwei Aspekte unterscheiden diese Vorgehensweise fundamental von der traditionellen Erfassung von Daten. Erstens: Der Kapazitätsengpass des Prozesses ist nicht länger bestimmt durch die Zeit, welche Kunden oder Sachbearbeiter für die Erfassung der Daten aufzubringen bereit sind, sondern durch den zur Verfügung stehenden Speicherplatz, die für die Verarbeitung der riesigen Datenmengen nötige Rechenleistung, die Performance der Algorithmen und die Zeitspanne, innerhalb welcher Modellresultate verfügbar sein müssen um die Kundeninteraktion effizient und barrierefrei zu gestalten. Zweitens: Die Herausforderung für den Aktuar besteht nicht mehr darin, möglichst viele Erkenntnisse aus möglichst wenig, standardisierten Daten zu gewinnen, sondern unter möglichst geringem Einsatz kostenintensiver Ressourcen die wichtigsten Erkenntnisse aus den durch die maschinelle Erfassung anfallenden riesigen und größtenteils nutzlosen Datenmengen zu extrahieren. Wenn dies der Fall ist, dann sprechen wir vom Umgang mit „Big Data“. KI, oder auch einfach maschinelles Lernen, ist dann schlichtweg ein Portfolio von mathematischen, computerbasierten Methoden, welche der Aktuar zum Erkenntnisgewinn aus den großen Datenmengen nutzen kann.

Das derzeit größte und ambitionierteste Big Data Projekt der HUK-COBURG heißt Telematik Plus. Für den Kunden bedeutet der Abschluss des Telematik Plus Bausteins, dass er durch sicheres Fahrverhalten bis zu 30% seines normalen Kfz-Tarifs einsparen kann. Um das Fahrverhalten zu bewerten bekommt der Kunde einen Telematik-Sensor zur Verfügung gestellt, welcher in etwa die Größe einer Zündholzschachtel hat und in die Windschutzscheibe des versicherten Autos eingeklebt werden muss. Zudem muss sich der Kunde die HUK Mein-Auto App auf sein Smartphone herunterladen, Smartphone und Sensor über Bluetooth verbinden und sich in der App registrieren. Der Telematik Plus Tarif kann seit April 2019 von ausnahmslos allen Kunden der HUK-COBURG und seit September auch von allen Kunden der HUK24 abgeschlossen werden. Stand 31.11.2019, also das Jahreswechselgeschäft 2019/20 abgenommen, gab es etwa 90.000 aktive Fahrer im Telematik Plus Programm, die zusammen mehr als 15 Mio. Fahrten durchgeführt haben.



Abbildung 31: Aktueller Stand (31.11.19) aktiver Fahrer im Telematik Plus Baustein vor dem Jahreswechselgeschäft 2019/20.

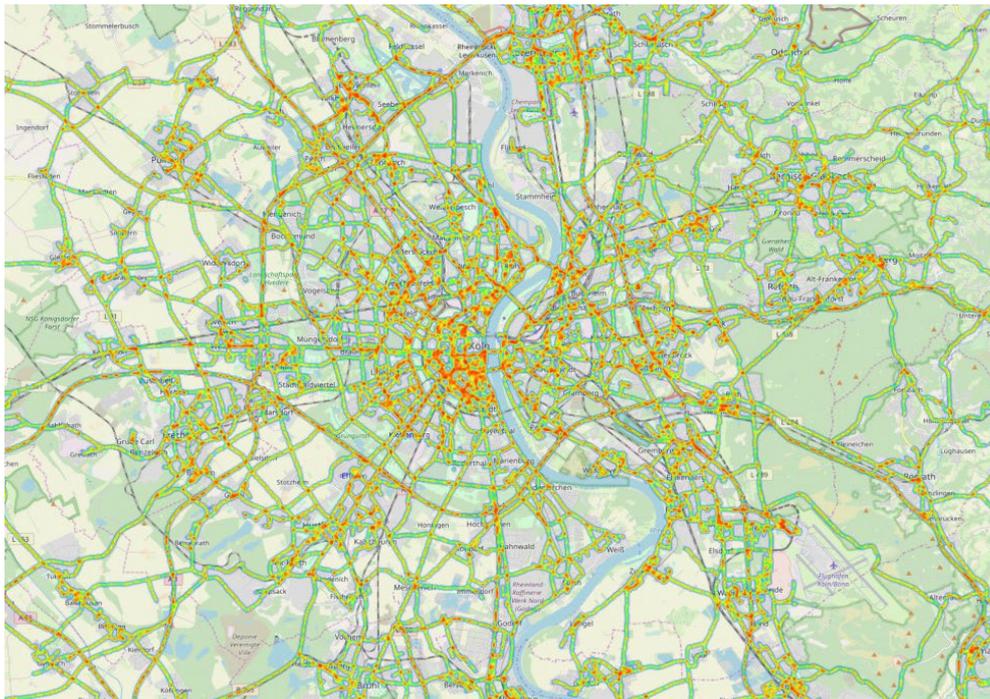


Abbildung 32: Straßenabdeckung in Köln von Fahrern im Telematik-Plus Programm an einem „ganz normalen“ Montag (11.11.2019).

Der Telematik-Sensor ist dabei lediglich mit einem hochwertigen Beschleunigungssensor, einer Batterie, einem Speicher und einem Bluetooth-Controller ausgestattet, über welchen beim Einsteigen und Starten des Fahrzeugs auch die Verbindung mit dem Smartphone und damit mit der HUK-Mein-Auto-App hergestellt wird. Während der Autofahrt zeichnen Sensor und Smartphone kontinuierlich Fahrdaten auf. Dazu gehören die Uhrzeit, die Position (GPS-Koordinaten), die gefahrene Geschwindigkeit sowie die vom Sensor gemessene Längs- und Querschleunigung. Nach Beendigung der Fahrt werden diese Fahrdaten per Mobilfunknetz, oder wahlweise auch nur per WLAN, an den Dienstleister Cambridge Mobile Telematics (CMT) gesendet. Dort werden die Daten bereinigt, aufbereitet, auf die Karte gematched und so mit zusätzlichen Karteninformationen (z.B. Tempolimits und Straßentypen) angereichert. Die so angereicherten Fahrdaten werden dann der HUK Datenservice und Dienstleistungen GmbH (HDD) als Datenstrom zur Verfügung gestellt. Diese berechnet daraus den persönlichen Fahrwert des Fahrers sowie den über alle Fahrer des versicherten Fahrzeugs aggregierten Jahresfahrwert, welchen die HDD am Ende des Versicherungsjahres pseudonymisiert an die Versicherung (HUK-COBURG oder HUK24) übermittelt. Die Versicherung ordnet diesem Pseudonym dann den entsprechenden Versicherungsvertrag zu und weist den resultierenden Bonus auf den Versicherungstarif des Folgejahres aus. Darüber hinaus reicht die HDD ausgewählte Fahrdaten, den persönlichen Fahrwert und sogenannte Fahrereignisse an die HUK-Mein-Auto-App weiter, wo sie dem Fahrer bereits wenige Minuten nach Beendigung der Fahrt angezeigt werden.

Die Datenmengen, welche dabei anfallen, sind angesichts der hohen Aufzeichnungsfrequenz der Sensoren und der großen Anzahl an Fahrern im Telematik Plus Programm gigantisch. Wie dicht die Abdeckung des Straßennetzes bereits wenige Monate nach dem Verkaufsstart von Telematik Plus ist, zeigt Abb. 32 exemplarisch am Beispiel Köln. An nur einem einzelnen Wochentag wurden alle größeren und nahezu alle kleineren Straßen in und um Köln von Fahrern im Telematik Plus Programm befahren. Wie anhand dieses Beispiels greifbar wird, stellt die schnelle und zuverlässige Verarbeitung der anfallenden Datenmengen innerhalb nur weniger Minuten nach Fahrtende eine ganz besondere Herausforderung dar. Die HDD musste dazu in den letzten Jahren sowohl intensiv in

Rechnerinfrastruktur als auch ganz immens in den Know-how Aufbau investieren, z.B. in Bezug auf Cloud-Computing, die Betreuung von Hadoop Clustern, Programmierung in PySpark und Scala, KI und Machine Learning. Ohne die Kombination von lokaler und cloud-basierter Rechnerstruktur, eine enge und regelmäßige Koordination mit dem Dienstleister CMT, eine tagtägliche Überwachung der Datenlieferung auf Umfang und Qualität, sowie die Koordination von Releases, angefangen von den Betriebssystem-Updates der Smartphones über Updates von CMT bis hin zu Updates der App oder der Fahrdatenverarbeitung bei der HDD, könnte eine zuverlässige und schnelle Datenlieferung an den Kunden dabei nicht gewährleistet werden.

Nur durch die Bereitstellung dieser Infrastruktur sowie schneller und effizienter Algorithmen ist es möglich, dass die Auswertung einer Fahrt dem Kunden bereits wenige Minuten nach deren Beendigung in der App angezeigt werden kann (siehe Abb. 33). Der Versicherungsnehmer kann, nach seiner Registrierung, verschiedene zusätzliche Fahrer für jedes versicherte Fahrzeug einladen. Jeder Fahrer sieht dann in der App seinen Persönlichen Fahrwert, berechnet über seine eigenen Fahrten in allen mit einem entsprechend registrierten Telematik-Sensor ausgestatteten Fahrzeugen. Ist der Fahrer auf mehreren Fahrzeugen registriert sieht er dabei alle seine individuellen Fahrten und Fahrwerte auf jedem einzelnen Fahrzeug. Zudem bekommt er einen Überblick über seine letzten Fahrten, zusammen mit individuellem Feedback in Form von "Ereignissen" sowie eine generelle Auswertung zu seinem Lenk-, Geschwindigkeits-, Beschleunigungs- und Bremsverhalten über alle Fahrten hinweg. Der Versicherungsnehmer selbst kann sich zusätzlich noch den VN-Score, also den über alle Fahrer und Fahrten des versicherten Fahrzeugs gemittelten Fahrwert, und den sich daraus berechneten Folge-Bonus anzeigen lassen. Die individuellen Fahrten der anderen Fahrer sieht er dabei nicht. Somit ist gewährleistet, dass jeder Fahrer individuelles Feedback zu seinem eigenen Fahrverhalten bekommt, während das versicherte Fahrzeug risikogerecht tarifiert und der Datenschutz unter den einzelnen Fahrern gewährleistet werden kann.

Während die Kunden an Telematik Plus, unserer eigenen Marktforschung zufolge, in erster Linie die Möglichkeit der Reduzierung des Unfallrisikos durch individuelles Feedback zu ihrem Fahrverhalten und, allen voran, die Möglichkeit der Ersparnis bei der Versicherungsprämie zu schätzen wissen, profitiert die Versicherung selbst vor allem von einer deutlich verbesserten Risikodifferenzierung, welche in der Folge eine gerechtere und wettbewerbsfähigere Tarifierung ermöglicht.

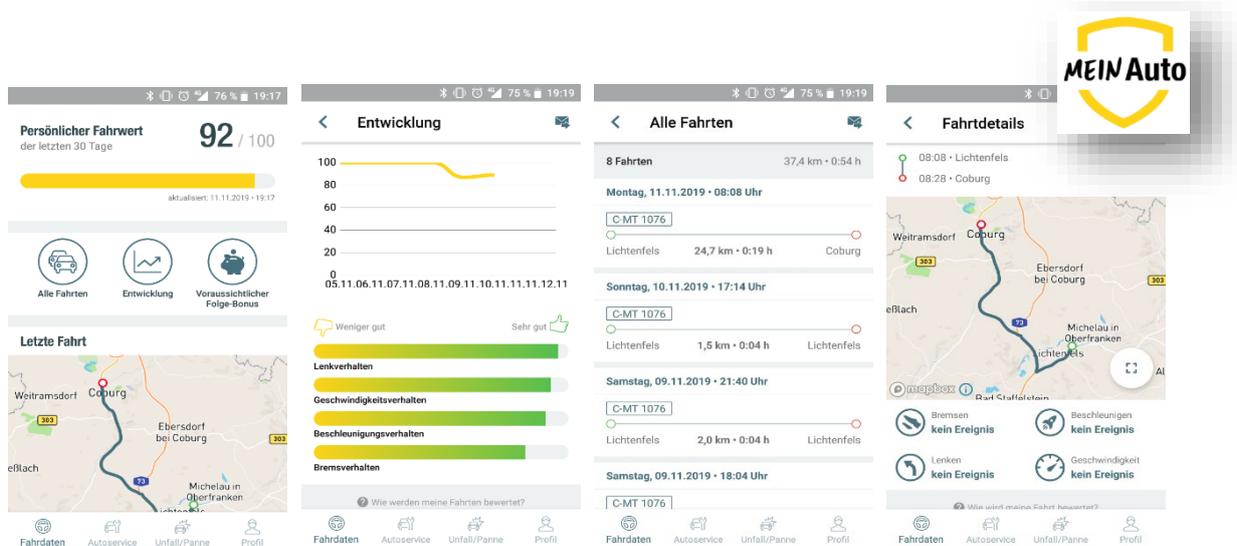


Abbildung 33 Darstellungen in der HUK Mein Auto App.

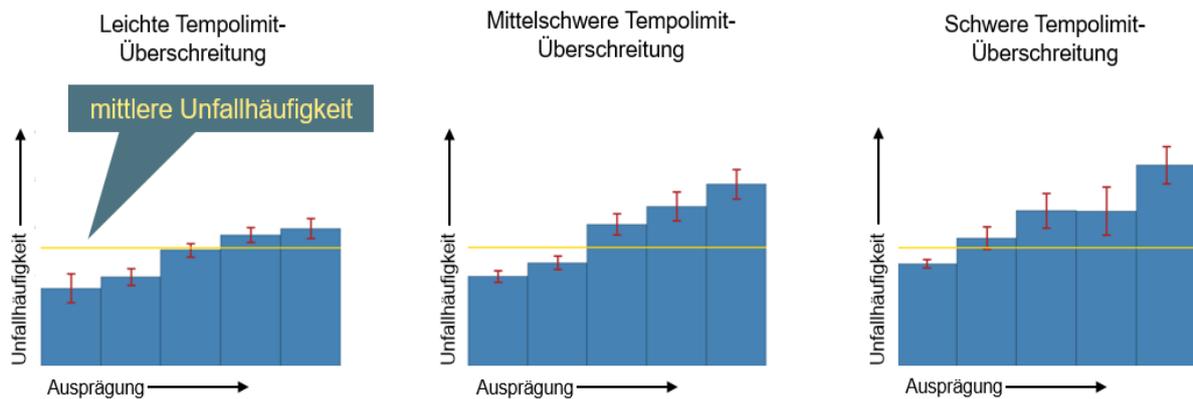


Abbildung 34: Zusammenhang zwischen Unfallhäufigkeit und Häufigkeit des Auftretens eines bestimmten Merkmals (hier: Überschreitungen des Tempolimits) im Fahrverhalten eines Fahrers (Ausprägung). Je häufiger und je stärker ein Fahrer das gesetzliche Tempolimit überschreitet, desto höher ist die Wahrscheinlichkeit eines Unfalls. Fahrer, die sehr häufig das Tempolimit überschreiten haben eine stark erhöhte Unfallwahrscheinlichkeit.

Die individuelle Bewertung des Unfallrisikos bestimmten Fahrverhaltens, welches sich im Persönlichen Fahrwert niederschlägt, erfolgt dabei vorurteilsfrei und datenbasiert. Dies ist nur möglich, weil die HUK-COBURG mehr als zwei Jahre lang Erfahrung (und Daten) im Vorgänger von Telematik Plus, dem Smart Driver Programm für Junge Fahrer U25, sammeln konnte. In dieser Zeit ist nicht nur eine große Menge an Fahrdaten, sondern darüber hinaus auch eine signifikante Anzahl an Unfällen angefallen. Mit Hilfe einer Mischung von computerbasierten mathematischen Modellen ("KI") und fachlichem Know-how lässt sich das Fahrverhalten so mit Unfallhäufigkeiten korrelieren und damit diejenigen Fahrverhaltensmerkmale identifizieren, welche das Unfallrisiko statistisch signifikant erhöhen oder senken. Beispiele für solche Merkmale sind in Abb. 35 dargestellt. Fahrer, die sich immer an Tempolimit-Beschränkungen halten, haben demnach nachweislich ein deutlich reduziertes Unfallrisiko. Umgekehrt ist das Unfallrisiko deutlich höher als im Durchschnitt, wenn das Tempolimit häufig mittelschwer (mittlere Grafik) oder schwer (rechte Grafik) überschritten wird. Nach diesem Muster lassen sich auch jede Menge andere Fahrverhaltensmerkmale finden, welche positiv oder negativ mit der Unfallhäufigkeit korrelieren, z.B. in Bezug auf Lenk-, Brems- oder Beschleunigungsverhalten, aber auch auf komplexere Merkmale wie das Anfahrverhalten an Ampeln, das Verhalten bei Überholvorgängen, Umfang und Art der Nutzung des Smartphones während der Fahrt usw.

Werden solche mathematisch eindeutigen Korrelationen gefunden, so werden sie anschließend von den Experten der HDD noch einmal auf eine Reihe von Kriterien hin überprüft, z.B. hinsichtlich einer logischen Kausalität (nur weil ein bestimmtes Fahrverhalten mit Unfallhäufigkeit korreliert heißt das nicht notwendigerweise, dass dieser Zusammenhang auch kausal ist), Zuverlässigkeit (kann das Merkmal in den Daten zuverlässig identifiziert werden), Transparenz (ist eine entsprechende Bewertung des Verhaltens für den Kunden nachvollziehbar bzw. ist es realistisch möglich dem Kunden Feedback zu geben um sein Fahrverhalten bzgl. dieses Merkmals zu verbessern) und Kundenakzeptanz bzw. möglicher Diskriminierung (kann ausgeschlossen werden, dass es Kundengruppen gibt, die durch die Bewertung des Merkmals systematisch diskriminiert würden, wie z.B. Schichtarbeiter bei einer Bewertung von Nachtfahrten oder Großstädter bei einer Bewertung von Stadtfahrten). Nur solche Kriterien, welche sowohl mathematisch eindeutig mit der Unfallhäufigkeit korrelieren als auch die genannten weiteren Kriterien erfüllen, werden schließlich im Scoring-Algorithmus verwendet, um den Fahrwert zu berechnen. Die Grenzwerte des Fahrwerts von 0 bzw. 100 entsprechend dabei einer deutlich erhöhten bzw. reduzierten Unfallhäufigkeit - dementsprechend selten treten diese Werte dann, statistisch gesehen, auf. Der Fahrwert der meisten Fahrer pendelt sich nach einiger Zeit im mittleren Bereich ein, was dementsprechend einer mittleren Unfallwahrscheinlichkeit entspricht.

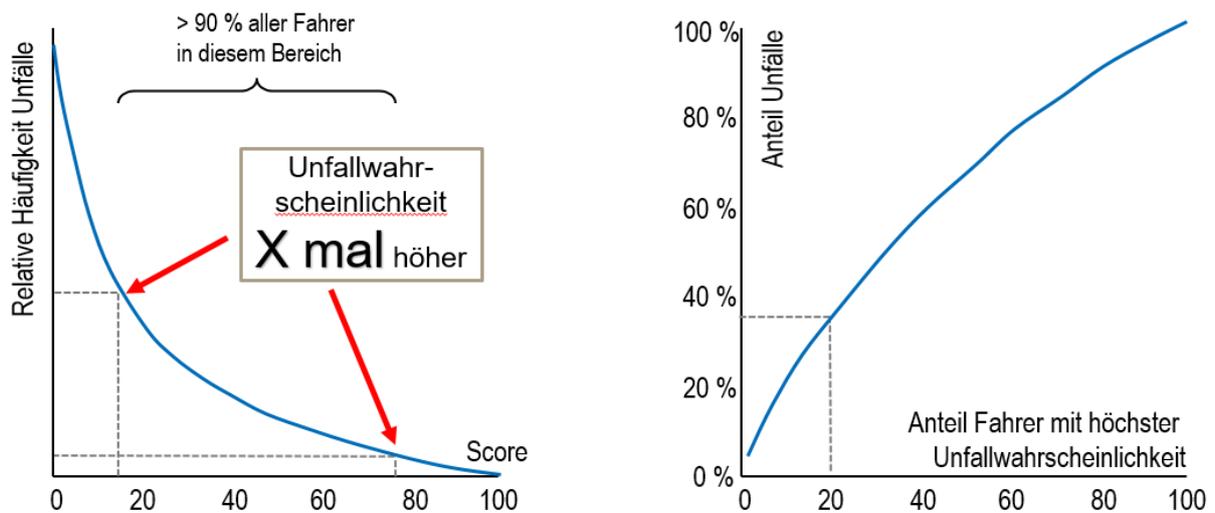


Abbildung 35: Links: Relative Unfallhäufigkeit in Abhängigkeit vom Fahrwert. Die Unfallhäufigkeit der 5% Fahrer mit den niedrigsten Fahrwerten unterscheidet sich von der Unfallhäufigkeit der 5% besten Fahrer um einen Faktor X. Je nachdem welche Merkmale man verwendet und wie man den Algorithmus kalibriert können Faktoren von 8 oder höher erreicht werden. Rechts: Die 20% Fahrer mit der höchsten Unfallwahrscheinlichkeit produzieren 35% der Unfälle.

Abb. 36 zeigt den Mehrwert, den eine solche Berechnung des Fahrwerts liefert. Der Score trennt risikoreiche von risikoarmen Fahrern. Wie wichtig diese Trennung ist zeigt sich z.B. daran, dass die 20% Fahrer mit der höchsten Unfallwahrscheinlichkeit bereits 35 Prozent der Unfälle produzieren. Die Unfallhäufigkeit der 5 Prozent Fahrer mit den niedrigsten Telematik Plus Fahrwerten unterscheidet sich dabei von der Unfallhäufigkeit der 5 Prozent Fahrer mit den höchsten Fahrwerten um einen Faktor X. Je nachdem, welche Fahrverhaltensmerkmale man für das Scoring verwendet und wie viel Erfahrung, Know-how und Daten in den Algorithmus einfließen, sind Faktoren von $X > 8$ dabei durchaus realistisch. Der Fahrwert liefert daher wertvolle und zuverlässige Informationen über das individuelle Unfallrisiko von Fahrern und erlaubt, dieses auf bestimmte Verhaltensweisen zurückzuführen. Dies ist essentiell, um den Fahrern die Möglichkeit zu geben, ihr persönliches Unfallrisiko und damit auch ihren Versicherungsbeitrag durch Anpassung ihres Fahrverhaltens zu senken.

Am Ende bleibt natürlich die Frage: Wie reagieren die Kunden auf Telematik Plus? Fest steht, die Kunden kommen in erster Linie um Beiträge zu sparen, und die meisten sind auch sehr überzeugt davon, sehr gute und sichere Autofahrer zu sein. Unsere Umfragen zeigen, dass unsere Kunden sich im Mittel einen Fahrwert von 80 geben würden. Wenn die Kunden explizit darauf hingewiesen werden, dass der Mittelwert aller Fahrer bei einem Fahrwert von 50 liegt, geben sie sich selbst im Mittel immer noch einen Fahrwert von 70. Insbesondere gibt es kaum jemanden, der die Sicherheit seines Fahrstils selbst als unterdurchschnittlich bezeichnen würde; dabei betrifft das statistisch nun mal in etwa die Hälfte aller Fahrer. Diese Diskrepanz zwischen der eigenen, subjektiven Einschätzung und der objektiven und ehrlichen Bewertung durch den Fahrwertalgorithmus gilt es in der Kundenkommunikation zu bewältigen.

Erschwerend kommt hinzu, dass der Kunde durch das regelmäßige Feedback in der HUK-Mein-Auto-App sich nun plötzlich sehr regelmäßig mit seiner Versicherung auseinandersetzt. Während sich die Interaktion mit der eigenen Versicherung bisher für die allermeisten Menschen auf den Vertragsabschluss, die Kündigung und den Schadenfall beschränkte, so beschäftigen sich Telematik

Plus Kunden nun sehr viel häufiger mit der App und damit auch mit ihrem Versicherungstarif. Und während sich beim Abschluss einer Versicherung kaum mehr jemand darüber beschwert, dass er in München deutlich mehr für den gleichen Versicherungsschutz zahlt als in Coburg, so stellen nicht wenige Kunden nun plötzlich sehr regelmäßig in Frage, warum hartes Bremsen oder häufige Geschwindigkeitsüberschreitungen ihren Rabatt beeinflussen. Die Versicherungen werden Antworten auf diese neuen Herausforderungen finden müssen. Bei der HUK-COBURG arbeiten wir daher täglich daran, das Feedback an die Fahrer kontinuierlich zu verbessern und den Algorithmus und die Bewertung des Fahrverhaltens möglichst transparent zu gestalten.

Tatsächlich haben wir bereits jetzt einige Hinweise darauf, dass die Teilnahme an Telematik Plus das Fahrverhalten verbessert und das Unfallrisiko damit signifikant senkt. Bei den 50 Testern aus unserem Pilotprojekt vor Produkteinführung, die nach Marktstart selber in das Telematik Plus Programm gewechselt und damit über 100.000 Kilometer gefahren sind, haben sich die Fahrwerte deutlich verbessert (Abb. 36); die Testpersonen fuhren deutlich vorsichtiger. Auch wenn diese Zahlen sicherlich (noch) nicht ausreichend repräsentativ sind, zeigt diese Auswertung, dass Telematik das Potential zu einer positiven Verhaltensänderung hat und damit auch zu einem geringeren Unfallrisiko unserer Kunden und insgesamt sichereren Straßen beitragen kann. Darüber hinaus zeigen unsere Analysen auch sehr deutlich, dass der Fahrwertalgorithmus in Telematik Plus eine umweltfreundliche, verbrauchsarme Fahrweise belohnt: Fahrer mit gutem Fahrwert verbrauchen im Schnitt etwa 10% weniger Sprit als solche mit einem schlechten Fahrwert.

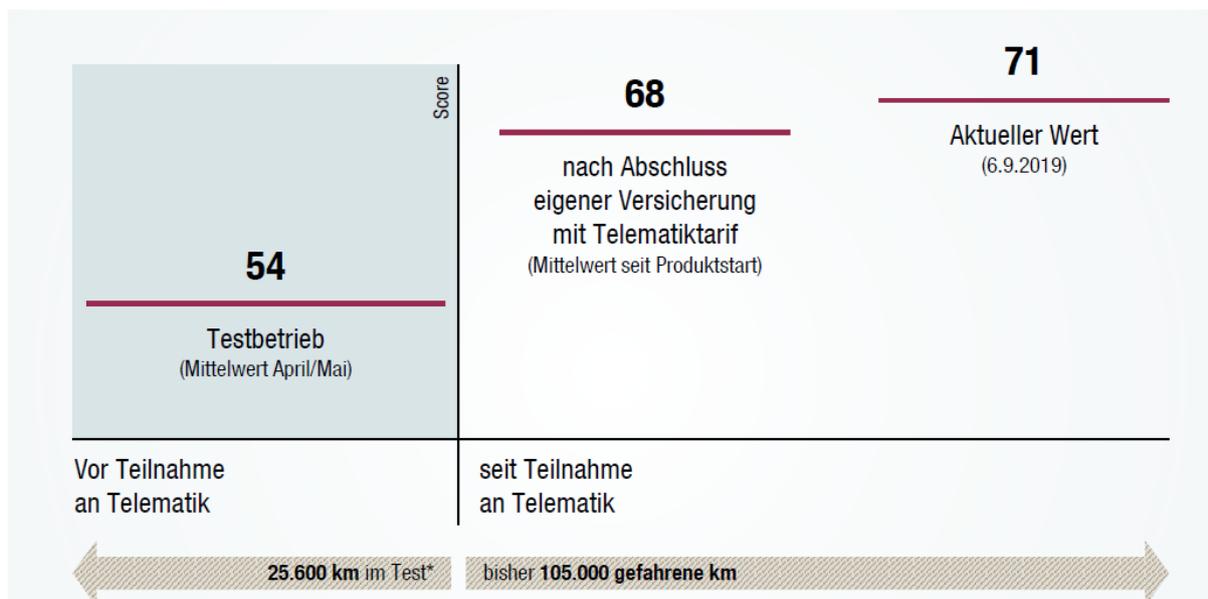


Abbildung 36: Die Teilnahme an Telematik Plus führte bei unseren Testern im Mittel zu einer deutlichen Steigerung des Fahrwerts und damit zu einer Senkung des Unfallrisikos.

Telematik Plus ist das bisher größte und ambitionierteste Big Data Projekt der HUK-COBURG und ohne Frage auch eines der größten und wichtigsten Big Data Projekte der Versicherungsbranche in Deutschland. Der Aufbau der dafür nötigen infrastrukturellen, organisatorischen und personellen Voraussetzungen stellte uns dabei vor sehr große Herausforderungen. Allerdings haben wir dabei auch sehr viel gelernt, und dieses Know-how und die geschaffene Infrastruktur können und möchten wir nun auch auf andere Big Data und KI Projekte im Konzern übertragen. Allein schon deshalb ist unser Zwischenfazit ganz klar: Es hat sich gelohnt! Telematik als Baustein der Kfz Versicherung steht in

Deutschland insgesamt erst am Anfang, und die Zeit wird zeigen, welche Stellung dieses neue Produkt auf Dauer einnehmen wird. Wir bei der HUK-COBURG sind jedenfalls sicher, dass wir, auch mit Telematik Plus, sehr gut auf die Herausforderungen der Zukunft in der Kfz Versicherung eingestellt sind.

8. Selbstlernende KI zur Unterstützung des Underwritings in der Industrierversicherung

Dr. Christoph Carl Kling

Der Begriff der künstlichen Intelligenz (KI) ist in aller Munde. Da die Definition von (künstlicher) Intelligenz schwierig ist, wird KI oft anhand von spektakulären Beispielen verstanden – etwa anhand von Schachcomputern und selbstfahrenden Automobilen. Viele dieser Beispiele basieren auf automatisierten Vorhersagen und Entscheidungen, also auf Methoden des maschinellen Lernens. Diese Methoden nutzen eine große Anzahl von Entscheidungen aus der Vergangenheit, um Muster zu erkennen und mit diesen Entscheidungen in der Zukunft zu automatisieren.

Ein Blick auf den Call for Papers der aktuellen deutschen KI-Konferenz (KI 2019) zeigt aber, dass es dutzende weitere Themengebiete gibt, die der KI zugerechnet werden. Eines dieser Gebiete ist die automatisierte Erkennung von Bedeutung in Texten (Text Mining). Diese Methoden machen sich Wittgensteins Definition von Bedeutung zunutze: Meistens liegt die Bedeutung eines Wortes in seiner Verwendung. Die Bedeutung eines Wortes kann unter anderem durch die Wörter, mit denen es gemeinsam verwendet wird, erkannt werden. Betrachtet man eine Menge an Zeitungsartikeln, so fällt beispielsweise auf, dass Wörter wie Bank, Finanzen, Wachstum, Prozent oder Politik, Wahl, Parlament, Abstimmung jeweils häufig gemeinsam zusammen auftreten. Diese Mengen von häufig gemeinsam auftretenden Wörtern lassen sich automatisiert erkennen und können als Themen interpretiert werden. Sie werden daher englisch Topics genannt. Texte können Topics, und dadurch Bedeutungen zugeordnet werden – und das selbstlernend!

Eine Anwendung automatisierte Erkennung von Bedeutung ist die Unterstützung komplexer Entscheidungen.

Underwriter von Industrierversicherungen bestimmen kundenindividuelle Risiken und Versicherungsprämien. Dafür stehen ihnen nur wenige Informationen zur Verfügung: Ausschreibungsdokumente des Versicherungsnehmers, Guidelines und Tarif, sowie Erfahrung zu Risiken und Markt. Dieser Mangel an Informationen führt zu suboptimalen Prämienentscheidungen: Aus Gesprächen mit Versicherern und Maklern wissen wir, dass zwischen dem günstigsten und zweitgünstigsten Prämienangebot regelmäßig 10-20% liegen. Noch größere Abweichungen wurden beobachtet, wenn Marktteilnehmer aggressiv in neue Marktbereiche drängen. Diese Abweichungen verursachen alleine in Deutschland entgangene Gewinne in dreistelliger Millionenhöhe für Industrierversicherer.

Mit Hilfe von künstlicher Intelligenz können Assistenten für Underwriter dabei helfen, Prämien besser festzulegen, indem sie bei Industrierversicherern vorhandenes Wissen zu Markt und Risiken sichtbar machen. Dazu erkennt eine KI automatisiert Themen in Ausschreibungs-Dokumenten für Versicherungen im Industriebereich. Underwriter bekommen zu einer Ausschreibung ähnliche Ausschreibungen und Prämienangebote aus Archiv und Bestand angezeigt. Für Entscheidungen wichtige Begriffe und Kennzahlen werden extrahiert und visualisiert.

Hierdurch können Angaben und Kennzahlen einer Ausschreibung mit ähnlichen Ausschreibungen verglichen und Risiken besser eingeschätzt werden. Vergangene Prämienangebote zu ähnlichen Ausschreibungen und deren Erfolg sind wertvolle Marktinformationen. Beides hilft Underwritern, Prämienhöhen optimaler zu bestimmen.

Die Entwicklung von maßgeschneiderten Methoden der künstlichen Intelligenz für spezielle Teilbereiche der Versicherungsindustrie ist mit hohem Aufwand verbunden. Trotz des hohen

Potentials für eingesparte Opportunitätskosten in dreistelliger Millionenhöhe alleine auf dem deutschen Markt ist es für Versicherer immer noch attraktiv, mit deutlich geringerem finanziellen Aufwand mit KI vorhandene Prozesse effizienter zu gestalten um Arbeitszeit einzusparen. Dass die Verbesserung von Entscheidungen im Industriebereich mit Umsätzen in Milliardenhöhe eine sinnvollere Strategie ist, dürften die nächsten Jahre zeigen. Industrieversicherer, die ihre Daten systematisch nutzen, um aus vergangenen Entscheidungen zu lernen, dürften ihren Wissensvorsprung zu nutzen wissen und könnten andere Teilnehmer mittelfristig vom Markt verdrängen.

Gleichzeitig bieten Assistenten für Underwriter das Potential, das Wissen aller Underwriter innerhalb eines Versicherers besser zu kombinieren und dadurch den Beruf des Underwriters aufzuwerten. Künstliche Intelligenz automatisiert also nicht nur menschliche Arbeitskraft, sondern macht hochspezialisierte Expertinnen und Experten sogar noch wichtiger für den Unternehmenserfolg.

Wer KI lediglich als Mittel begreift, um menschliche Arbeit zu automatisieren, dürfte von den Entwicklungen der nächsten Jahre überrascht werden.

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, 7/2020
ISSN (online) 2192-8479

Herausgeber Prof. Horst Müller-Peters, Prof. Dr. Jan-Philipp Schmidt, Prof. Dr. Michael Völler

Revolutionieren Big Data und KI die Versicherungswirtschaft?
24. Kölner Versicherungssymposium am 14. November 2019

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. Michael Völler

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 8275-3712

Fax +49 221 8275-3277

Mail michael.voeller@th-koeln.de

Web www.ivw-koeln.de

Prof. Horst Müller-Peters

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 8275-3547

Fax +49 221 8275-3277

Mail horst.mueller-peters@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

- 06/2020 Schmidt: Künstliche Intelligenz im Risikomanagement, Proceedings zum 15. FaRis & DAV Symposium am 6. Dezember 2019 in Köln
- 05/2020 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, Rohlfs: 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 Fehlwahrnehmung von Alltagsrisiken in der Öffentlichkeit (erscheint 2017)
- 11/2016 Heep-Altiner, Penzel, Rohlfs, 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 Rohlfs (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, Rohlfs, 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, Rohlfs: 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 Langlebigerisikos. 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, Rohlfs: 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