

DAS WIRTSCHAFTSMAGAZIN ZUR DIGITALISIERUNG

# DIGITALE WELT

SCIENCE MEETS INDUSTRY

Ausgabe 4 • Oktober • November • Dezember • 2019

## Artificial Intelligence – Wie Algorithmen Maschinen zum Leben erwecken

**73** Seiten  
Experten-  
beiträge  
zu AI

### Grundlagen

AI einfach erklärt

### Fachbeiträge

Über Machine-Learning,  
Deep-Learning und NLP

### Use Cases

Von Chatbots über  
Healthcare bis Fintech

### AFFECTIVE COMPUTING

Die vier Stufen  
emotionaler Intelligenz



Der Flughafen  
München-CIO über  
Artificial Intelligence  
an Flughäfen

**Michael Zaddach**

# WENN IHRE IT-SICHERHEIT VERSAGT, DANN AM BESTEN BEI UNS.

Egal ob für **Cyber Security Trainings, PoCs, immersive Workshops** oder **beeindruckende Präsentationen**:

Wir richten uns von der IT-Infrastruktur bis zur Software auf Sie ein.

Erleben Sie IT-Security **real life** und **hands-on** in Deutschlands modernstem und vielseitigstem **IT-Schulungs- und Event-Zentrum** direkt am **Flughafen München**.

# ISH

Information Security Hub

ISH - Information Security Hub  
Flughafen München GmbH  
Südallee 1, 85356 München

ish@munich-airport.de

ish-muc.com

Besuchen Sie uns auf der  
**DIGICON 2019**  
20. - 21. Nov.  
Palais Lenbach  
München

Ein Angebot des

# M



# 10

**HINTER DEN KULISSEN**  
Wie intelligent ist das Auto der Zukunft?

# 20

**ARTIFICIAL INTELLIGENCE**  
Wie Algorithmen Maschinen zum Leben erwecken

### DIGITALER MARKTPLATZ

9 **Digitalisierung in Zahlen** | Fakten, die überraschen

### HINTER DEN KULISSEN

10 **Mercedes-Benz** | Wie intelligent ist das Auto der Zukunft?

### VERY DIGITAL PERSON

16 **Michael Zaddach** | Wenn der Himmel denkt

### 20 WISSEN – Artificial Intelligence

#### WISSENSCHAFTLICHE FACHBEITRÄGE

22 **Sabrina Brill** | Deep Learning in der Textverarbeitung

26 **Christopher Koska** | Blackbox AI – State Regulation or Corporate Responsibility?

30 **Prof. Dr. Kristian Kersting** | Maschinelles und Tiefes Lernen: Der Motor für „KI made in Germany“

33 **Dr. Peter Kullmann** | KI-Systeme im produktiven Unternehmenseinsatz

38 **Svenja Oprach** | Building the Future of the Construction Industry through Artificial Intelligence and Platform Thinking

43 **Prof. Michel Barbeau** | Recognizing Drone Swarm Activities: Classical versus Quantum Machine Learning

#### AI-GRUNDLAGEN EINFACH ERKLÄRT

49 **Dr. Thomas Franz** | Künstliche Intelligenz: Lernen und lernen lassen

51 **Franz Kögl** | So lernen Maschinen beim Machine Learning

53 **Jürgen Wirtgen** | Künstliche Intelligenz: Möglichkeiten und Grenzen

54 **Dr. Wolfgang Thronicke** | Was heute besser als mit Katzenbildern geht

#### SOCIAL IMPACTS & THE FUTURE

56 **Jörg Doeblér** | Wie KI unsere Gesellschaft verändert: Worauf es jetzt ankommt

58 **Markus Dohm** | KI gehört die Zukunft, sie braucht aber Regeln

61 **Igor Ilunin** | Wie künstliche Intelligenz unsere Lebensbedingungen beeinflusst

61 **Michaela Tiedemann** | Machine Learning und die Zukunft des Menschen in der Arbeitswelt



**16** VERY DIGITAL PERSON  
Michael Zaddach



**86** SZENE  
München

- ZUR TECHNOLOGIE**
- 62 **Eberhard Hechler** | Auf dem Wege zur Demokratisierung des Maschinellen Lernens
  - 64 **Dr. Sandra Lemmer** | Wie Künstliche Intelligenz und Algorithmen das Innovieren revolutionieren
  - 65 **Prof. Dr. habil. Imre Koncsik** | Topologische komplexe Informationsverarbeitung in neuronalen Netzen
  - 67 **Dr. Christoph Goller** | Natural Language Processing punktet vor allem bei Textsuche, -klassifikation und -analyse
- AFFECTIVE COMPUTING**
- 70 **Dr. Marco Maier** | Was ist Affective Computing?
  - 70 **Lilian Schröder** | Was macht ein Gebäude intelligent?
  - 71 **Michael Bartl** | Step Up! Die vier Stufen Emotionaler Intelligenz
- USE CASES**
- 72 **Markus Mayer** | Instrumente der Zukunft: Software-Roboter-gesteuerte Prozessautomatisierung (RPA) und Künstliche Intelligenz (KI) als wichtige Wettbewerbsfaktoren
  - 75 **Holger Hornik** | So profitieren Unternehmen von KI-Chatbots

- 76 **Britta Hilt** | Vorausschauende Produktion: Kosten reduzieren, Ausfälle verhindern und Produkte nachhaltig verbessern
- 79 **Alexander Eser** | Machine Learning & Healthcare: Wie Algorithmen Krankenkassenbeiträge fairer gestalten können
- 81 **Matthias Koeplin** | Herausforderungen für Machine Learning in der Abschlussprüfung
- 83 **Xavier Guerin** | (K)IQ-Test für Banken: Technologie für Kundenbindung

- SZENE**
- 86 **München** | Digitale Stadt München e. V.

- KOLUMNEN**
- 13 **Marcus Raitner** | Irrwege der agilen Transformation
  - 15 **Petra Bernatzeder** | Gewohnheiten ändern – aber wie?
  - 85 **Uwe Walter** | Wie China an allen vorbeizieht

- IMMER DABEI**
- 7 **Editorial** | Prof. Dr. Paul Lukowicz
  - 89 **Fachbeirat**
  - 89 **Impressum**
  - 90 **Call for Contribution**

Die nächste DIGITALE WELT erscheint am 04.12.2019

Foto: Pashkova/Shutterstock, Dammier A.G., Privat, Digitale Stadt München e.V., Tinel, Pashkova/Shutterstock, Privat

digitalweltmagazin.de/digicon

# DIGICON 2019

Buy your ticket now!

## DIGITALE WELT CONVENTION

Use the code DIGITALEWELT10 to get a 10% discount

Science meets Industry

20<sup>TH</sup> - 21<sup>ST</sup> NOVEMBER 2019  
Palais Lenbach, Munich



**ARTIFICIAL INTELLIGENCE –**  
With cognitive technologies to autonomous systems

### OUR TOP SPEAKERS



**Prof. Dr. Elisabeth André**  
Chair of Human-Centered Multimedia, Augsburg University



**Dr. Andreas Antrup**  
Managing Director of Marketing and Vice President of Advertising, Zalando



**Dr. Stefanie Babst**  
Head of the Strategic Analysis Capability, NATO



**Thomas Bönig**  
CDO and Head of IT, City of Munich



**Marcus Hartmann**  
CEO and CDO, ProSiebenSat.1 Media SE and ProSiebenSat.1 Digital Data GmbH



**Dr. Markus Heyn**  
Member of the Management Board, Robert Bosch GmbH



**Prof. Dr. Paul Lukowicz**  
Head of the Research Department Embedded Intelligence, DFKI



**Daniel Mattes**  
Entrepreneur and Founder, AI-42 Market Intelligence Ltd.



**Dr. Dieter Nirschl**  
Managing Director, ADAC



**Jean-Paul Schmetz**  
Chief Scientist and CEO, Hubert Burda Media and Cliqz GmbH



**Dr. Ralf Schneider**  
CIO, Allianz SE



**Michael Sen**  
Member of the Management Board, Siemens AG

... and about 30 more

Marketing Input for  
Business Output

# FELDM

## Happy Customers, Happy Business. We use data and analytics to make it happen.

- Data Strategy & Advanced Analytics
- Marketing Attribution & Media Mix Modeling
- Onsite Personalization & Recommendation Systems
- Analytical CRM
- Digital Analytics
- KPI & Reporting Systems
- Dashboards & Visualizations
- Conversion Rate Optimization
- Data Integration & Architecture
- Customer Journey Mapping
- User Research & User Experience Design
- Multi-Channel Communication and Sales Concepts

[www.feld-m.de](http://www.feld-m.de)

Und treffen Sie uns persönlich auf der  
Digitale Welt Convention DIGICON2019

[www.digitaleweltmagazin.de/digicon](http://www.digitaleweltmagazin.de/digicon)



### PROF. DR. PAUL LUKOWICZ

Prof. Dr. Paul Lukowicz (born in 1967) has been Scientific Director and Head of the Research Unit “Embedded Intelligence” at the German Research Center for Artificial Intelligence (DFKI) in Kaiserslautern since 2011.

Paul Lukowicz studied computer science (Dipl. Inform.) and physics (Dipl. Phys.) at the University of Karlsruhe, where he received his PhD in 1999 on opto-electronic computer architectures. During his subsequent work at ETH Zurich, he established the Wearable Computer Group at the Institute of Electronics between 1999 and 2004. In October 2003 he was appointed Professor of Computer Science at the Private University for Health Sciences, Medical Informatics and Technology in Hall in Tyrol (UMIT). Three years later he accepted an appointment at the University of Passau, where he headed the Chair of Applied Computer Science with a focus on Embedded Systems and Pervasive Computing. In 2011 Paul Lukowicz accepted the call to the TU Kaiserslautern and since then he has been head of the newly founded research area “Embedded Intelligence” at DFKI. Since 2014 he also manages the DFKI SmartCity Living Lab.

His research focuses on cyber-physical systems, pervasive computing and social interactive systems.

## The Challenge of Human Centric AI

The notion of “Human Centric AI” increasingly dominates public AI debate in Europe<sup>1</sup>. It postulates a “European brand” of AI beneficial to humans on both individual and social level that is characterized by a focus on supporting and empowering humans as well as incorporating “by design” adherence to appropriate ethical standards and values such as privacy protection, autonomy (human in control), and non-discrimination. Stated this way (which is how it mostly appears in the political debate) it may seem more like a broad, vague wish list than a tangible scientific/technological concept. Yet, on a second glance, it turns out that it is closely connected to some of the most fundamental challenges of AI [1].

First of all consider the notion of “supporting and empowering” humans in the context of privacy protection and autonomy. Today a broad range of AI assistants exists: from smart loudspeakers through recommender systems, intelligent search engines and personalized news services to professional assistance systems e.g. for industrial applications. All of them struggle with privacy concern as most of the underlying Machine Learning (ML) techniques critically depend on having as much training data as possible. Thus, the ability to learn from as little data as possible, just as humans do, which is a core fundamental research question of ML [5], is also an essential component of the vision of Human Centric AI. Related is the problem of distributed, collaborative learning that does not require centralized collection of large amounts of possibly sensitive data.

Beyond privacy today’s AI assistants also run into fundamental limits with respect to the notions of “empowerment” and autonomy. Empowerment and autonomy imply that a system should help users make more informed decisions, pursue their own agendas more efficiently, and build up their own differentiated opinions. In other words systems should be able to truly, constructively elaborate and explore issues

with human users. By contrast today’s AI systems mostly provide the users with a limited set of recommendations to choose from, or collect and filter information, or try to prevent users from doing what the system considers as mistakes. In most cases the system reaches its decision in a “black box” like manner which the user has no way of understanding or arguing with. Thus, in a way, today’s systems are largely prescriptive and autonomy constraining rather than empowering and truly supportive. To change this AI systems must gain the ability to develop a differentiated understanding of human lines of reasoning, relate to human motivations, emotions, moral assumptions and implications in this reasoning, help human partners challenge their own assumptions as well as provide simulations with consequences and explain alternate “AI angle” on seeing the problem. They must be able to make their own reasoning transparent to the user and anchor it within complex differentiated world models grounded in both the physical reality and the user’s subjective perception of reality.

Transparency and explainability of ML systems together with the ability to reason within complex, differentiated world models are also core concerns when it comes to the adherence to ethical standards, fairness, and non discrimination. Thus, AI systems increasingly support or even make decision that have grave personal and/or social consequences. Examples are judges, doctors, policy-makers or managers who more and more rely on AI decision support or even decision making systems. The ability to challenge such decisions when they have impact on a person’s life is a fundamental ethical concern that can not be satisfied when the decisions are influenced or even directly made by a “black box” like AI system. Instead the AI systems must be able to translate their computation into an explanation that is accessible to a non expert. Such translation between the complex AI model

and related computation and simple non expert mental model anchored within a user's subject world view goes far beyond current state of the art in explainable ML [4].

Fairness and non discrimination are further issues where AI systems need to relate their own computation models to complex world models and the way humans perceive and judge real world situations. The problem is that, in most cases, discrimination and bias do not arise as a result of any objective errors in the respective AI algorithms. Instead, the systems do what they were designed to: build models based on patterns contained in the training data. Unfortunately training data often reflect social bias and unfairness of the real world which the system incorporates and often amplifies. To avoid this the systems must be able to go beyond mere statistical analysis and numerical optimization and relate the data to world models that reflect human ethical and moral values [6]. In a way it requires that the systems do not discover the actual statistical properties of the data but adjust what they discover according to what is desirable from an ethical/social point of view. Give the vagueness and fluidity of such an adjustment (we do not want the system to fully ignore the data and just produce outcomes that we like) this will in general not always be a fully automated process. Instead humans must be able to accompany and guide the learning process and specify high level boundary conditions and optimization goals. This goes beyond explainable ML towards the notion of interactive ML [2,3] where the learning process is a "co-creation" between the user and the AI.

In summary the notion of Human Centric AI should not

be seen as a potential regulatory roadblock to AI research but rather as a challenge involving basic open AI problems such as:

1. Comprehensive world models that, in their scope and level of sophistication, should strive for human-like world understanding
2. "Interactive AI" that allows humans to not just understand and follow the learning and reasoning process, but also to seamlessly interact with it and guide it.
3. Understanding and naturally interacting with humans and complex social settings within dynamic open world environments.
4. Reflexivity and expectation management

The above research challenge is at the core of the Humane AI initiative<sup>2</sup> which combines nearly 50 European AI labs of high renown in the effort to make the vision of Human Centric AI a reality.

References: [1] Nowak, Andrzej, Paul Lukowicz, and Pawel Horodecki. "Assessing Artificial Intelligence for Humanity: Will AI be the Our Biggest Ever Advance? or the Biggest Threat [Opinion]." IEEE Technology and Society Magazine 37.4 (2018): 26-34. [2] Amershi, S., Cakmak, M., Knox, W. B., & Kulesza, T. (2014). Power to the people: The role of humans in interactive machine learning. AI Magazine, 35(4), 105-120. [3] Abdul, Ashraf, et al. "Trends and trajectories for explainable, accountable and intelligible systems: An hci research agenda." Proceedings of the 2018 CHI conference on human factors in computing systems. ACM, 2018. [4] Samek, Wojciech, Thomas Wiegand, and Klaus-Robert Müller. "Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models." arXiv preprint arXiv:1708.08296 (2017). [5] Snell, Jake, Kevin Swersky, and Richard Zemel. "Prototypical networks for few-shot learning." Advances in Neural Information Processing Systems. 2017. [6] Moor, James H. "The nature, importance, and difficulty of machine ethics." IEEE intelligent systems 21, no. 4 (2006): 18-21  
<sup>1</sup> <https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai>  
<sup>2</sup> <https://www.humane-ai.eu/>

Foto: Privat

# DIE IS4IT GRUPPE

## EINE STARKE IT-MANNSCHAFT AUF EINEM SPIELFELD VOLLER MÖGLICHKEITEN!

- BERATUNG
- CLOUD
- RECHENZENTRUM & INFRASTRUKTUR
- INFORMATIONSSICHERHEIT
- ANWENDER-SUPPORT
- WORKPLACE MANAGEMENT

**IS4IT**

IS4IT GmbH  
 Grünwalder Weg 28b  
 82041 Oberhaching  
 Deutschland  
 telefon +49 89 6389848-0  
 info@is4it.de

**IS4IT KRITIS**

IS4IT KRITIS GmbH  
 Kraftwerkstraße 1  
 74847 Obrigheim  
 Deutschland  
 telefon +49 6261 31944-0  
 info@is4it-kritis.de

**CyDIS** CYBER DEFENSE AND INFORMATION SECURITY

CyDIS Cyber Defense and Information Security GmbH  
 Grünwalder Weg 28b  
 82041 Oberhaching  
 telefon +49 89 2488207-41  
 info@cydis.de

**itsa 2019**  
 08.-10. Oktober 2019

Halle 10  
 Stand 311

**kick IT**  
 DAS TOP-TEAM IN DER SECURITY-LIGA

# DIGITALISIERUNG

## in Zahlen

Laut einem Bericht von CompTIA nutzen nur

**29 %**  
 der US Unternehmen regulär Künstliche Intelligenz.

In über **90 %** aller neuen Softwareprojekte wird Open-Source eingesetzt.

Der Umstieg der südkoreanischen Regierung von Windows 7 auf Linux wird vermutlich ca.

**780 Milliarden Dollar** kosten.

Die aktuell performantesten Chipsätze für Smartphones sind in etwa

**7 Nano-meter** groß.

Laut Statista wird das globale Einkommen durch Künstliche Intelligenz in 2025 auf

**90 Mrd. US Dollar** geschätzt.

Die US-Army hat mit Microsoft einen Vertrag abgeschlossen, um das Militär mit HoloLens Headsets auszustatten.

**480 Mio. US Dollar**

Die weltweiten Ausgaben für IT-Security werden in 2019 laut Gartner

**124 Mrd. Dollar** übersteigen.

Das Training und Tuning von gängigen Sprachverarbeitungsmodellen mittels Deep Learning verursacht etwa

**280.000** Tonnen an Kohlen-dioxidemissionen.

**77 %** der Java Open-Source-Anwendungen enthalten mindestens eine sicherheitskritische Schwachstelle.

Das Quantum Computing Startup Riverline der Universität Cambridge erhält ein Startkapital von **3,25 Millionen Pfund.**



Das Forschungsfahrzeug Mercedes-Benz F 015 Luxury in Motion im Stadtverkehr der Zukunft.

# Wie intelligent ist das Auto der Zukunft?

Ein Auto, das Sie mit einem schlichten, aber galant-seriösen „Hallo“ begrüßt, dann nach dem Starten des Motors Ihre Lieblingsmusik von selbst abspielt, nachdem es mit Ihrem Smartphone eine Bluetooth-Verbindung hergestellt hat, und schließlich zur gewohnten Zeit – etwa auf halber Strecke Ihres täglichen Nachhausewegs – Ihre Frau anruft. Unsere Autos von heute denken. Mit uns und für uns. Dr. Steven Peters beschäftigt sich als Leiter des Daimler-Forscherteams „Artificial Intelligence Research“ mit der Frage nach der Einbindung künstlicher Intelligenz in das Auto von morgen.

**„Künstliche Intelligenz“ ist ein Begriff, der schon seit Jahrzehnten im Umlauf ist und manchmal unterschiedlich gebraucht wird. Was bedeutet für Sie künstliche Intelligenz?**

In der Tat ist die genaue Definition nicht klar. „KI“ – also „künstliche Intelligenz“ – ist ein Begriff, der seit mittlerweile fast 70 Jahren in der Welt ist und inzwischen viele unterschiedliche Anwendungsmethoden zusammenfasst. Die zum Teil divergierenden Begriffsdefinitionen sind eine Konsequenz daraus. Ich fokussiere mich in unserer Arbeit und in meinen Vorträgen immer auf Machine Learning – wohl wissend, dass das nur eine Teilmenge von KI ist. Obwohl dieser Teilbereich nicht neu ist, ist Machine Learning zurzeit das, was am dynamischsten und deshalb für uns am attraktivsten ist. Wiederum eine Teilmenge von Machine Learning ist das Deep Learning, was Dinge wie autonomes Fahren überhaupt erst möglich macht. Diese beiden Bereiche werden in der Presse in der Regel mit „KI“ gleichgesetzt und spielen auch für unsere Anwendungsbereiche eine entscheidende Rolle.

**Wie hängen Digitalisierung und künstliche Intelligenz zusammen?**

KI ist ein Werkzeug. Ein Werkzeug, das in Zusammenhang mit der Digitalisierung gebraucht wird, um die Ziele, die mit der digitalen Transformation einhergehen, zu erreichen. KI ist zugleich aber keine Allzweckwaffe, sondern lediglich ein weite-

res Werkzeug. Das kann ich beispielsweise dafür verwenden, um meine internen Prozesse schneller oder besser zu machen oder um Komplexität in Arbeitsabläufen oder anderen Prozessen rauszunehmen. Ich kann KI natürlich auch zum Einsatz bringen, um neue Produktfeatures zu realisieren. So treffen sich Digitalisierung und KI etwa in der Sprachsteuerung oder in der Funktionsweise hochautomatisierter bzw. vollautomatisierter Fahrzeuge.

**Also ist KI auch ein Werkzeug der Automobilindustrie. Wo wird KI heute schon eingesetzt?**

Für unseren Bereich ist KI ein verhältnismäßig junges Werkzeug, das uns viele neue Möglichkeiten bietet. Wir können damit unsere eigenen Prozesse verbessern, die von der Entwicklung bis zu Produktion und Vertrieb reichen. Wir verwenden KI aber auch, um neue Fahrzeugkonzepte zu realisieren oder arbeiten mithilfe von KI an lukrativeren Geschäftsmodellen. Künstliche Intelligenz wird für alle Arbeitsschritte zur Anfertigung bis zum Verkauf eines Autos gebraucht.

Ein konkretes Beispiel für den alltäglichen Anwendungsfall von KI: Wenn Sie mittwochabends immer nach Hause fahren und in dieser Zeit Ihren Bruder anrufen, dann wird Ihnen das vom Auto schon vorgeschlagen. Solche Anwendungen von KI sind schon in Serie. Auch andere Assistenzsysteme wie der Fußgängerbremsassistent, bei dem Daimler Vorreiter war, beruhen auf KI. Diese Anwendungsmöglichkeiten von KI und deren

**„KI ist ein Werkzeug, das gebraucht wird, um die Ziele der digitalen Transformation zu erreichen.“**

Umsetzung werden weiterhin steigen.

Die Arbeit mit künstlicher Intelligenz hat mir gezeigt, dass sie als Werkzeug universal einsetzbar ist. Es ist nicht so, dass KI nur für autonomes Fahren gebraucht würde, nein, wir können KI in allen Entwicklungsbereichen nutzen: von der Aerodynamik bis zur Motorenentwicklung, über Assistenzsysteme, Telematik und User-Experience.

**Was konnten Sie in Ihrem Forscherteam schon Praktisches für den gegenwärtigen Autobau umsetzen? Wie überwinden Sie die Diskrepanz zwischen Forschung und konkreter Anwendung Ihrer Ergebnisse?**

Wir sind in der Konzernforschung von Daimler als eine Keimzelle installiert, die für die gesamte Entwicklung der Ansprechpartner ist, wenn es darum geht, Machine Learning in Anwendung zu bringen, wo es heute noch nicht möglich ist. Es geht uns nicht um eine Einführung von KI-Standardlösungen. Vielmehr besteht unser Ziel darin, Anwendungen von KI zu entwickeln, die es noch nicht gibt.

Ein Beispiel: Wir können in einer ganz frühen Phase der Motorenentwicklung, wo es um das Design des Motors hinsichtlich des Ansaugens und der Verbrennungsgestaltung geht, den Entwickler mit Machine Learning unterstützen. In unserem Team arbeiten wir gemeinsam mit den Motorenentwicklern an Lösungen, die für sie in der täglichen Arbeit einen konkreten Nutzen bringen.

Neben unserer Hauptaufgabe, Machine Learning für unsere Anwendungsdomäne weiterzuentwickeln, sind wir in der Konzernforschung breit aufgestellt: von Trucks, Bussen, Vans bis zu AMG und Formel 1. Überall gibt es Anwendungen. Wenn man sich Geschäftsmodelle ansieht wie SHARE NOW, dann hängen



### Steven Peters

Dr.-Ing. Steven Peters, Jahrgang 1987, trat im Februar 2016 in die Konzernforschung der Daimler AG ein. Zuvor war er Oberingenieur am Karlsruher Institut für Technologie (KIT) und von 2014-2015 zusätzlich KIT-Industry Fellow der Daimler AG. In der zentralen Forschung der Daimler AG baut er seit April 2017 das neue Team „Artificial Intelligence Research“ auf. Der Forschungszweig beschäftigt sich mit der Integration künstlicher Intelligenz in alle Einzelbereiche der Fahrzeugentwicklung. Diese interdisziplinäre Aufgabe, die eine Verbindung zwischen Forschung und konkreter Einzelanwendung anstrebt, fusioniert AI-Algorithmiker, Funktionsentwickler, Psychologen, Designer und oft auch Juristen.

solche Konzepte stark davon ab, wo und wann ich welche Fahrzeuge in welcher Menge benötige. Hier ist KI der zentrale Enabler für einen erfolgreichen Business Case.

**Die intelligente Maschine von morgen könnte also auch dabei helfen, ökologisches Fahren zu optimieren?**

Selbstverständlich! Das ist ein Beispiel von vielen. Ich kann künstliche Intelligenz nutzen, um den Verbrauch und die Emissionen zu minimieren; ich kann KI aber auch nutzen, um die Qualität des Fahrerlebnisses zu steigern. Dabei steht für uns im Vordergrund, Komfort, Sicherheit und emissionsfreies Fahren mithilfe von KI zu realisieren.

**Wie sieht Ihr Auto der Zukunft aus?**



**Das Forschungsfahrzeug von Daimler zeigt dem Passanten über einen virtuellen Zebrastrreifen an, dass er die Straße gefahrlos überqueren kann.**

Unsere Forschungsfahrzeuge haben schon gezeigt, wo die Reise hingehen soll. Da war schon eine Menge KI im Einsatz. Insgesamt geht es uns um emissions- und unfallfreies Fahren, das den Fahrer eines KI-ausgestatteten Fahrzeugs in den Mittelpunkt stellt. Wenn wir an den Kunden im Fahrzeug denken, dann bleibt zentral, dass ich für ein Fahrerlebnis Sorge, das möglichst einzigartig ist und mit unserer Philosophie einer Mercedes-Benz-Experience zusammenpasst. Wir wollen zum Beispiel nicht, dass das Auto irgendetwas macht, was für den Fahrer nicht nachvollziehbar ist. Der Kunde muss selbstwirksam bleiben; es ist wichtig, dass er versteht, warum etwas passiert. Letztendlich geht es um Transparenz und Nachvollziehbarkeit. Der Kunde soll aussteigen und seine Fahrt kommentieren: „Das war ein gutes Erlebnis!“

**Wie stehen Sie zu ethischen Aspekten der KI? Wer ist verantwortlich, wenn die Maschine nicht das macht, was sie machen soll?**

Ganz klar: Zum einen fängt das schon in der Entwicklung von solchen Verfahren an, indem entsprechende Qualitätsstandards in der Entwicklung von KI etabliert werden. Das ist der technische Aspekt der Frage. Zum anderen ist das ethische Thema für uns ein sehr großes, das wir im Konzern sehr stark mit Psychologen, Designern, Juristen und auch im Dialog mit der Gesellschaft diskutieren, das aber auch unternehmensübergreifend in Gremien organisiert wird. Das kommt sehr stark auf die Use-Cases an: Wenn ich einem Mitarbeiter ein Assistenzsystem anbiete, das ihn bei der Arbeit entlastet, er aber die letztendliche Entscheidung trifft, dann ist das eine ganz andere Ausgangslage als irgendwann ein System zu haben, das völlig autonom Entscheidungen trifft.

**Mit der zunehmenden Digitalisierung geht auch das Problem der Datenspeicherung einher. Wie stehen Sie dazu?**

Das sind zwei Dinge: Erstens muss der Kunde selbst bestimmen können, was mit seinen Daten passiert. Dazu muss er wissen, welche Daten in das System einfließen oder einfließen würden, wenn er in einen Datenaustausch einwilligt. Transparenz ist hier das Stichwort. Zweitens geht es um Datensicherheit im technischen Sinn. Wenn der Kunde einer gewissen Öffnung zu Daimler zugestimmt hat, dann müssen wir gewährleisten, dass wir sicher mit seinen Daten umgehen. Selbstbestimmung, Datentransparenz und Datensicherheit im technischen Sinne – diese drei Aspekte sind unser Ansatz, um den Kunden in den Mittelpunkt zu stellen.

**Kann neben dem Auto auch unser Verkehrssystem künstlich intelligent gemacht werden? Wie bewerten Sie den Einsatz und die Notwendigkeit von KI im allgemeinen Verkehrssystem?**

Künstliche Intelligenz außerhalb des Autos – da kann es nur ein Wort geben: selbstverständlich! Entwicklung, Produktion, Vertrieb – dort überall ist KI schon ein Thema. Was passiert in Richtung Verkehrssteuerung? Da träume ich jeden Morgen davon, wenn ich die Ampelsteuerung in Stuttgart erlebe, die mitunter sehr statisch und teilweise mit sehr veraltetem Equipment ausgestattet ist. Hier könnte man sehr viel Praktisches tun. In der Regel bräuchte man für den ersten Schritt gar nicht mal KI. Zuerst bräuchten wir eine vernetzte Infrastruktur, die Staus erkennt und eine entsprechende Ampelschaltung verbindet. Das gibt es in vielen modernen Städten im Ausland schon. Insgesamt reden wir hier aber von einem großen Feld, das eher ein Thema der Städte und Kommunen ist. Hier muss man abwarten, wie sich die Zusammenarbeit entwickelt. Auf alle Fälle gibt es in diesem Bereich viel Potenzial, denn auch hier greift die Logik, KI als Werkzeug zu gebrauchen, das für alle Branchen und auch für viele Administratoren und Infrastrukturmaßnahmen vielversprechend anwendbar ist.

**Wie sehen Sie den Zusammenhang zwischen KI und Quantencomputing (QC)?**

Der Quantencomputer ist eine ganz andere Baustelle, die vor dem Horizont von Machine Learning mit einer ganz anderen Skala zu bewerten ist.

Wir bei Daimler haben eine Forschungs-Kooperation mit IBM Research und Google Research. Wir sind da sehr aktiv. Es geht im Wesentlichen um Elektrochemie für zukünftiges Batteriezelldesign. Mein Team und ich sind in beiden Kooperationen engagiert. Wir wollen herausfinden, ob in einem mittel- bzw. langfristigen Horizont Vorteile im Machine Learning durch Quantencomputer erzielt werden können. Im Moment ist das noch sehr weit weg, trotzdem gehen wir das Themenfeld mit IBM und Google gemeinsam an. Wir wollen von Anfang an verstehen, was sich durch den Quantencomputer für unsere Prozesse ändern könnte. Man muss aber fairerweise dazu sagen, dass wir noch weit entfernt sind von konkreten Anwendungen. Die ersten tatsächlichen Realisierungen des Quantencomputers in der Autoindustrie werden nach meinem Kenntnisstand in der Elektrochemie vollzogen werden.



**Assistenzsysteme wie der Fußgängerbremsassistent sind ein praktikables Beispiel dafür, wie künstliche Intelligenz im Fahrzeug sinnvoll eingesetzt werden kann. Die reale Szene (Bild 1) wird zunächst gelabelt (Bild 2) und anschließend durch das Netzwerk interpretiert (Bild 3).**

**Neben elektrochemischen Anwendungen könnte ein Quantencomputer doch auch eine entscheidende Rolle in der Verkehrsanalyse spielen.**

Eine schöne Vorstellung, ich glaube aber, dass wir hier weit weg sind von konkreten Anwendungen. Das liegt daran, dass die großen Datenmengen mit den bestehenden Quantencomputern nicht verarbeitet werden können, weil wir nicht genug Qubits haben und weil die Fehlerquote der Qubits der Chips noch sehr hoch ist, was in einer solch frühen Phase, in der wir uns gerade befinden, völlig normal ist. Solche Anwendungen haben wir zwar auf unserer Roadmap, aber ich glaube nicht, dass wir hier in den nächsten Jahren Durchbrüche erzielen werden.

Die QC sind für elektrochemische Anwendungen so interessant, weil ich dort mit quantenphysikalischen Effekten rechnen muss. Ein Quantencomputer, der inhärent quantenphysikalisch arbeitet, schafft dort einen großen Mehrwert. Das ist das Vielversprechende daran.

Von Hannes Mittermaier

Fotos: Daimler AG

## Irrwege der agilen Transformation

Marcus Raitner arbeitet als Agile Transformation Agent und Agile Coach bei der BMW Group IT. In seinem Blog „Führung erfahren!“ schreibt er seit 2010 über die Themen Führung, Agilität, Digitalisierung und vieles mehr.



Nicht überall, wo Transformation in Leuchtbuchstaben draufsteht, ist auch Transformation drin. Es beginnt mit der irrigen Annahme, mit Agilität ließe sich die Mitarbeiterleistung wie mit Kraftfutter steigern. Fehlgeleitet von diesem Versprechen von mehr Effizienz, wird die Transformation dann aber umso überzeugter von oben angeordnet und bewährte Blaupausen (Spotify und Co.) werden ausgerollt. Das führt schließlich dazu, dass die bestehenden verkrusteten Strukturen und Abläufe „agilisiert“ werden, ohne sie konsequent zu hinterfragen. Am Ende bleibt kaum Transformation, sondern nur agiler Etikettenschwindel: Same same but different.

### Agiles Kraftfutter

Die agile Transformation hat bisweilen einen entscheidenden Geburtsfehler. Ein häufig anzutreffendes Missverständnis ist, dass Agilität als eine Art Kraftfutter die Mitarbeiterleistung steigert. Buchtitel wie „Scrum: The Art of Doing Twice the Work in Half the Time“ von Jeff Sutherland (ein im Übrigen lesenswertes und hilfreiches Buch) verleiten den geneigten Manager schnell zu diesem Fehlschluss und entwerfen die agile Transformation von Beginn an durch die einseitige Fokussierung auf Effizienz.

Mitarbeiter sind aber keine Milchkühe und agile Methoden sind kein Kraftfutter. Agilität optimiert nicht die Leistung der einzelnen Menschen, sondern die Leistung, den Wertstrom und die Wertschöpfung des gesamten Systems, in dem diese Menschen ihre Leistung erbringen.

Agilität zielt primär auf Effektivität und nicht auf Effizienz. Es geht darum, in unsicherem und komplexem Umfeld das Richtige zu tun, und nicht so sehr darum, bekannte und geplante Umfänge effizienter abzuwickeln. Der Fokus von Agilität liegt auf der schnellen Lieferung von Kundenwert. Einerseits natürlich, um schnell Wert zu generieren. Andererseits aber auch, um aus der Benutzung empirisch gestützte Erkenntnisse für die weitere Entwicklung zu gewinnen und sich so möglichst effektiv gemeinsam lernend dem Ziel anzunähern.

### Transformiert euch!

So verlockend Blaupausen auch erscheinen und so schön aktionistisch ihre Einführung im großen Stil auch aussehen mag, so sicher führt genau das die agile Transformation in eine Sackgasse. Die Management- und Führungsaufgabe in der agilen Transformation lautet nicht, das beste Modell einer

agilen Organisation aus der Vielfalt der Blaupausen auszuwählen oder ein eigenes zu konzipieren und das dann auszurollen. Dieser traditionell zentralistische Top-Down-Ansatz verletzt das zentrale agile Prinzip der Selbstorganisation, weil es die Menschen und Teams zu Objekten der Transformation degradiert, obwohl das Ziel autonome, selbstverantwortliche und aktive Subjekte auf Augenhöhe sein müssen.

Wer seiner agilen Transformation diese Sackgasse ersparen will tut gut daran, die Rolle des Schachmeisters an den Haken zu hängen und mehr wie ein Gärtner zu agieren. Ziel muss es sein, einen Rahmen zu schaffen, in dem ein geeignetes agiles Organisationsmodell nach und nach aus der Zusammenarbeit von selbstorganisierten Teams entsteht. Das ist ein gemeinsamer Lernprozess, der sich durch Blaupausen nicht abkürzen lässt. Wer es trotzdem versucht, führt dann eben nur ein neues Organisationsmodell ein und setzt eine Transformation um, agil ist dann aber weder das eine noch das andere.

### Same same but different!

Eine Schwalbe macht noch keinen Sommer und ein paar agile Projekte in hippen Räumen mit Sitzsäcken und Kanban-Boards noch keine agile Organisation. Agile Projekte führen nicht zu agilen Organisationen, wenn sie in verkrustete Strukturen und bürokratische Abläufe eingebettet sind – von der Genehmigung des Projekts bis zu den obligatorischen Lenkungsreisen. Und es reicht auch nicht, die schönen neuen agilen Methoden über diese Strukturen und Abläufe zu stülpen und sie irgendwie zu „agilisieren“. Im Wesentlichen bleibt so nämlich alles beim Alten, bloß anders: Same same but different.

Dem Gesetz des Werkzeugs – nach seinem Entdecker Abraham Maslow auch „Maslows Hammer“ genannt – zu erliegen und in allem einen Nagel zu sehen, bloß weil man den neuen agilen Hammer entdeckt hat, führt nur zu mäßig lustigem Cargo-Kult. Stattdessen lautet die Devise ganz klar „Entkalken vor Skalieren“. Gemeint ist damit, dass Strukturen und Abläufe nicht einfach einen agilen Anstrich bekommen dürfen, sondern konsequent im Sinne der Kundenorientierung und des Flusses im Wertstrom neu gedacht werden müssen.

Dr. Marcus Raitner

Das Buch zum Manifest für menschliche Führung. Erhältlich als Taschenbuch und E-Book bei Amazon



Foto: Privat



## GEWOHNHEITEN ÄNDERN – ABER WIE?

Stellen Sie sich bitte einen Ironman-Triathleten vor. Er schwimmt fast 4 Kilometer, dann radelt er mal eben 180 Kilometer und läuft zum krönenden Abschluss einen Marathon von 42 Kilometern. Und stellen Sie sich bitte vor, er würde dies mit seiner Lauf-, Schwimm- und Radfahrtechnik tun, die er sich als Kind angewöhnt hat. Vorbereitende Technik-Trainings mit Ruhephasen hat es nicht gegeben, die Strecken wurden einfach immer länger. In welchem Zustand, glauben Sie, kommt der Sportler, wenn überhaupt, ins Ziel?

Viele Menschen fühlen sich heute am Arbeitsplatz wie Langstreckenläufer im Hamsterrad, das sich immer schneller dreht. Und sicher haben sie viele Rituale entwickelt, die dazu beitragen, dass sie nicht aus dem Hamsterrad herausfliegen. Aber reicht das schon aus? In einigen Unternehmen gewinnt das Thema „bewusste Pausen, Achtsamkeit“ an Bedeutung. Trainingsprogramme werden gestartet, das Interesse wächst. Aber wie wird aus einem im Training ausprobierten Verhalten, z.B. einer Kurzmeditation, eine neue Gewohnheit?

### Die Wahrnehmung von Unterschieden ist der Schlüssel zur Veränderung

Wer liebgelebte Gewohnheiten im Alltag verändern will, braucht außerdem Neugier, Wissen, ein Ziel und Maßnahmen bei Rückfällen in alte Muster.

Wir unterscheiden beim Lernen von neuem Verhalten vier Stufen.

- Unbewusste Inkompetenz. Fahrschüler wissen zunächst gar nicht, was sie beim Kuppeln und Schalten genau motorisch leisten müssen, um das Auto in Bewegung zu bringen.
- Bewusste Inkompetenz. Nachdem das Auto zum dritten Mal „abgewürgt“ wurde, ist klar, dass Kuppeln und Schalten exakt abgestimmt werden müssen.
- Bewusste Kompetenz. Nach einigem Üben gelingt es immer häufiger, ohne Ruckeln wieder anzufahren.
- Unbewusste Kompetenz. Es ist ein automatisierter Prozess – Wahrnehmung und Motorik sind eingeschwungen. Die Aufmerksamkeit kann sich auf anderes richten.

Wenn wir dieses Modell auf die psychische Gesundheit übertragen, finden wir viel unbewusste Kompetenz. Die meisten Menschen verfügen über einen gut gefüllten Werkzeugkasten für den Umgang mit den täglichen Belas-

tungen, sonst wären weit mehr als 25% der Erwerbstätigen von psychischen Überbelastungen [1] betroffen.

Gleichzeitig finden wir in den vielen Gesprächen – sei es in Seminaren, Beratungen oder Coachings – einige weiße Flecken auf der Landkarte. Viele Menschen sind unbewusst inkompetent, selbst wenn es um einfache Zusammenhänge im Stressmanagement geht, wie z.B. der Einfluss der Gedanken auf die Leistungsfähigkeit unseres Systems.

Andere haben im Achtsamkeitstraining gespürt, wie angenehm der Fokus auf das „Hier und Jetzt“ ist. Aber so eine Methode in den Alltag zu integrieren, dazu „fehlt die Zeit“, so höre ich häufig.

Nutzen wir die Kurzmeditation als Beispiel für den Aufbau neuer Gewohnheiten, das auf andere Verhaltensweisen übertragen werden kann:

- Das Angebot von Trainings kann neue Türen öffnen. Ein erstes Erkennen, wie wirksam Kurzmeditation sein kann, und das Aufräumen von Vorurteilen – „Esoterik“ – schaffen den Einstieg.
- Über die persönliche Erfahrung von Unterschieden – wie geht es mir mit bzw. ohne Kurzmeditation im Alltag, wie leistungsfähig bin ich über den Tag, wie schalte ich abends ab? – entstehen Ziele, die die Motivation steuern.
- Mit einer kurzen täglichen Übungseinheit, die mit einem bereits vorhandenen Ritual verknüpft wird, entwickelt sich eine erste Routine. Beispielsweise direkt vor dem Frühstück drei Minuten Kurzmeditation einzuschieben. Über die wahrgenommene Wirkung verstärkt sich die Motivation, mehr Zeit zu investieren oder häufigere Rituale in den Alltag zu integrieren.
- Der Tagesablauf hat sich verändert, dies wird als normal erlebt. Gegebenenfalls hat die neue Gewohnheit, gerade im Beispiel Kurzmeditation, auch zu neuen Ritualen in der Familie oder im Arbeitsteam geführt. Entscheidend ist, zu Beginn gerade so viel Zeit einzuplanen, dass erste Effekte spürbar sind. Und es gilt, Vorhandenes mit Neuem möglichst einfach zu verknüpfen! Damit aus „guten Vorsätzen“ wirkliche Veränderung entsteht.

Dr. Petra Bernatzeder,

Diplom-Psychologin, Geschäftsführung upgrade human resources GmbH

Referenzen: [1] Wittchen, H-U. et al. (2011). The size and burden of mental disorders and other disorders of the brain in Europe 2010. European Neuropsychopharmacology 21, 655–679





## *Very Digital Person:* MICHAEL ZADDACH Wenn der Himmel denkt

**F**olgende Situation: Sie stehen am Eingang des Flughafens und suchen nach Ihrem Gate. Zuvor muss geklärt werden, von welchem Terminal aus Ihr Flieger überhaupt in die Luft geht und die Koffer eingecheckt werden können. Und eine Toilette in unmittelbarer Nähe wäre auch nicht schlecht. Seit gut einem Jahr antwortet am Flughafen München auf solche Fragen Josie Pepper, eine 1,20 Meter große und mit hell leuchtenden Kulleraugen ausgestattete Roboterfrau, die Ihnen mit ihrer sympathischen Stimme stets behilflich ist. Wenn die charmante Dame mit Ihnen spricht,

unterstreicht sie ihre Worte mit einem grünen Leuchten rund um ihre Augen. Außerdem bewegt sie ihre Arme, die mit menschenähnlichen Händen und Fingern ausgestattet sind, leicht hin und her, um ihrem Gesagten Nachdruck zu verleihen. Josie Pepper ist ein Meilenstein: Das erste Mal wird an einem deutschen Airport ein humanoider Roboter eingesetzt, der mit künstlicher Intelligenz ausgestattet ist und deshalb mit jeder Frage lernt. Michael Zaddach ist Senior Vice President IT des Flughafens München. Künstliche Intelligenz ist für ihn lange schon ein Thema für die moderne Luftfahrt.

**Wie geht man am Flughafen München mit dem Thema künstliche Intelligenz (KI) um?**

Es gibt noch keinen konkreten Anwendungsbereich, aber viele Ideen: An einem Flughafen treffen verschiedenste Prozesse aufeinander: Starten, Landen, Gepäckabfertigung, Passagierabfertigung, Transport, kommerzielle Dinge etc. Die Frage lautet: Wie kann ich optimale Reiseprozesse schaffen? Wie kann ich an einer Optimierung der derzeitigen Reiseprozesse arbeiten? Dies funktioniert nur, wenn ich die Gesamtheit der Prozesse, die an einem Flughafen zu bewältigen sind, vernetzt betrachte.



Neue verbesserte Sicherheitskontrollspur im Terminal 2



### Michael Zaddach

Michael Zaddach ist seit 2000 Senior Vice President IT der Flughafen München GmbH, die wiederholt als bester Flughafen Europas ausgezeichnet wurde – zuletzt 2019.

Seine Verantwortungsbereiche umfassen IT-Governance, IT-Sicherheit, Systementwicklung, Systembetrieb und die gesamte IT-Infrastruktur am Flughafen München. Nach Abschluss seines Studiums der Nachrichtentechnik arbeitete er bei Siemens, AEG und debis Systemhaus in verschiedenen Bereichen und Managementfunktionen, beispielsweise in den Bereichen Systementwicklung, Produktlinienmanagement und Beratung. Im debis Systemhaus leitete er einen Bereich für IT Service Consulting, in dem er mehrere Outsourcing-Projekte durchführte.

„Simulation“ und „Forecast“ sind die Stichworte. Weil diese Gesamtheit der zu berücksichtigenden Daten sehr komplex ist, sehe ich hier einen möglichen Anwendungsbereich für Quantencomputer. Denn: Sogenannte „real-time-Simulationen“ in diesem sehr stark vernetzten Umfeld – die das Ziel sein müssen – sind heute nicht oder nur sehr begrenzt möglich. Uns fehlt einfach die nötige Rechnerpower. Gerade dafür ist Quanten-Computing ein wichtiges Thema.

#### Können Sie diese Aspekte an einem konkreten Beispiel festmachen?

Nehmen wir einen klassischen Fall, der München jedes Jahr betrifft: die Wiesn. Das Oktoberfest in München bereitet dem Flughafen München das höchste Passagieraufkommen des Jahres. Tendenz steigend. Eine solche Datendiagnostik der Zukunft, die für unsere Prozesse am Flughafen München relevant wäre, müsste – nicht nur Daten der Vergangenheit – reale Bedingungen in der

gegenwärtigen und zukünftigen Vorhersage mit einbeziehen. Konkret: Aus welchen Gründen auch immer ist ein Stau auf der A8 entstanden. Was hat das für Konsequenzen für die Prozesse am Flughafen? Was passiert mit unseren Flügen in zwei Stunden? Es braucht eine dynamische Vorhersage, die nicht nur Daten aus der Vergangenheit, sondern eben Ist-Daten direkt auf die Zukunft beziehen kann. Meine Vision dahinter: Wir müssen einen digitalen Zwilling des Flughafens haben, der virtuell vorausdenkt, damit wir unsere Prozesse am realen Flughafen über die Modellfunktion des virtuellen anpassen können.“

haben, der virtuell vorausdenkt, damit wir unsere Prozesse am realen Flughafen über die Modellfunktion des virtuellen anpassen können.

**Wie groß soll diese mögliche Datenmenge sein? Stellt uns nicht die potenzielle Unendlichkeit der auszuwertenden Daten vor ein weiteres Problem? Ein Beispiel: Der Flieger aus New York, der Gäste nach München bringt, ist verspätet. Es gab einen Stau in Manhattan, der wiederum auf einem Unfall in einer Seitenstraße**



Die humanoide Roboterde Josie Pepper unterstützt Passagiere am Flughafen München

**basiert, der mit dem Ausfall einer U-Bahn begründbar ist, weil Unfallfahrer A durch das Ausbleiben der U-Bahn gestresst auf sein Fahrzeug ausgewichen ist.**

Klar, wo sind die Grenzen der Daten? Abflugzeiten von Flughäfen sind uns heute schon bekannt. Damit arbeiten wir schon, aber nicht mehr. Eine Berücksichtigung solcher Daten würde uferlos werden.

Innerhalb Europas gibt es bereits das Projekt „Single European Sky“, koordiniert von Eurocontrol. Das Ziel ist die komplette Vernetzung der Flüge in Europa. Größere Flughäfen ab einem bestimmten Passagieraufkommen sind verpflichtet, ihre Daten an Eurocontrol zu liefern. Eurocontrol versucht

damit, den Flugverkehr in Europa zu optimieren. In 15 Jahren rechnen wir weltweit mit einer Verdopplung des Flugverkehrs. Dies ist eine klare Botschaft, nach neuen Methoden Ausschau zu halten. Damit wir als Flughafen München Eurocontrol bessere Daten liefern können („besser“ im Sinne von quantitativ und qualitativ mehr, sprich etwa Umgebungsdaten und Rahmenbedin-

gungen), dafür ist Quanten-Computing wieder ein wichtiges Thema.

**Wie stünden Sie zu einer allgemeinen Plattform, die zum kommunikativen Austausch des Themas eingerichtet wurde?**

Das wäre eine tolle Sache! Es ist mein Wunsch, mehr konkrete Anwendungsfälle von Quanten-Computing und künstlicher Intelligenz kennenzulernen. Was wird

für ein Aufwand betrieben? Welche Skills sind vonnöten? Was muss ich tun, um die Bedingungen für Quanten-Computing und KI zu schaffen? Was sind das für Bedingungen? Wie finanziere ich sie?

ACI ist der globale Verband der Flughäfen mit Sitz in Montreal. Hier könnte man einen solchen Vorschlag auf die Agenda bringen. Ein solches Pilotprojekt wurde noch nicht angesprochen, wobei wir über KI-Anwendungen schon geredet haben. Unsere nächste Sitzung findet im Dezember in Hongkong statt. Warum nicht einen konkreten Vorschlag in diese Richtung machen? Von Hannes Mittermaier

In Japan und in anderen technikbegeisterten Ländern kommen Roboter wie Josie Pepper schon länger zum Einsatz. Etwa in Shops begrüßen sie Kunden, beantworten Fragen, reagieren auf Beschwerden oder geben Auskunft zu produktspezifischen Informationen. Josie Pepper ist der erste humanoide Roboter, der an einem deutschen Flughafen zum Einsatz kommt. Die 1,20 Meter große Roboterde wurde von der französischen Firma SoftBank Robotics entwickelt. Ihr künstliches „Gehirn“ kommt von IBM Watson. Der Roboter steht in ständigem Informationsaustausch mit dem Flughafen München. Über WLAN ist Josie Pepper mit dem Internet verbunden und hat dadurch Zugriff auf eine Cloud, die zum Datentransfer zwischen Flughafeninformationen und der Interpretation des Gesprochenen dient. Spricht Josie Pepper, dann greift sie dabei nicht auf einen vorgefertigten Text zurück, sondern antwortet individuell auf jede Frage. – Im Moment nur auf Englisch, denn Deutsch muss die Roboterde noch lernen.

„Josie Pepper“ ist übrigens eine Namensgebung, die von Mitarbeitern des Airports und der Lufthansa stammt.

Der führende internationale Dachverband der Flughafenbetreiber Airports Council International (ACI) hat seinen Sitz seit 2010 im kanadischen Montreal. Vor seiner Gründung im



Jahre 1991 waren die Flughäfen durch das Airport Associations Coordinating Council (AACC) miteinander verbunden. Diese Organisation wurde 1970 durch das Airport Operators Council International (AOC), die International Civil Airports Association (ICAA) und die Western European Airports Association (WEAA) gegründet. ACI gehören Stand Januar 2016 592 Mitglieder an, die insgesamt mehr als 1853 Flughäfen in 173 Staaten und Territorien betreiben. 2015 haben die Mitglieder von ACI mehr als 7,1 Milliarden Passagiere, 105 Millionen Tonnen Fracht und 86 Millionen Flugzeugbewegungen abgewickelt. In den letzten zwei Jahren hatte Michael Zaddach den Chair des World Airport IT Standing Committee (WAITSC) der ACI.

# 1. ARTIFICIAL INTELLIGENCE

Artificial Intelligence is currently one of the most exciting topics in computer science with many existing and emerging applications in industry, education, security as well as everyday life. Many advances in Artificial Intelligence especially in Machine Learning, Natural Language Processing and Autonomous Decision Making have enabled the realization of exciting applications like Object Detection in videos and images, language translation, and autonomous driving which have not been possible with classical engineering methods before.

While being a seemingly promising direction to solve many complex tasks, Artificial Intelligence still poses some challenges which need to be addressed by research and industry in the future to increase its wide application range: Approaches to Artificial Intelligence have to be able to make guarantees about their performance in extreme and unexpected situations. They also have to be explainable in various ways like being transparent about their decision or prediction process and being able to explain their behavior after performing a task as well as giving reasons why particular actions were chosen over others. While most Artificial Intelligence applications are originally designed to function without human intervention, it is not always possible to keep humans out of the loop. Applications in education for example require the system to socially interact and show empathy towards the user to be generally accepted by society.

A central goal of Artificial Intelligence is to offer general ways to solve a variety of complex problems without manual engineering and minimal domain knowledge. Thus current research should explore directions to transfer knowledge between systems, to extend task specific methods to general frameworks and to discover similarities about problems to find general problem formulations which are solvable by Artificial Intelligence.

The articles in this journal offer an exciting and rich overview of challenges and solutions concerning different fields of Artificial Intelligence about theoretical methods, definitions, surveys, visions as well as real applications in industry.

## MEIST GEKLIKT – Unsere erfolgreichsten Blog-Beiträge

Unsere  
Beiträge wurden  
insgesamt **700.000**  
Mal geklickt\*

Beiträge  
zum Thema  
**ARTIFICIAL  
INTELLIGENCE**  
erhielten **27.700**  
Klicks.

	Autor   Thema
#1	<b>Dr. Marco Maier</b>   Was ist Affective Computing? Seite 70
#2	<b>Markus Mayer</b>   Instrumente der Zukunft: Software-Roboter gesteuerte Prozessautomatisierung (RPA) und Künstliche Intelligenz (KI) als wichtige Wettbewerbsfaktoren Seite 72
#3	<b>Lilian Schröder</b>   Was macht ein Gebäude intelligent? Seite 70
#4	<b>Igor Ilunin</b>   Wie künstliche Intelligenz unsere Lebensbedingungen beeinflusst Seite 61
#5	<b>Michael Bartl</b>   Step Up! Die vier Stufen Emotionaler Intelligenz Seite 71

\*Unsere Beiträge wurden online unter [www.digitaleweltmagazin.de/blog](http://www.digitaleweltmagazin.de/blog) veröffentlicht und erzielten dabei die oben genannte Klickanzahl im Zeitraum 01. August 2017 – 29. Juli 2019.

## INHALT

### WISSENSCHAFTLICHE FACHBEITRÄGE

Sabrina Brill   Deep Learning in der Textverarbeitung	22
Christopher Koska   Blackbox AI – State Regulation or Corporate Responsibility?	26
Prof. Dr. Kristian Kersting   Maschinelles und Tiefes Lernen: Der Motor für „KI made in Germany“	30
Dr. Peter Kullmann   KI-Systeme im produktiven Unternehmenseinsatz	33
Svenja Oprach   Building the Future of the Construction Industry through Artificial Intelligence and Platform Thinking	38
Prof. Michel Barbeau   Recognizing Drone Swarm Activities: Classical versus Quantum Machine Learning	43

### 1.1 AI-GRUNDLAGEN EINFACH ERKLÄRT

Dr. Thomas Franz   Künstliche Intelligenz: Lernen und lernen lassen	49
Franz Kögl   So lernen Maschinen beim Machine Learning	51
Jürgen Wirtgen   Künstliche Intelligenz: Möglichkeiten und Grenzen	53
Dr. Wolfgang Thronicke   Was heute besser als mit Katzenbildern geht	54

### 1.2 SOCIAL IMPACTS & THE FUTURE

Jörg Doeblér   Wie KI unsere Gesellschaft verändert: Worauf es jetzt ankommt	56
Markus Dohm   KI gehört die Zukunft, sie braucht aber Regeln	58
Igor Ilunin   Wie künstliche Intelligenz unsere Lebensbedingungen beeinflusst	61
Michaela Tiedemann   Machine Learning und die Zukunft des Menschen in der Arbeitswelt	61

### 1.3 ZUR TECHNOLOGIE

Eberhard Hechler   Auf dem Wege zur Demokratisierung des Maschinellen Lernens	62
Dr. Sandra Lemmer   Wie Künstliche Intelligenz und Algorithmen das Innovieren revolutionieren	64
Prof. Dr. habil. Imre Koncsik   Topologische komplexe Informationsverarbeitung in neuronalen Netzen	65
Dr. Christoph Goller   Natural Language Processing punktet vor allem bei Textsuche, -klassifikation und -analyse	67

### 1.4 AFFECTIVE COMPUTING

Dr. Marco Maier   Was ist Affective Computing?	70
Lilian Schröder   Was macht ein Gebäude intelligent?	70
Michael Bartl   Step Up! Die vier Stufen Emotionaler Intelligenz	71

### 1.5 USE CASES

Markus Mayer   Instrumente der Zukunft: Software-Roboter gesteuerte Prozessautomatisierung (RPA) und Künstliche Intelligenz (KI) als wichtige Wettbewerbsfaktoren	72
Holger Hornik   So profitieren Unternehmen von KI-Chatbots	75
Britta Hilt   Vorausschauende Produktion: Kosten reduzieren, Ausfälle verhindern und Produkte nachhaltig verbessern	76
Alexander Eser   Machine Learning & Healthcare: Wie Algorithmen Krankenkassenbeiträge fairer gestalten können	79
Matthias Koeplin   Herausforderungen für Machine Learning in der Abschlussprüfung	81
Xavier Guerin   (K)IQ-Test für Banken: Technologie für Kundenbindung	83

# Deep Learning in der Textverarbeitung

Sabrina Brill

Lesen ist mehr als nur Grammatik anzuwenden. Für einen Menschen bedeutet Lesen etwas über den Autor zu erfahren, was er weiß, denkt oder fühlt. Für ein neuronales Netz bedeutet Lesen eine Klassifikationsaufgabe zu lösen - ohne Wissen über Menschen und wie sie ihre Umwelt wahrnehmen. Ein neuronales Netz weiß nicht, wie ein Baum aussieht, wie sich Angst anfühlt oder warum Menschen schreiben. Weltwissen hilft aber beim Verstehen von Texten. Sätze können verschiedene Lesarten haben, wovon einem Menschen nur eine plausibel erscheint. Während Menschen diese Schwierigkeit meist nicht einmal wahrnehmen, lässt sich ein neuronales Netz leicht davon in die Irre führen. Deshalb sollte eine KI auch die Konzepte hinter den Worten lernen. Das macht dieses Problem so schwierig.

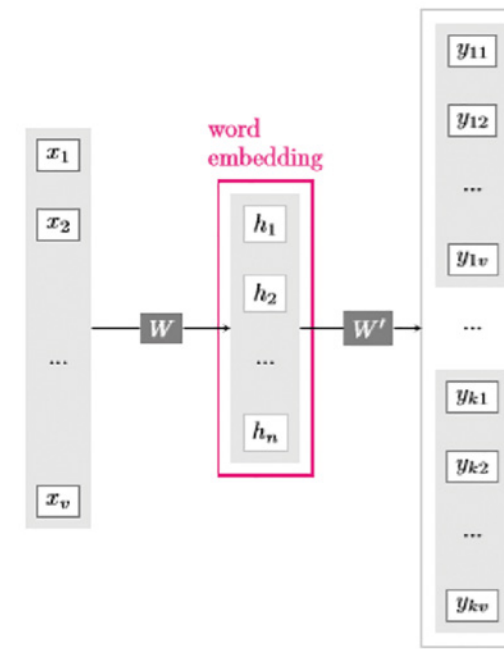
Ein neuronales Netz lernt Texte zu verarbeiten, indem es aus Beispielen generalisiert. Dadurch lernt es, wie Menschen Sprache verwenden, und nicht die Normen, mit denen Menschen Sprache beschreiben. Hierfür werden Trainingsdaten benötigt – also Texte, die mit einer Annotation versehen wurden. Dieses Annotationsschema wird bei der Vorhersage auf ungesehene Daten übertragen und steuert daher, welche Informationen ein neuronales Netz einem Text entnimmt. Die Qualität der Vorhersagen hängt neben der Struktur des neuronalen Netzes maßgeblich von der Menge und der Qualität der Trainingsdaten ab. Neuronale Netze führen auf einer Eingabe eine Abfolge von linearen Transformationen durch, wofür eine Vielzahl von Gewichten während des Trainings bestimmt werden müssen. Gewichte erlauben einem neuronalen Netz, nur bestimmte Merkmale zu beachten. Im Training wird daher gelernt, welche Merkmale wann relevant sind. Im Fall von Text besteht die Eingabe aus einem Wort bzw. dessen Vektorrepräsentation (word embedding). Zusätzlich wird ein Zustand mit Kontextinformationen mitgeführt. Das ist eine Besonderheit von recurrent neural networks (RNNs), eine Art neuronaler Netze, die Sequenzen bearbeiten. Jede Schicht (layer) verarbeitet ein Wort, produziert für dieses Wort einen Output und aktualisiert den Zustand, der an die

nächste Schicht weitergegeben wird. Das heißt, die Länge des Texts entspricht der Tiefe des neuronalen Netzes. Da sehr viele Schichten durchlaufen werden, um eine Vorhersage für den gesamten Text zu produzieren, kann von Deep Learning gesprochen werden. Die Pflege eines Zustands in einem tiefen Netz ist eine zentrale Herausforderung in der Verarbeitung sequentieller Daten. Es gibt einige Schwierigkeiten, die während des Trainings neuronaler Netze auftreten können, insbesondere gehäuft beim Deep Learning. Hierfür wurden u.a. spezielle Netzwerkarchitekturen entwickelt wie LSTM (long short-term memory) oder GRU (gated recurrent unit). Diese steuern die Aktualisierung des internen Zustands, damit sich das neuronale Netz wichtige Beobachtungen länger „merken“ kann. Diese bereits komplexen neuronalen Netze lassen sich weiter ausbauen, um strukturiertes Weltwissen zu nutzen, oder als bidirektionale Netze, die Texte vorwärts und rückwärts lesen.

## Wörterbuch: Deutsch – neuronales Netz

Um für Worte Vorhersagen treffen zu können, müssen diese zunächst in Zahlen übersetzt werden. Ein einfacher Ansatz ist, für jedes Wort im Vokabular eine Dimension einzuführen. Dann kann jedes bekannte Wort eindeutig mit einem binären Vektor dargestellt werden, bei dem immer genau eine Dimension 1 ist. Die Anzahl der Dimensionen entspricht folglich der Größe des Vokabulars. Natürlich werden nicht so viele Dimensionen benötigt, um diese Informationen darzustellen. Allerdings kann diese Repräsentation genutzt werden, um word embeddings – eine niedrigdimensionale Vektorrepräsentation - zu lernen. In diesem deutlich kleineren Vektorraum sind Worte nach ihrer Bedeutung angeordnet. Ähnliche Worte liegen nahe beieinander und Bedeutungen können berechnet werden (z.B. [Berlin] - [Deutschland] + [Italien] = [Rom]). Word embeddings können mithilfe von einem zweischichtigen neuronalen Netz gefunden werden [1]. Dieses lernt Worte ihrem Kontext zuzuordnen, indem es die hochdimensionale Wortrepräsentation in eine niedrigere

Dimension und anschließend in die Vektoren der Kontextwörter projiziert. Dabei lernt das neuronale Netz implizit eine Transformationsmatrix für word embeddings, die niedrigdimensionale Repräsentation (siehe Abbildung 1). In der Regel wird die Vektorrepräsentation in einer Art Wörterbuch gespeichert, in dem beim Einlesen von Texten nachgeschlagen wird.



**Abbildung 1:  $W$  und  $W'$  enthalten Gewichte, die so optimiert werden, dass mit einem Wort  $x$  dessen Kontext  $y$  vorhergesagt werden kann. Dabei lernt dieses zweischichtige neuronale Netz, was das Wort bedeutet. Alle drei Vektoren  $x$ ,  $h$  und  $y$  beinhalten diese Information. Dabei hat  $h$ , das word embedding, die geringste Anzahl an Dimensionen.**

## Warum ist Deep Learning schwierig?

Die zentrale Frage bei der Arbeit mit neuronalen Netzen ist die nach den optimalen Gewichten. Im Deep Learning wiegt diese Frage besonders schwer, da sehr viele Gewichte zu optimieren sind. Daher ist ein geschicktes Vorgehen beim Training besonders wichtig.

Neuronale Netze werden mit dem Forward-Backward-Algorithmus (bzw. Baum-Welch-Algorithmus) trainiert. Dabei wird für Texte in den Trainingsdaten eine Vorhersage gemacht, der Fehler berechnet und die Gewichte aktualisiert. Fehler in einer Schicht können in den folgenden Schichten weitere Fehler verursachen. Beim Aktualisieren der Gewichte wird der Fehler dann Schicht für Schicht rückwärts durch das Netz geleitet und die Gewichte werden entsprechend angepasst. Dieser Vorgang wird backpropagation genannt. Handelt es sich bei der Eingabe wie bei Text um eine Sequenz, muss die Zeit (bzw. wo ein Wort im Text steht) miteinbezogen werden. Für jede Schicht wird der Gradient der Fehlerfunktion berechnet, um festzustellen, in welche Richtung die Gewichte angepasst werden müssen, damit der Fehler minimiert wird. Dabei kann einiges schief gehen.

Durch die iterative Approximation werden nur lokale Minima der Fehlerfunktion gefunden. Daher kann die Qualität des trainierten Modells abhängig von den initialen Gewichten stark variieren. Hat ein neuronales Netz viele Schichten, wird die Funktion komplexer und es gibt mehr lokale Minima und daher mehr mögliche Lösungen. Eine verbreitete Technik ist stochastic gradient descent [2]. Dieses Verfahren arbeitet mit Zufall und verfolgt nicht zielstrebig das erste lokale Minimum, das es findet. Dafür werden die Gewichte nach jedem Text aktualisiert, anstelle der Aktualisierung nach dem vollständigen Durchlauf der Trainingsdaten. Der Fehler und die Gewichte variieren stärker, da sich das neuronale Netz mit jeder Aktualisierung auf einen anderen Text spezialisiert. Dadurch kann das neuronale Netz im Training mehr lokale Minima sehen und ein insgesamt besseres Modell finden. Abgesehen vom extremen Ansatz, immer nur einen Text vor dem Update zu betrachten, gibt es auch die Möglichkeit, eine Teilmenge der Texte für das Update in Betracht zu ziehen. Unabhängig von der gewählten Anzahl von Texten müssen diese zufällig gewählt werden.

Eine weitere Hilfestellung ist eine gute Initialisierung der Gewichte. Was eine gute Initialisierung ist, hängt von der verwendeten Aktivierungsfunktion ab. In einem Neuron wird der Eingabevektor zunächst mit den Gewichten multipliziert. Auf das Produkt wird dann eine Funktion angewendet, damit das Ergebnis innerhalb eines bestimmten Intervalls bleibt. Das ist die Aktivierungsfunktion, nach der die Initialgewichte gewählt werden. Das mindert auch die Gefahr, dass ein Gradient unendlich groß oder Null wird. Mit zunehmender Anzahl an Schichten steigt die Wahrscheinlichkeit, dass dieses Problem auftritt. Hierfür wurden spezielle Netzwerkarchitekturen für sequentielle Eingabedaten wie Text entwickelt.

Eine andere Frage ist, wie weit man die Fehlerfunktion minimieren möchte. Eine Fehlerfunktion sucht die wahrscheinlichste Label-Sequenz für einen Text. Welche Lösung richtig ist, geben die Trainingsdaten vor. Innerhalb der vielen Freiheitsgrade, die ein tiefes neuronales Netz bietet, werden die Gewichte dahingehend optimiert, dass die Vorhersage der vorgegebenen Lösung entspricht. Informationen aus einem Text zu extrahieren, bedarf einer komplexen Funktion, um die ebenfalls komplexen Zusammenhänge zu modellieren. Allerdings steigt mit der Komplexität auch die Gefahr des overfittings – des Auswendiglernens der Trainingsdaten. Ein neuronales Netz kann nicht nur zu wenig, sondern auch zu viel lernen. Wird ein neuronales Netz „zu gut“ trainiert, macht es immer bessere Vorhersagen auf den Trainingsdaten. Gleichzeitig kann es das Gelernte aber immer schlechter auf ungesehene Daten übertragen.

## Wie hat der Satz nochmal angefangen?

Auch ein neuronales Netz braucht ein Gedächtnis zum Lesen. In einem einfachen RNN ersetzt in jeder Schicht ein neuer Zustand den vorherigen. Durch den unregulierten Informationsfluss steigt mit zunehmender Textlänge das Risiko, dass die Gewichte und damit auch die Gradienten während des Trainings extreme Werte annehmen, was das Lernen behindert. Im schlimmsten Fall betrachtet das neu-

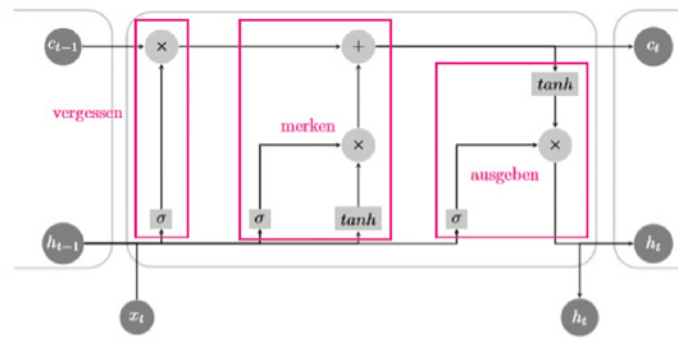


Abbildung 2: Ein LSTM trennt den Zustand  $c$  von den Ausgaben  $h_t$ . Aktualisierungen werden mit der vorherigen Ausgabe  $h_{t-1}$  und der aktuellen Eingabe  $x_t$  berechnet. Neuronen sind entweder für das Vergessen, das Merken oder die Ausgabe zuständig.

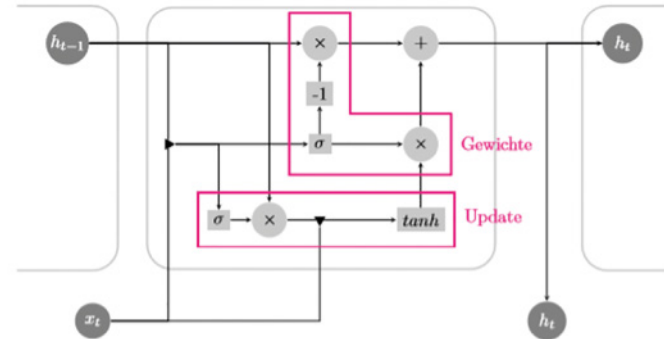


Abbildung 3: Ein GRU berechnet eine gewichtete Summe aus dem Zustand  $h_{t-1}$  und den neuen Informationen  $x_t$ . Einen separaten Output gibt es hier nicht.

ronale Netz Worte einzeln, indem es den Zustand vollständig überschreibt. Oder es kann alle neuen Informationen für irrelevant halten und den Zustand einfach übernehmen. Als Lösung für dieses Problem wurden Netzwerkarchitekturen entwickelt, die den Informationsfluss regulieren. Dafür werden in jedem Schritt mehrere Neuronen eingesetzt, um zu entscheiden, welche Informationen in den Zustand geschrieben und welche gelöscht werden. Damit wird verhindert, dass Gewichte sehr groß oder Null werden. Verbreitet sind zwei Architekturen GRU [3] und LSTM [4], die in der Praxis beide gute Ergebnisse liefern. Beide haben einen Mechanismus, um Informationen hinzuzufügen und zu entfernen. Unter Berücksichtigung des Kontexts und der aktuellen Eingabe wird der Zustand aktualisiert. Dabei werden neue Informationen addiert, was ein vollständiges Überschreiben des Zustands verhindert. Ein LSTM berechnet einen Output zusätzlich zum aktualisierten Zustand, der mit einer Vergessen- und einer Merken-Operation berechnet wird (siehe Abbildung 2). Der Output wird zur Klassifikation des Wortes und für die Berechnung des nächsten Updates genutzt. Damit schirmt ein LSTM seinen internen Zustand vollständig ab. Dadurch entsteht eine sog. memory cell. Bei einem GRU hingegen ist der neue Zustand gleichzeitig Grundlage für die Klassifizierung des Wortes und wird daher auch bei der Berechnung des Updates verwendet. Der neue Zustand entspricht einer linearen Interpolation zwischen dem Zustand und dem Update. Das heißt, es wird eine gewichtete Summe vom aktuellen Zustand und dem Update berechnet und als neuer Zustand gesetzt (siehe Abbildung 3). Das GRU lernt im Training, wie es das Update berechnet und wann es wie den Zustand und das Update gewichten muss. Das LSTM hingegen lernt, was es wann vergessen, sich merken und ausgeben soll.

#### Alles eine Frage der Perspektive

Texte kann man auch rückwärts lesen. Für einen Menschen unvorstellbar. Aber genauso wie ein neuronales Netz lernen kann, einen Text vorwärts zu lesen, kann es auch lernen, diesen rückwärts zu lesen. Natürlich löst dieser Perspektivwechsel nicht alle Verständnisprobleme, zumal Sprache für das Vorwärtslesen entwickelt wurde. Die Kombination von

Vorwärts- und Rückwärtslesen verschafft dem bidirektionalen Netz einen Vorteil, indem es mehr Kontextinformationen zur Verfügung stellt: einen Vektor mit dem Kontext vom Textanfang und einen mit dem Kontext vom Textende [5]. Für das Gesamtergebnis werden diese beiden Vektoren meistens konkateniert – d.h. sie werden „gestapelt“. Auch beim Training ist diese Vorgehensweise vorteilhaft. Wird ein neuronales Netz rückwärts trainiert, wird der Fehler von der anderen Seite aus durch das Netz propagiert und erreicht die Schichten zuerst, die sonst zuletzt aktualisiert werden. Auch in dieser Hinsicht ergänzen sich zwei Netze, die Texte in unterschiedliche Richtungen lesen.

#### So lernt ein neuronales Netz die Welt kennen

Eine wichtige Information fehlt dem neuronalen Netz noch: Wie sieht die reale Welt aus? Damit gezielt nach Informationen gesucht werden kann, benötigt das neuronale Netz strukturiertes Weltwissen. Diese Informationen werden meist in Form eines Graphen oder einer Liste von Tripeln  $\langle \text{Entität} \rangle \langle \text{Relation} \rangle \langle \text{Entität} \rangle$  bereitgestellt. Je nach Sprache und Thema stehen auch schon fertige knowledge bases (KBs) zur Verfügung. Ein Tripel könnte z.B. so aussehen:  $\langle \text{Fisch} \rangle \langle \text{lebt in} \rangle \langle \text{Wasser} \rangle$ . Für manche Texte kann diese Information relevant sein. Für eine Speisekarte hingegen wird dieses Wissen meistens nicht benötigt. Deshalb sollten zusätzliche Informationen nur manchmal genutzt werden. Dabei hilft ein sog. Attention-Mechanismus [6]. Attention heißt, es wird eine gewichtete Summe verschiedener Vektoren gebildet, sodass ein Vektor mit den relevantesten Informationen aus allen Quellen entsteht. Damit kann ein neuronales Netz selbst entscheiden, wann es welche Information nutzt. Dafür wird zunächst in der KB nach dem aktuellen Wort gesucht und Scores für die Embeddings der dazugehörigen Tripel berechnet. Mit den Scores wird eine Vorauswahl getroffen. Gewichte werden nur für die relevantesten Tripel berechnet. Dabei wird der Ergebnisvektor aus dem LSTM genutzt, um zu entscheiden, welches Wissen aktuell benötigt wird. (Bislang wurde dieses Verfahren nicht mit GRU verwendet.) Für die Textinformationen wird ein weiterer Output, ein sog. Sentinelvektor, berechnet. Um diesen Vektor zu berechnen,

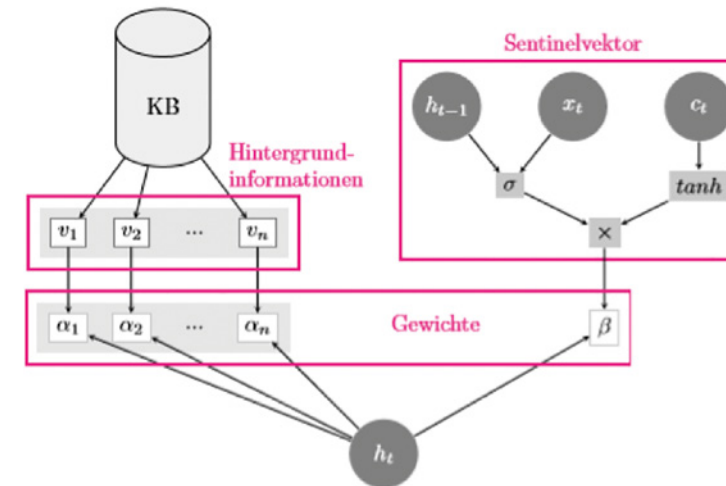


Abbildung 4: Für den Attention-Mechanismus werden die Gewichte  $\alpha_1$ - $\alpha_n$  und  $\alpha$  geschätzt. Es gibt sowohl einen Vektor mit Textinformationen (der Sentinelvektor) als auch einen Vektor für jede Hintergrundinformation  $v_1$ - $v_n$ . Der Sentinelvektor unterscheidet sich vom eigentlichen Output  $h_t$ , mit dem die Gewichte geschätzt werden. Mithilfe dieser Gewichte wird die Summe aus allen Informationen gebildet.

werden separate Gewichte gelernt. Damit unterscheidet sich der Sentinelvektor vom eigentlichen Output, mit dem die Gewichte berechnet werden (siehe Abbildung 4). Aus den Textinformationen und den Hintergrundinformationen wird eine gewichtete Summe gebildet, welche auf das ursprüngliche Ergebnis addiert wird. Damit erlangt ein neuronales Netz die Fähigkeit, beim Lesen Weltwissen gezielt einzusetzen, ohne die Textinformationen vollständig überschreiben zu können. Stehen alle wichtigen Informationen bereits im Text oder die zusätzlichen Informationen passen nicht in den Kontext, erhält der Sentinelvektor im Vergleich zu allen anderen Vektoren ein sehr hohes Gewicht. Setzt der Text hingegen diese zusätzlichen Informationen voraus, werden diese ergänzt. Dazu muss im Training zusätzlich gelernt werden, wann welche Informationen relevant sind und wie ein Sentinelvektor berechnet wird.

#### Einsatzmöglichkeiten

Der berechnete Vektor aus dem neuronalen Netz kann in eine Kategorie umgerechnet werden. Ein gängiges Annotationsschema ist BIO für named entity recognition (NER). „B“ (beginning) markiert das erste Wort einer Entität, „I“ (inside) ein weiteres zum Namen der Entität gehörendes Wort und „O“ (outside) alle anderen Worte. Für unterschiedliche Arten von Entitäten können „B“ und „I“ mit unterschiedlichen Indizes versehen werden. Das ermöglicht einem neuronalen Netz, Entitäten zu kategorisieren und z.B. Firmen- und Personennamen als solche zu erkennen. Für eine Namenserkennung mag der Trainingsaufwand groß sein. Dies ist aber die Grundlage für weiterführende Aufgaben. Sind die Hauptakteure eines Textes bekannt, kann nun gelernt werden, Beziehungen zwischen diesen Akteuren zu identifizieren.

Neben Namen können Worte aber auch nach Ereignissen kategorisiert werden. Es geht also um die Frage: „Was passiert?“ In der event extraction werden meistens Verben gesucht. Allerdings können auch Nomen ein Ereignis beschreiben. Dass Trigger so unterschiedlich sein können, macht das Problem etwas schwieriger als das Erkennen von Namen. Ist das Identifizieren von Ereignissen bereits unzuverlässig, passieren beim Kategorisieren weitere Fehler, worunter die

Qualität der Vorhersage leidet. Um diese Aufgabe zuverlässig bearbeiten zu können, ist weitere Forschung notwendig. In Zukunft wäre denkbar, Informationen über Ereignisse mit den Informationen über die beteiligten Akteure zu kombinieren und damit die Frage „Wer macht was?“ zu beantworten.

#### Fazit

Mithilfe neuronaler Netze können wir automatisch Informationen aus Texten entnehmen und strukturiert abspeichern. Dadurch werden Daten für die weitere Verarbeitung verfügbar gemacht. Aktuell gibt es keine Modelle, die genauso präzise arbeiten wie Menschen. Bei großen Datenmengen besticht aber ihre Schnelligkeit.

Referenzen: [1] T. Mikolov, I. Sutskever, K. Chen, G. Corrado und J. Dean, „Distributed representations of words and phrases and their compositionality“, Advances in neural information processing systems, pp. 3111-3119, 2013. [2] L. Bottou, „Large-scale machine learning with stochastic gradient descent“, Proceedings of COMPSTAT'2010, pp. 177-186, 2010. [3] J. Chung, C. Gulcehre, K. Cho und Y. Bengio, „Empirical evaluation of gated recurrent neural networks on sequence modeling“, arXiv preprint, 2014. [4] S. Hochreiter und J. Schmidhuber, „Long short-term memory“, Neural Computation, p. 1735-1780, 1997. [5] A. Graves und J. Schmidhuber, „Frame-wise phoneme classification with bidirectional LSTM and other neural network architectures“, Neural Networks, pp. 602-610, 2005. [6] B. Yang und T. Mitchell, „Leveraging knowledge bases in LSTMs for improving machine reading“, in Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), 2017.



#### Sabrina Brill

Sabrina Brill arbeitet als Softwareentwicklerin bei der itera-tec GmbH. In Kundenprojekten entwickelt sie Anwendungen, die mithilfe künstlicher Intelligenz entlasten. Ihr Wissen aus dem Bereich des maschinellen Lernens erlangte sie im Studium der maschinellen Sprachverarbeitung.

# Blackbox AI – State Regulation or Corporate Responsibility?

Christopher Koska, Alexander Filipović

*“In the past a lot of S&P 500 CEOs wished they had started thinking sooner than they did about their Internet strategy. I think five years from now there will be a number of S&P 500 CEOs that will wish they’d started thinking earlier about their AI strategy.”* Andrew Ng

## Introduction

Artificial intelligence changes our understanding of the world, of others and of ourselves. Already today, the catchword “AI” can deeply unsettle people: “As an optimization machine, algorithmic automation mills its patterns in ever shorter intervals into the functional conditions of entire areas of life, work and society” (Martini 2019, V) and leaves behind diffuse fears and worries as well as pious wishes and hopes. Hardly any data-driven company can escape this confused state of mind. The economic success of an AI strategy also depends on the social acceptance of the new technologies. Confidence-building and transparency-increasing measures therefore play an increasingly important role in the success or failure of AI projects.

Based on the legal regulatory recommendation of Martini (2019), but also in contrast to a blind ideology of transparency, this contribution traces the potential of Corporate Responsibility (CR) and outlines how CR can be anchored within the framework of a sustainable AI strategy. The entrepreneurial scope does not only encompass promising opportunities and possibilities for counteracting excessive government regulation measures that could curb technical innovations. Rather, it also spans the trust horizon of digital society over basic social values. In this sense, companies are important players to count on if we want to shape digital society in a humane manner. Thinking ahead at this point leads us to the digital self-determination of people and to a practice-oriented interpretation of the concept of transparency using the example of a tiered information system or user cockpit. Like this, companies can offer their customers targeted solutions to contextually control what happens around their own data. To end our thoughts, a module for a trustworthy use of data will be integrated into the new concept of “Corporate Digital Responsibility (CDR)”, which has already been discussed in various contexts.

## Perception of Corporate Responsibility

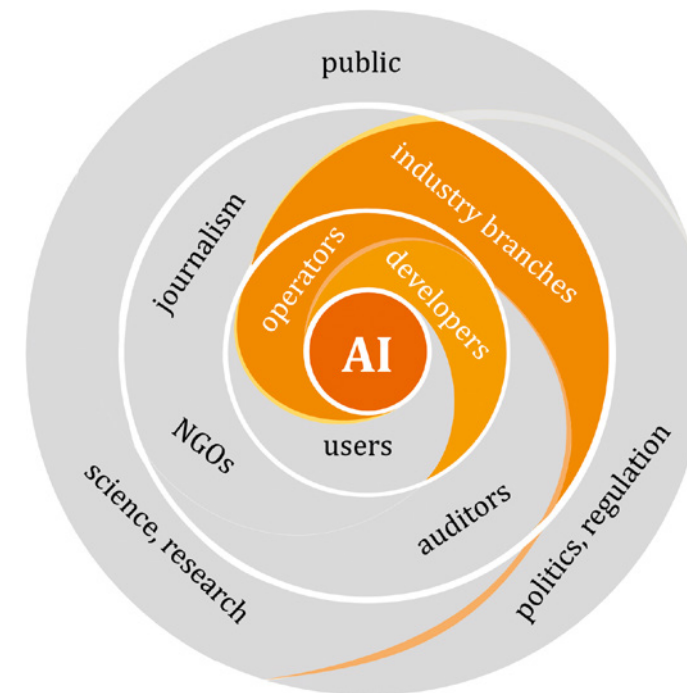
According to the jurist Mario Martini (since July 2018 a member of the Data Ethics Commission of the German Federal Government), companies are committed to abide by the principles of transparency and data economy when processing personal data only under two premises: “if they are either forced to do so by regulation or if the customer’s wish gives them the choice of respecting their right to self-determination or of allowing the data stream to dry up” (Martini 2019, VII).

Morally, the right to self-determination is deeply rooted in the idea of a free society. Critical voices however see the guarantee that people can set the standards by which they want to live seriously threatened through the increasing “datafication of the world” (cf. Filipović 2015, p. 6 - 15). Since most people in Europe know little about algorithms and a large part of the population is in a state of discomfort and disorientation (cf. Fischer und Petersen 2018; Grzymek und Puntschuh 2019), the call for further state regulation – especially in the context of artificial intelligence – is becoming increasingly clear (cf. Budras 2019).

Government and political action are based on the fundamental values of our society represented in the Constitution. Therefore, the current debate is no longer about the question of “whether” but “how” the population can be introduced to a self-determined handling of algorithmic and data-driven automation (“artificial intelligence”). Before we examine the solution of a staged information system for user data, the so-called black box problem, which is often cited as reason for the lack of transparency of algorithmic systems, is first highlighted. According to Martini (2019), there are two different causes for the current lack of transparency: 1) Legal causes, insofar as algorithms are evaluated as official or business secrets, and 2) Technical causes, if the technical operation mode of “artificial intelligence” appears to be impenetrable for the human mind.

For a detailed explanation as to why “the previously applicable law, in particular data protection law, but also anti-discrimination and competition law [...] does not yet specifically take into account the constitutional mandate” (ibid. p. 109), we can refer to the monograph of Martini (2019). Building on these findings, the aim of this article is to show ways in which companies can take responsibility for shaping the scope currently

available to them in order to develop potentially promising technologies within the framework of our fundamental social values. The two motives for action already cited above (regulatory compulsion and customer satisfaction) can be anchored in a third motive for action: corporate digital responsibility. The insight that data-driven companies have a special responsibility for AI from a practice-oriented perspective can be illustrated by the following graphic (based on Saurwein 2018):



**Figure 1: Overview of the groups of players that can act as responsible parties for AI.**

Corporate responsibility concentrates on the innermost shell of the “onion of responsibility”, initially on the operators and developers of AI systems, but also on cooperation with industry associations on the second shell (both coloured orange). Since developers and operators – in contrast to the users – have privileged access to the behaviour and working methods of AI, the perception and recognition of one’s own responsibility is the most important basis for a sustainable solution to the current black box problem.

## Criticism of the blind ideology of transparency

The concept of transparency is extremely complex in the context of digitisation. “No other buzzword today dominates public discourse as much as transparency” (Han 2015). On the one hand, the term stands for the widespread fear of observation and the “glass human being” on the internet, for a danger to privacy and individual personality development (cf. Lück 2013). On the other hand, an ethical ideal is formed under the social demand for transparency, which is cited as an all-purpose weapon against opaque power structures, political and economic dependencies, conflicts of interest, corruption, data abuse and much more. The moral question that can be added to this discussion is: who or what should be transparent to whom?

Regarding the use of highly automated decisions, it is essentially a question of making the origination of such decisions

visible and understandable to the persons affected by them. This is necessary because only then can those affected assess whether they should take the risks that may result from an AI-based evaluation, or not. The introduction of the EU General Data Protection Regulation (GDPR) has already strengthened individual rights. However, the transparency requirement from Art. 12 GDPR can only make a limited contribution, as Martini also states: “Often consumers do not accept well-intentioned consumer information under the time restrictions of everyday life or perceive it as an annoying dowry that merely follows a formalism and in the worst case raises more questions than answers” (Martini 2019, p. 345).

Martini therefore recommends establishing the option in Art. 12 (7) GDPR for the use of standardised pictorial symbols (e.g. a red map marker pin for the use of anonymous geodata) which previously existed on a voluntary basis, as a “normative requirement specification” (Martini 2019, p. 345). The combination of written information and pictorial symbols aims at “providing a meaningful overview of the intended data processing in an easily perceptible, understandable and clearly comprehensible form” (Gola et al. 2017, p. 56). This is not only a matter of better orientation in the sense of data protection transparency, but above all also of enforcing the decision-making and intervention rights of the persons concerned, which are fundamental for guaranteeing informational self-determination (personal rights) (cf. ibid. p. 319). Against this background, Martini continues: “Users should not only act in an informed manner, but should also be able to exercise sovereignty over their data to the greatest extent possible in individual cases via a user cockpit, in particular be able to grant and withdraw rights of disposal and trace access to data” (Martini 2019, p. 345).

In the implementation of the GDPR, the concept of transparency has so far mostly been reduced to the concept of informational self-determination. The only way for potential customers to exercise control is for them to consent to or object to the processing of their own data. This approach is based on a minimal concept of autonomy, since the declaration of consent required for data processing is usually a one-time informed consent – which many companies regard as fulfilled, even if they refer to the improvement of their products and services as general purpose. The question of how much freedom of choice or action exists for the users within the technical system or which conditions must be fulfilled for interaction with complex algorithmic systems in order to speak of transparency or personal autonomy – even after the first declaration of consent – remains problematic.

What makes an action an autonomous and self-determined action? This question is the key to the formulation of targeted transparency requirements, as the idea of digital self-determination (and of many other fundamental values, such as the moral status of a person, human dignity, etc.) can be traced to the concept of personal autonomy: “Whoever is autonomous controls his directly given motives or controls himself through self-chosen goals by accepting them, approving them, identifying himself with them, appreciating them or else rejecting them, not letting them become effective, disapproving of them and distancing himself from them” (Betzler 2013, p. 12). The condition of authenticity adds that “what a person approves and

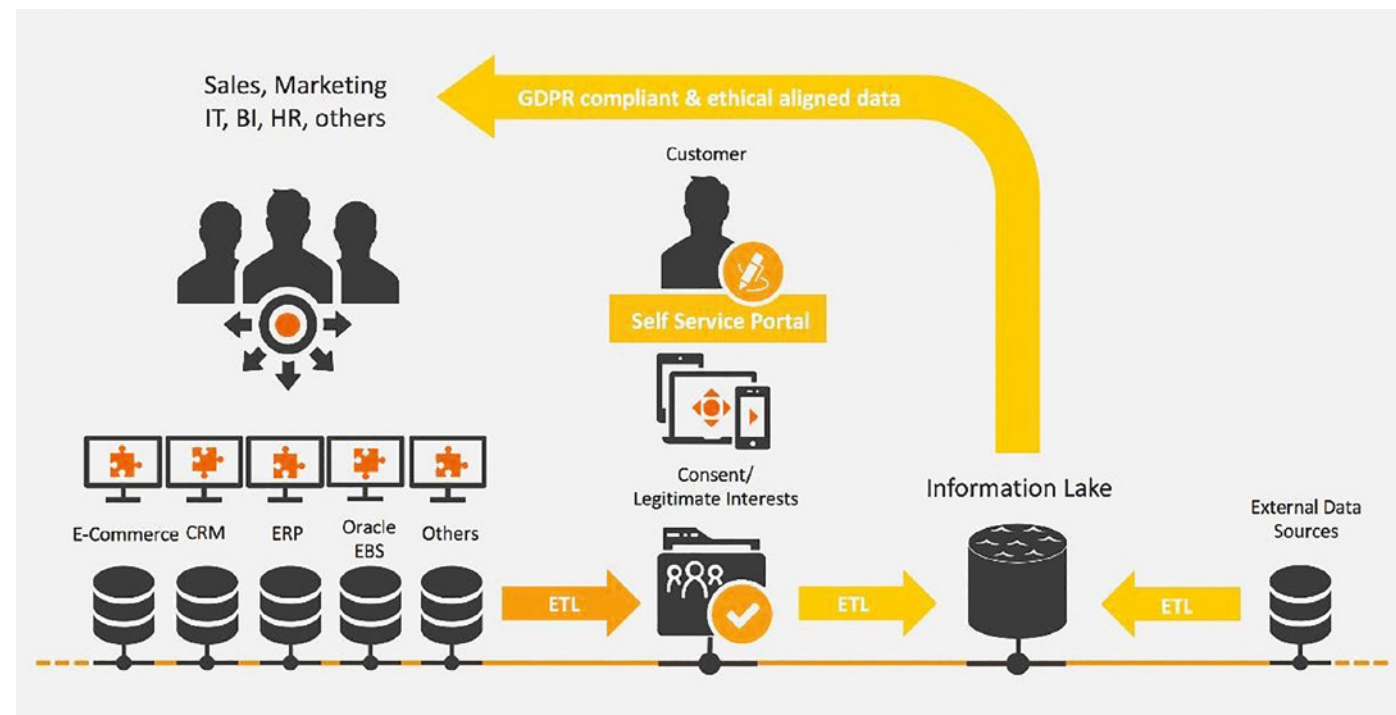


Figure 2: Framework for legal and ethical aligned data processes

by which he controls himself should be something that is truly ‘his own’ and ‘really distinguishes’ him” (ibid., p. 13).

In the context of artificial intelligence, algorithmic profiling and the current black box debate, it makes sense to demand transparency requirements in addition to the control and authenticity conditions. This means that the filter criteria and selection mechanisms of AI should be transparent for the user, as otherwise it would not be possible to check whether the algorithmic decision criteria really correspond to one’s own motives and goals.

In order to sum up the criticism of a blind ideology of transparency, it is helpful to briefly reflect on the two extreme poles of the transparency requirement:

- i) As outlined above, minimum transparency is achieved, if the legal minimum of information requirements (accord. to the GDPR etc.) is met.
- ii) Maximum transparency would supposedly be achieved, if all motives, dangers and risks of data use were fully captured and disclosed at all times; if all personal data could be viewed by the data users at all times; if all details of the functional logic, such as the weighting of filter criteria and selection mechanisms – especially in the context of machine learning and with regard to algorithmic decisions – were explained in detail, etc.

Neither the legal minimum nor supposedly complete transparency fulfils the requirements to ensure the digital self-determination rights of the persons concerned in dealing with AI. In practice, the minimal concept of transparency usually allows only informed self-determination, since (more or less detailed) information on the purpose of data processing relates only to the time of consent. This form of static consent is extremely inefficient both for the individual and for the data-driven industry. The latter already rightly points out that the proactive duty

to provide information massively slows down the innovation potential of AI in Europe. On the other hand, the information for those concerned usually remains very vague and general – for example, when reference is made “to improve our services” or “for the purpose of anonymizing data”. Data anonymisation is not only carried out to protect the privacy of the persons concerned (however usually only justified by this), but also because an evaluation of so-called anonymised affinity models no longer falls under the special protection for personal data in the GDPR. In most cases it is not mentioned that the collective character of algorithms can easily undermine this logic of individual rights (cf. Jaume-Palasi und Spielkamp 2017). Nor which personal disadvantages and long-term social risks are associated with the dissolution of individual interests and actions in the “numerical generality” of affinity models (Heesen 2018) according to the watering can principle, etc. With a maximum concept of transparency, the question arises as to how a scientific treatise on such complex socio-technical details can concretely help the average citizen. Since too much information usually leads to a lack of transparency (cf. Ananny und Crawford 2016) the question of the right measure is more the focus of attention. From a scientific and legal perspective, it is of course important to penetrate all the interpretation methods of black box analyses mathematically and logically, to find new models and deeper insight. For the vast majority of users, a detailed explanation system that represents all factors for a particular prediction or behaviour would be counterproductive, because people prefer short and contextual explanations for an event in their everyday lives (cf. Miller 2017; Doshi-Velez und Kim 2017; Molnar 2019). In order to build lasting trust in AI applications, it is therefore primarily a matter of preparing the sometimes-agnostic interpretability of statistical models for specific target groups.

### Transparency as part of a tiered information system

Digital self-determination is located at the abstraction level, where transparency and control can be established for the individual user (cf. Koska 2015). Since the same level of knowledge cannot be assumed for all users, a tiered information system is suitable for this issue. For a quick general introduction to the topic, standardized picture symbols (see above) can be used, which – preferably – are displayed context-sensitively during a particular user action. Because not all information is helpful in every situation. At this level, complexity reduction is required. Comprehensive information should therefore be better separated and ideally linked or made accessible to users via a more detailed self-service portal (see illustration).

On the one hand, the users can – analogous to the non-digital world (cf. Nissenbaum 2010) – better decide when they want to share specific data (segments) with whom and for what purpose. In certain situations, e.g. regarding specific health issues or for the preparation of a long-term loan, it can of course be very useful for potential patients or customers to receive tailor-made offers based on individual goals and personal interests and not on numerical generality. On the other hand, by introducing a tiered information system or user cockpit, companies are not only fulfilling their information and transparency obligations. By upgrading the “data lake” to an “information lake”, cross-departmental authorisation concepts can be realised, internal data governance processes optimised, data quality improved and much more.

### Implementing Corporate Digital Responsibility (CDR)

Transparency can create trust. However, transparency mostly only exists as a futuristic vanishing point, see also Schneider (2013): “It becomes apparent that ‘transparency’ can only ever be promised. There is no transparency here and now.” An increase always seems possible. To assume that transparency in terms of data protection, as it has already been compulsory introduced by the GDPR, is sufficient to guarantee digital self-determination, ignores the actual living conditions of the persons concerned, just the same as blind ideology of transparency. Companies that recognise this and are aware of their own responsibilities are currently in a particularly privileged position. Due to the changed communication and information possibilities (between companies, current customers and potential customers), businesses can use the (still) existing creativity scope to raise the concept of digital self-determination to a new level for their customers and to distinguish themselves from competitors. If they succeed in taking the customer with them on their journey towards digital responsibility, the customer will be able to build lasting trust in algorithmic decisions. The journey does not end with self-commitment codes, general statements of transparency and promotionally effective AI guidelines, it continues by letting the customer participate in holding the rudder and becoming an integral part of the AI responsibility strategy of companies (see Ackermann 2017).

In Germany, an intensive exchange between science, politics and companies has been taking place for several months now under the banner of “Corporate Digital Responsibility” (cf. Altmeppen und Filipović 2019). This involves the voluntary integration of social and ecological concerns into the digitisation

strategy of companies. Digitally responsible action therefore means not only complying with legal regulations, but also creating social, ecological and economic added value through ethical and sustainable corporate activities beyond mere legal conformity. This enables companies to enhance their reputation and at the same time create a solid basis of trust for digital innovations.

Literature: Ackermann, Gabriele (2017): CSR in der gesetzlichen Krankenversicherung. In: Alexandra Hildebrandt und Werner Landhäußer (Hg.): CSR und Digitalisierung. Der digitale Wandel als Chance und Herausforderung für Wirtschaft und Gesellschaft. Berlin, Heidelberg: Springer Berlin Heidelberg, 947-960. Altmeppen, Klaus-Dieter; Filipović, Alexander (2019): Corporate Digital Responsibility. Zur Verantwortung von Medienunternehmen in digitalen Zeiten. In: Communicatio Socialis 52 (2). Ananny, Mike; Crawford, Kate (2016): Seeing without knowing. Limitations of the transparency ideal and its application to algorithmic accountability. In: New Media & Society 33 (4), 146144481667664. DOI: 10.1177/1461444816676645. Budras, Corinna (2019): Ein Gesetzbuch für Roboter. Hg. v. Frankfurter Allgemeine Zeitung. Online available: <https://www.faz.net/aktuell/wissen/regulierung-der-ki-ingesetzbuch-fuer-roboter-16247534.html?GEP=s5>. Doshi-Velez, Finale; Kim, Been (2017): Towards A Rigorous Science of Interpretable Machine Learning. Online available: <http://arxiv.org/pdf/1702.08608v2>. Filipović, Alexander (2015): Die Datafizierung der Welt. Eine ethische Vermessung des digitalen Wandels 48 (1). Online available: <http://ejournal.communicatio-socialis.de/index.php/cc/article/view/901/899>. Fischer, Sarah; Petersen, Thomas (2018): Was Deutschland über Algorithmen weiß und denkt. Hg. v. Bertelsmann Stiftung. Online available: <https://algorithmenethik.de/wpcontent/uploads/sites/10/2018/05/Was-die-Deutschen-%C3%BCber-Algorithmen-denken-ohne-Cover.pdf>. Gola, Peter; Eichler, Carolyn; Franck, Lorenz; Klug, Christoph; Lepperhoff, Niels (Hg.) (2017): Datenschutz-Grundverordnung. VO (EU) 2016/679 : Kommentar. München: C.H. Beck. Grzymek, Viktor; Puntshub, Michael (2019): Was Europa über Algorithmen weiß und denkt. Hg. v. Bertelsmann Stiftung. Online available: <https://www.bertelsmannstiftung.de/fileadmin/files/BS/Publikationen/GrauePublikationen/WasEuropaUeberAlgorithmenWeissUndDenkt.pdf>. Han, Byung-Chul (2015): Transparenzgesellschaft. 1. Aufl. s.l.: Matthes Seitz Berlin Verlag. Online available: <http://gbv.ebib.com/patron/FullRecord.aspx?p=4346308>. Jaume-Palasi, Lorena; Spielkamp, Matthias (2017): Ethik und algorithmische Prozesse zur Entscheidungsfindung oder -vorbereitung. Arbeitspapier 4. Hg. v. Algorithm Watch. Online available: [https://algorithmwatch.org/wpcontent/uploads/2017/06/AlgorithmWatch\\_Arbeitspapier\\_4\\_Ethik\\_und\\_Algorithmen.pdf](https://algorithmwatch.org/wpcontent/uploads/2017/06/AlgorithmWatch_Arbeitspapier_4_Ethik_und_Algorithmen.pdf). Koska, Christopher (2015): Zur Idee einer digitalen Bildungsidentität. In: Harald Gapski (Hg.): Big Data und Medienbildung. Zwischen Kontrollverlust, Selbstverteidigung und Souveränität in der digitalen Welt. Düsseldorf, München: kopaed (Schriftenreihe zur digitalen Gesellschaft NRW, 3), p. 81–93. Online available: [http://www.grimmesinstitut.de/schriftenreihe/downloads/srdg-nrw\\_band03\\_big-data-undmedienbildung.pdf](http://www.grimmesinstitut.de/schriftenreihe/downloads/srdg-nrw_band03_big-data-undmedienbildung.pdf). Lück, Anne-Kathrin (2013): Der gläserne Mensch im Internet. Ethische Reflexionen zur Sichtbarkeit, Leiblichkeit und Personalität in der Online-Kommunikation. Zugl.: Zürich, Univ., Diss., 2012 u.d.T.: Lück, Anne-Kathrin: Zwischen Sichtbarkeit und Gläsertheit: ethische Überlegungen zur Kommunikation in sozialen Netzwerken und OnlineBewertungsportalen. Stuttgart: Kohlhammer (Forum Systematik, 45). Online available: <http://d-nb.info/1034216120/04>. Martini, Mario (2019) (in print): Blackbox Algorithmen – Grundfragen einer Regulierung Künstlicher Intelligenz. Unter Mitarbeit von Michael Kolain und Jan Mysegades: Springer. Miller, Tim (2017): Explanation in Artificial Intelligence: Insights from the Social Sciences. Online available: <http://arxiv.org/pdf/1706.07269v3>. Molnar, Christoph (2019): Interpretable Machine Learning. A Guide for Making Black Box Models Explainable. Online available: <https://christophm.github.io/interpretable-mlbook/>. Nissenbaum, Helen Fay (2010): Privacy in context. Technology, policy, and the integrity of social life. Stanford, California: Stanford Law Books an imprint of Stanford University Press. Online available: <http://site.ebrary.com/lib/academiccompleterites/home.action>. Schneider, Manfred (2013): Transparenzraum. Literatur, Politik, Medien und das Unmögliche. 1. Aufl. Berlin: Matthes & Seitz. Online available: [http://subhh.ciando.com/book/?bok\\_id=1016191](http://subhh.ciando.com/book/?bok_id=1016191).



#### Christopher Koska, MA

Partner at dimension2 economics & philosophy consult GmbH, Research Associate at zem::dg - Centre for Media Ethics and the Digital Society. His work focuses on data protection and context-sensitive recommendation technologies, semantic mashups, information visualization, human-machine interfaces and ethics of algorithms.



#### Prof. Dr. Alexander Filipovic

University Professor for Media Ethics, Member of the Enquete Commission “Artificial Intelligence - Social Responsibility and Economic, Social and Ecological Potentials” in the German Bundestag, Partner at dimension2 economics & philosophy consult GmbH.

# Maschinelles und Tiefes Lernen: Der Motor für „KI made in Germany“

Prof. Dr. Kristian Kersting, Prof. Dr. Volker Tresp

Künstliche Intelligenz (KI) erlebt aktuell einen wahren Boom. Aus einer Fachdisziplin der Informatik, deren Anfänge auf die 1950er-Jahre zurück gehen, wurde in den vergangenen Jahren ein viel diskutiertes und öffentlichkeitswirksames Thema. Grund dafür sind KI-basierte Anwendungen, die noch vor wenigen Jahren als Science Fiction galten: Intelligente sprachgesteuerte Assistenzsysteme unterstützen uns heute bei der Navigation, Bilderkennungssysteme interpretieren mit hoher Zuverlässigkeit Röntgenaufnahmen und automatisiertes Fahren wird zunehmend Realität. Die künftigen Auswirkungen von KI auf wirtschaftliche Prozesse wie auch unseren Alltag lassen sich längst nicht absehen – und kaum überschätzen. Die technologische Entwicklung darf daher nicht sich selbst überlassen werden, sondern muss begleitet werden. Wozu wollen wir KI nutzen? Wie kann ihr Einsatz dem Wohl der Gesellschaft dienen und den Wirtschaftsstandort Deutschland stärken? Diese Fragen gilt es in einem breiten öffentlichen Dialog zu klären. Damit verbunden sind zentrale Fragen für Forschung und Wissenschaft: Welche KI-Kompetenzen müssen wir in Deutschland aufbauen, um die gute Ausgangsposition in der internationalen KI-Forschung zu stärken? In welche Forschungsthemen sollte im Sinne einer zukunftsfähigen Ausrichtung künftig verstärkt investiert werden?

Technologische Treiber der aktuellen KI-Entwicklung sind das Maschinelle Lernen und das Tiefe Lernen. Verbunden mit der Verfügbarkeit von Massendaten sowie Fortschritten beim schnellen, parallelen Rechnen waren sie für die spektakulären KI-Durchbrüche der vergangenen Jahre verantwortlich – an-

gefangen von DeepMinds AlphaZero, welches durch intensives Spielen gegen sich selbst erlernt, mehrere Brettspiele auf übermenschlichem Niveau zu spielen, bis hin zu modernen Übersetzungs- und Bilderkennungssystemen. Gegenüber dem umfassenden Begriff der Künstlichen Intelligenz grenzen sich Maschinelles und Tiefes Lernen wie folgt ab:

- Künstliche Intelligenz definiert Herausforderungen, die es zu lösen gilt und entwickelt Lösungsansätze.
- Maschinelles Lernen ist eine grundlegende Methode der Künstlichen Intelligenz. Sie zielt darauf, dass Maschinen ohne explizite Programmierung eines konkreten Lösungswegs automatisiert sinnvolle Ergebnisse liefern. Spezielle Algorithmen lernen dabei aus den vorliegenden Beispieldaten Modelle, die dann auch auf neue, zuvor noch nicht gesehene Daten angewendet werden können.
- Maschinelles Lernen mit großen neuronalen Netzen wird als Tiefes Lernen (Deep Learning) bezeichnet. Es stellt derzeit einige der leistungsfähigsten Ansätze des Maschinellen Lernens bereit.

Heute werden smarte Lösungen noch vornehmlich manuell programmiert. So beinhaltet ein Smartphone etwa mehr als zehn Millionen Codezeilen. Die aktuellen Entwicklungen auf dem Gebiet der Künstlichen Intelligenz markieren jedoch einen Paradigmenwechsel: Statt Verarbeitungsschritte manuell zu kodieren, wird KI-basierten Systemen die Fähigkeit zu lernen programmiert. Mithilfe des Maschinellen Lernens können Agenten aus sehr vielen Beispielsituationen Muster erlernen

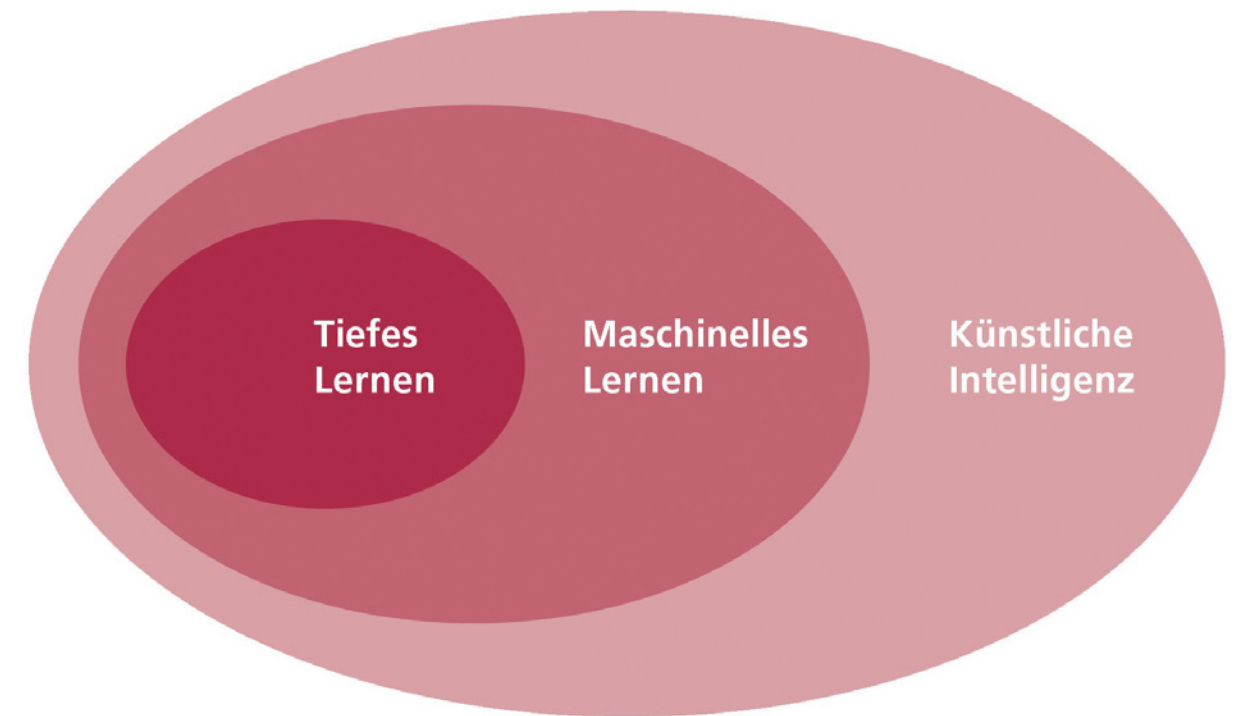


Abbildung 1: Zusammenhang zwischen Künstlicher Intelligenz, Maschinellem Lernen und Tiefem Lernen

und auf neue, ähnliche Situationen übertragen. Auch beim Maschinellen Lernen programmiert weiterhin der Mensch – allerdings nicht mehr fertige Lösungen. Stattdessen entwickelt er Programme, die aufgrund von Trainingsdaten die Lösung erlernen.

Die größten KI-Erfolge basieren derzeit auf tiefen neuronalen Netzen (Tiefes Lernen bzw. Deep Learning). Hierbei verarbeiten eine große Zahl an künstlichen Neuronen Eingangsinformation in mehreren Schichten und stellen am Ausgang das Ergebnis bereit. So sind beispielsweise moderne Übersetzungs- und Bilderkennungssysteme ohne Tiefes Lernen nicht denkbar. Neuronale Netzwerke besitzen eine hohe Expressivität, oder vereinfacht gesprochen: die Fähigkeit, jede kontinuierliche Funktion beliebig genau zu approximieren. Dadurch gestaltet sich ihr Training oftmals sehr daten- und zeitintensiv. Gleichzeitig ist es aber in der Regel möglich, ein für eine spezielle Aufgabe aufwendig trainiertes Netz über Transferlernen mit wenig Aufwand auf eine neue Aufgabenstellung anzupassen.

#### Expertise in Maschinellem und Tiefem Lernen ausbauen

Für eine zukunftsorientierte und erfolgreiche „KI made in Germany“ ist es unabdingbar, die Expertise für Maschinelles Lernen und Tiefes Lernen in Deutschland zu stärken – sowohl an Hochschulen, als auch in Forschungsprogrammen und Kompetenzzentren. Denn unabhängig davon, ob Daten als das „Öl des 21. Jahrhunderts“ in großem oder kleinem Umfang gesammelt werden: Ohne hochleistungsfähige „Raffineri-

en“ – also Methoden wie Maschinelles oder Tiefes Lernen – bleiben sie, was sie sind: Rohöl, das keinen (Wirtschafts-) Motor antreiben kann. Um sie in intelligente und nutzbringende Anwendungen zu überführen, benötigen wir Expertinnen und Experten mit exzellenter Kenntnis der Grundlagen und Verfahren des Maschinellen Lernens. Zu nennen sind hierbei beispielsweise das (un)überwachte Lernen, das Lernen durch Verstärkung (Reinforcement Learning), die Dichteschätzung, das Boosting und Ensemble-Methoden, Max-Margin-Modelle, Online- und Datenstrom-Lernverfahren, das relationale Lernen, Aufmerksamkeitsmodellierung, Memory Netze und andere Verfahren. Zu den Grundlagen gehören auch umfangreiche Kenntnisse in der Modellauswahl, der Datenbereinigung, der Merkmalsauswahl, der mathematischen Optimierung, der Statistik, der Interpretation von Modellen und ihren Ergebnissen und der Durchführung einer empirischen Evaluierung im Allgemeinen.

Stärken müssen wir auch die vorhandene Expertise im Bereich des Tiefen Lernens, insbesondere in den Teilgebieten wie neuronale Netzwerke, Convolutional Neural Networks oder rekurrente neuronale Netze sowie die Visualisierung bzw. Erklärbarkeit von tiefen Modellen. Für eine zukunftsorientierte KI-Forschung muss zudem die KI-Infrastruktur in Deutschland weiter auf- und ausgebaut werden – insbesondere durch Cluster, die Maschinelles und Tiefes Lernen mittels speziellen KI-Beschleunigern (z.B. GPU-/CPU-Cluster) unterstützen. Wichtig ist dabei vor allem, dass die Infrastruktur für alle Stakeholder mit ausgewiesener Expertise zur Verfügung



steht und die Leistungsanforderungen verschiedenster Anwendungen erfüllen kann. Darüber hinaus müssen verschiedene Konzepte – etwa für Sicherheits- und Vertraulichkeitsanforderungen – erprobt werden können. Zu beachten ist: In Zukunft werden sich KI-Infrastrukturen voraussichtlich stark von den heutigen unterscheiden. Deutschland sollte daher nicht nur auf ausgereifte Technologien setzen, sondern gezielt auch neue Rechenplattformen erforschen. Dies könnte zu einem Wettbewerbsvorteil werden.

#### Anforderungen an KI von morgen

Moderne KI-Anwendungen sind beeindruckend. Allerdings sind sie in der Entwicklung auch sehr kostenintensiv. Darüber hinaus erfordern viele KI-Ansätze – wie das Tiefe Lernen – meist gelabelte Trainingsdaten, deren Beschaffung schwierig, wenn nicht gar unmöglich ist. Ein wichtiges Ziel der Forschung ist es daher, diese Entwicklungsprozesse zu vereinfachen. Für viele Anwendungen ist es zudem essentiell, dass KI-basierte Vorhersagen und Entscheidungen zuverlässig und nachvollziehbar sind. Letzteres ist nicht in allen Fällen erforderlich. Tiefe Netzwerke sollen ja gerade in großen, hochdimensionalen Datenmengen Muster finden, die kein Mensch jemals entdecken könnte. Aus ethischen, juristischen und sozialen Gründen ist in bestimmten Domänen (z.B. in der Medizin) und bei bestimmten Aufgaben (z.B. bei Therapieempfehlungen) nachvollziehbares und zuverlässiges Verhalten jedoch unabdingbar.

Der Aufbau in vertrauenswürdige KI-Systeme erfordert neben einem fundierten KI-Fachwissen auch umfangreiche Programmierkenntnisse, Anwendungswissen sowie ein fundiertes Wissen im Umgang mit Unsicherheiten. Zusätzliche



Prof. Dr. Kristian Kersting

Prof. Dr. Volker Tresp

Prof. Dr. Kristian Kersting und Prof. Dr. Volker Tresp sind Mitglieder der Arbeitsgruppe „Technologische Wegbereiter und Data Science“ der Plattform Lernende Systeme. Der Beitrag fasst wesentliche Inhalte des kürzlich veröffentlichten Whitepapers Maschinelles und Tiefes Lernen – Der Motor für „KI made in Germany“ zusammen.



Professuren in den Bereichen Künstliche Intelligenz, Maschinelles Lernen und Tiefes Lernen können dazu beitragen, die benötigten Multiplikatoren auszubilden, auf dass sie ihre KI-Expertise weitervermitteln sowie in die Anwendung und Praxis tragen – auch zusammen mit anderen Disziplinen.

Der technologische Fortschritt im Bereich Künstliche Intelligenz ist so rasant, dass einzelne Technologien schnell veralten. Daher gilt es nicht nur die Algorithmen weiterzuentwickeln, sondern insbesondere den Transfer durch die „Köpfe“ in den Unternehmen zu stärken und auf diese Weise die Innovationskraft zu sichern. Firmen können nur innovativ sein, wenn ihre KI-Expertise auf dem neuesten Stand der Technik ist und ihre Fachleute mit den neuesten Technologien umgehen können. Neben der klassischen Fort- und Weiterbildung braucht es dazu unter anderem den Transfer über KI-Köpfe – also den personellen Austausch zwischen Wissenschaft und Wirtschaft. Neue duale Programme für Doktorandinnen und Doktoranden und insbesondere die Förderung von Gründungen und Start-ups sind hierfür vielversprechende Instrumente.

Viele Entscheidungsträgerinnen und -träger in Wissenschaft, Wirtschaft und Gesellschaft haben das große Potential der Künstlichen Intelligenz erkannt. Oft bestehen jedoch noch Vorbehalte. Um das Potential von KI-Methoden zu heben, sollten bestehende Verbindungen zwischen verschiedenen Fachdisziplinen, Studiengängen (z.B. in der Data Science, Maschinellem Lernen und/oder Künstlicher Intelligenz) und Firmen in Deutschland gefestigt und neue Brücken geschlagen werden. Die geplanten KI-Kompetenzzentren und die KI-Hubs sollten daher neben der Grundlagenforschung auch Kooperationsprojekte und -strategien entwickeln, beratend tätig sein und die Verbreitung von Forschungsergebnissen verstärken. Öffentliche Veranstaltungen und Beiträge in verschiedenen Medien tragen dazu bei, eine informierte Debatte in Gang zu setzen und ein realistisches Bild von Künstlicher Intelligenz in der Gesellschaft zu vermitteln.

Maschinelles Lernen wird auch in Zukunft ein Schlüssel zur Künstlichen Intelligenz sein – jedoch nicht der einzige. Zu erwarten sind zunehmend synergetische Lösungen, die unterschiedliche Paradigmen der KI-Forschung verknüpfen. Unterschiedliche Bausteine einer heute oft noch segmentierten KI-Forschung – wie etwa Computer Vision, natürliche Sprachverarbeitung, Robotik und Kognition – werden zusammenwachsen und neue Themen erschließen.

Referenzen: [1] Nach J. McCarthy ist Künstliche Intelligenz „the science and engineering of making intelligent machines, especially intelligent computer programs. It is related to the similar task of using computers to understand human intelligence, but AI does not have to confine itself to methods that are biologically observable“ (McCarthy 2007). [2] T. Mitchell definiert Maschinelles Lernen als die Wissenschaft, „that is concerned with the question of how to construct computer programs that automatically improve with experience“ (Mitchell 1997: 15).

Literatur: **Bundesregierung** (2018): Strategie Künstliche Intelligenz der Bundesregierung. [www.bmbf.de/files/Nationale\\_KI-Strategie.pdf](http://www.bmbf.de/files/Nationale_KI-Strategie.pdf) (abgerufen am 12. Juni 2019). **Marcus & Davis** 2018: A.I. Is Harder Than You Think, in New York Times. <https://www.nytimes.com/2018/05/18/opinion/artificial-intelligence-challenges.html> (abgerufen am 28. Mai 2019). **McCarthy** 2007: What is artificial intelligence? <http://jmc.stanford.edu/artificial-intelligence/what-is-ai/index.html> (abgerufen am 01. März 2019). **Mitchell** 1997: Machine Learning, New York City: McGraw-Hill. **Schoenick et al.** 2017: Moving beyond the Turing Test with the Allen AI Science Challenge, in: Communications of the ACM, Bd. 60, Nr. 9, S. 60 – 64. **Silver et al.** 2016: Mastering the game of Go with deep neural networks and tree search, in Nature, Nr. 529, S. 484-489. **Silver et al.** 2018: A general reinforcement learning algorithm that masters chess, shogi and Go through self-playing, in Science, Bd. 362, Nr. 6419, S. 1140-1144.

# KI-Systeme im produktiven Unternehmenseinsatz

Dr. Peter Kullmann, Dr. Andreas Baumann, Dr. Kay Schwieger

KI-Lösungen werden im Normalfall zunächst unter Laborbedingungen entwickelt. Um eine Lösung anschließend produktiv in der Unternehmens-IT zu betreiben, müssen organisatorische und technische Fragen beantwortet werden: Haben die Ergebnisse einer KI-Lösung überhaupt die Qualität und Zuverlässigkeit, die für die Akzeptanz im Unternehmen erforderlich sind? Sind Daten in ausreichender Qualität und Quantität verfügbar? Rechnet sich der Einsatz aus betriebswirtschaftlicher Sicht? Wie kann das KI-System in eine bestehende Anwendungsarchitektur integriert werden? Wie kann es überwacht werden?

Um ein KI-System nachhaltig zu betreiben, muss es kontinuierlich aktualisiert und nachjustiert werden. Laufend anfallende neue Daten können verwendet werden, um das Modell durch kontinuierliches Lernen zu verbessern. All dies erfordert Prozesse, die weit über die initiale Erstellung eines KI-Modells hinausgehen.

Im vorliegenden Artikel beleuchten die Autoren die verschiedenen Dimensionen, die beim Betrieb von KI-Anwendungen im Unternehmensumfeld betrachtet werden müssen, und zeigen verschiedene Lösungsansätze und Handlungsalternativen auf.

#### Anforderungen für den Einsatz von KI

Die Wahrnehmung der KI und der dort erzielten Fortschritte ist im Wesentlichen geprägt durch zahlreiche Medienberichte von neuen, aufsehenerregenden Ergebnissen aus dem Forschungsbereich. Implementierungen, die daraus

hervorgehen, haben jedoch in aller Regel experimentellen, „proof-of-concept“-Charakter und lassen sich nicht ohne Weiteres in produktive Systeme überführen.

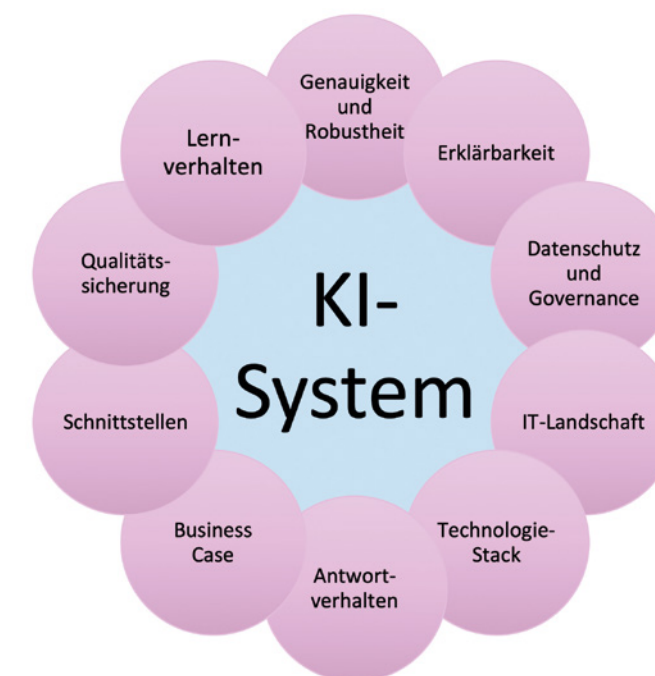


Abbildung 1: Anforderungsdimensionen

Die Entwicklung einer KI-Anwendung für den produktiven Einsatz beinhaltet jedoch deutlich mehr als die reine Lösung eines Problems mittels KI-Methoden. Dazu müssen von Beginn an die Anforderungen des Umfelds ganzheitlich betrachtet werden. Diese gehen meist über die eigentliche fachliche Problemstellung hinaus und haben unmittelbaren Einfluss auf die Auswahl des einzusetzenden KI-Verfahrens, wenn nicht sogar auf die Entscheidung für oder gegen ein KI-System. Weitere Anforderungen ergeben sich üblicherweise durch die nicht-funktionalen Anforderungen bzw. die Rahmenbedingungen des IT-Betriebs. Folgende Fragestellungen sollten u.a. abgeprüft werden:

- Welche Anforderungen werden an die Genauigkeit des KI-Systems gestellt?
- Unter welchen Rahmenbedingungen kann der Einsatz überhaupt erfolgen?
- Inwieweit ist eine Erklärbarkeit und Nachvollziehbarkeit der Ergebnisse notwendig?
- Wie soll die Anwendung in bestehende Systeme eingebettet werden?
- Welche Antwortzeiten werden gefordert? Sind Anfragen synchron oder asynchron?
- Wie wird die Qualität der Ergebnisse des KI-Systems überwacht? Gibt es einen Feedback-Mechanismus?
- In welcher Form soll das KI-System lernen? Offline? Inkrementell?
- Wie spielt die Anwendung mit anderen Systemen zusammen?
- Welche Einschränkungen bzgl. des Technologie-Stacks sind vorhanden?
- Welche Hardware-Ressourcen sind verfügbar?

Wenngleich viele dieser Kriterien aus der Anforderungsanalyse für klassische IT-Systeme entstammen, sind auch sie kritische Erfolgsfaktoren für die Entwicklung und den Einsatz von nachhaltigen KI-Systemen.

Erst wenn die Anforderungen an eine Lösung gesamtheitlich erfasst wurden, ist es sinnvoll, in einer systematischen Vorstudie geeignete KI-Verfahren zu wählen und zu verproben. Als Ergebnis sollte eine solche Studie die getesteten Verfahren nicht nur in Bezug auf die üblichen KI-Metriken, sondern auch entlang der erfassten Anforderungen bewerten.

#### Qualität = Akzeptanz

Missverständnisse, falsche Ausgaben oder Antworten von KI-Anwendungen sorgen im B2C-Umfeld bei den Betroffenen für Schmunzeln oder Irritationen. Im schlimmsten Fall wird die Anwendung deinstalliert und nicht mehr genutzt. Diese Wahlmöglichkeit haben Menschen, die im beruflichen Kontext KI-Anwendungen nutzen müssen, nicht. Entscheidungen der KI-Systeme haben daher einen sehr hohen Anspruch an Genauigkeit, d.h. an die Vermeidung von „False Positives“ und „False Negatives“. Während erstere einen Befund signalisieren, obwohl keiner vorliegt, werden bei „False Negatives“ real vorliegende Befunde übersehen. Beide verursachen zumindest Akzeptanzprobleme und haben – je nach Anwendungsbereich des KI-Algorithmus – unter Umständen gravierende Auswirkungen. Exemplarisch seien die Algo-

rithmen genannt, die etwa bei der Diagnostik medizinischer Röntgen- oder MRT-Untersuchungen, in der präventiven Kriminalistik, im Sicherheitsbereich zur Gesichtserkennung von Menschen und zur Früherkennung technischer Probleme an Maschinen mittels IoT genutzt werden.

In der betrieblichen Praxis bedeutet dies zusätzliche, manuelle Kontrolle durch Menschen. Wie häufig diese erforderlich ist, wird durch die Genauigkeit und Robustheit der eingesetzten KI-Systeme beeinflusst. Bei tausenden von Entscheidungen bzw. Bewertungen durch das KI-System führen allerdings bereits wenige Promille an „False Positives“ zu einem erheblichen Aufkommen an Nachkontrollen, die vom Bearbeiter leicht als überflüssige Arbeit klassifiziert werden kann. Nachdem aber alle bekannten KI-Methoden zudem auch eine gewisse Quote an korrekten Treffern nicht erkennen, werden im operativen Einsatz Schadensereignisse auftreten, die die KI eigentlich doch gerade verhindern sollte. Auf die Trefferquote des Erkennungsalgorithmus haben nicht nur der ausgewählte Algorithmus, oder gegebenenfalls die Kombination und Gewichtung mehrerer Algorithmen Einfluss, auch Art, Umfang und Bedingungen der Datenerhebung beeinflussen die Treffergenauigkeit.

Bestehen die Treffer zum überwiegenden Teil aus „False Positives“ und wird daher der Bearbeiter unnötig aktiviert, so sinken Akzeptanz, Nutzung und Nutzen des KI-Systems sehr schnell. Treten zudem Effekte von fälschlicherweise nicht erkannten Ereignissen auf, so verstärkt sich dieser Eindruck. Positiv formuliert: Gelingt es dem eingesetzten KI-System, dem menschlichen Nutznießer eine spürbare Entlastung seiner Arbeitstätigkeit zu bieten, so fördert das die Akzeptanz und motiviert zur weiteren Nutzung.

Eng verbunden mit der Akzeptanz-Problematik ist die Frage, welche Anforderungen an die Erklärbarkeit der KI-Ergebnisse gestellt werden. Denn obwohl es bezüglich neuronaler Netze viele Forschungsaktivitäten und erste Ergebnisse und Verfahren in diesem Bereich gibt, kann die mangelnde Nachvollziehbarkeit bei neuronalen Netzen ein Ausschlusskriterium sein. Als Beispiele hierfür sind gesetzliche oder regulatorische Vorgaben bezüglich Nachvollziehbarkeit von Entscheidungen sowie Vorgaben zur diskriminierungsfreien Entscheidungsfindung genannt. Andere Verfahren, die z.B. auf statistischen Verfahren beruhen, oder regelbasierte Verfahren bieten diesbezüglich große Vorteile. Im Allgemeinen wird es im betrieblichen Umfeld schon aus rechtlichen Gründen notwendig sein, dass die Ergebnisse eines KI-Systems vom menschlichen Betrachter nachvollzogen werden können. Dies ist in Form eines geeigneten Erklärungsmechanismus zu berücksichtigen.

Neben der psychologischen und motivatorischen Wirkung des Einsatzes muss auch die betriebswirtschaftliche Kostenbetrachtung berücksichtigt werden. Während die KI-gestützte Entlastung des Arbeitsprozesses auf den vorab erstellten Business-Case einzahlt, sorgen die fälschlicherweise gemeldeten bzw. übersehenen Effekte für Bearbeitungsaufwand. Dieser benötigt neben Arbeitszeit häufig auch noch den Einsatz weiterer Ressourcen (Material, Transport etc.). Daher sind stabile und robuste Systeme essenziell für den Einsatz im betrieblichen Alltag.

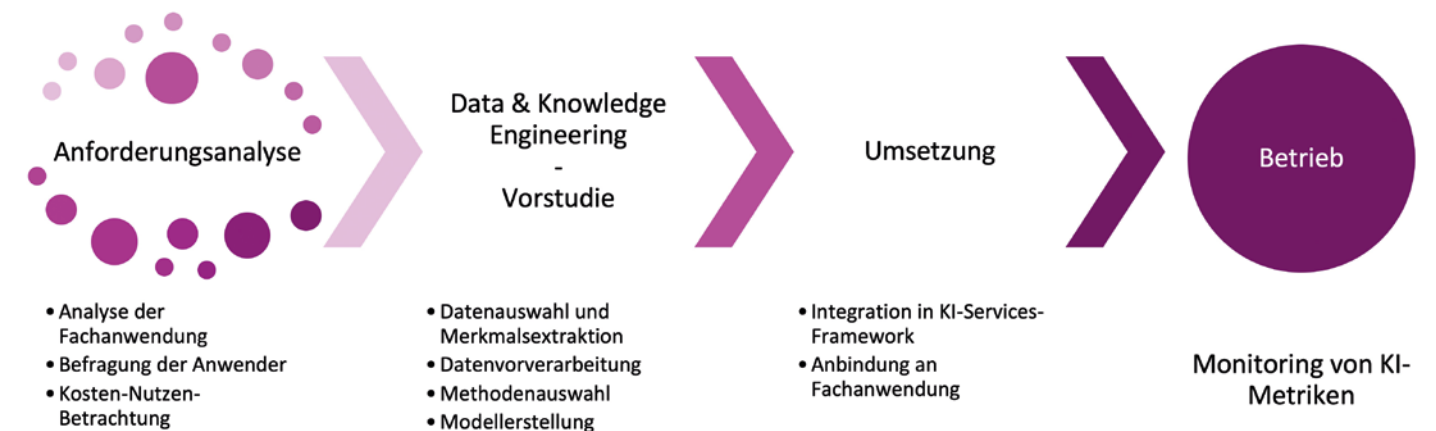


Abbildung 2: Vorgehensmodell für die Umsetzung von KI-Projekten

#### Daten für die KI

Der Einsatz von Systemen, welche sich der Unterstützung von Künstlicher Intelligenz bedienen, basiert in der Regel auf einer umfangreichen Datensammlung. Auf dieser werden die Algorithmen trainiert, entwickelt und bewertet.

Dementsprechend ist die erste Frage bei der Verwendung von KI-Systemen im unternehmerischen Einsatz die nach der Art der Daten, auf deren Basis Aussagen getroffen werden müssen. Technische Daten von Sensoren einer Maschine, die etwa versuchen Ermüdungserscheinungen zu erkennen, sind deutlich anders zu klassifizieren als etwa Systeme zur Gesichtserkennung in Sicherheitsbereichen. Gegebenenfalls sind hier neben den einschlägigen Vorgaben etwa der DSGVO auch Arbeitsgesetze, betriebliche und sonstige Vereinbarungen zu beachten.

Gut gemeinte, aber schlecht gemachte oder schlecht kommunizierte KI-Einsätze sorgen in den Medien für negative Publicity und öffentliche Aufregung und können somit leicht Probleme verursachen, die größer werden als der eigentliche Nutzen.

Neben der Art spielen Qualität und Quantität der zur Verfügung stehenden Daten eine weitere, wesentliche Rolle. Während für die Suche nach Katzen auf privaten Fotoaufnahmen ein nahezu unerchöpflicher Fundus an Testdaten und Qualifikation selbiger vorliegt, gibt es im industriellen Kontext Situationen mit wenigen oder nur beschränkt nutzbaren Daten. Ursachen dafür können (zu) spezielle Fragestellungen, technische bzw. organisatorische Probleme der Erhebung oder regulatorische Beschränkungen sein.

Das hat zur Folge, dass bestimmte KI-Methoden ihre Stärken nicht ausspielen können, weil nicht ausreichend Datenmaterial zum Training vorhanden ist. Es empfiehlt sich daher, sorgfältig zu betrachten, mit welcher KI-Methode oder -Kombination derselbigen mit dem vorliegenden Set an Daten die besten Ergebnisse erzielt werden können.

Eine der großen Herausforderungen, an der die KI-Forschung gerade arbeitet, besteht darin, Daten auch dann verarbeiten zu können, wenn diese von schlechter Qualität sind. Bekannte Beispiele hierfür sind etwa das autonome Fahren, welches Hindernisse oder Personen auch dann erkennen muss, wenn die Lichtverhältnisse schlecht sind, es regnet, Nebel oder Staub in der Luft liegt oder andere Effekte ein suboptimales Ausgangsdatenmaterial bereitstellen. Analoges gilt für die Gesichts- und Personenerkennung, wie sie etwa in Sicherheitsbereichen eingesetzt wird. IoT-Sensoren, die Daten über den Betriebszustand einer Maschine oder Anlage weitergeben, müssen dies ebenfalls auch unter widrigen Bedingungen wie Hitze, Kälte und mechanischer Beanspruchung robust und zuverlässig erledigen.

Erschwerend kommt zu den genannten Herausforderungen häufig noch hinzu, dass die erhobenen Daten als Betriebsgeheimnis eingestuft werden. Dies steht einer Veröffentlichung in einem größeren Datenpool, aus dem mehrere Unternehmen Optimierungen schöpfen könnten, entgegen.

Genau die umgekehrte Herausforderung stellt sich in Situationen dar, in denen extrem umfangreiche Volumina transportiert und verarbeitet werden müssen, wie etwa im Bereich des autonomen Fahrens. Werden dort die erfassten

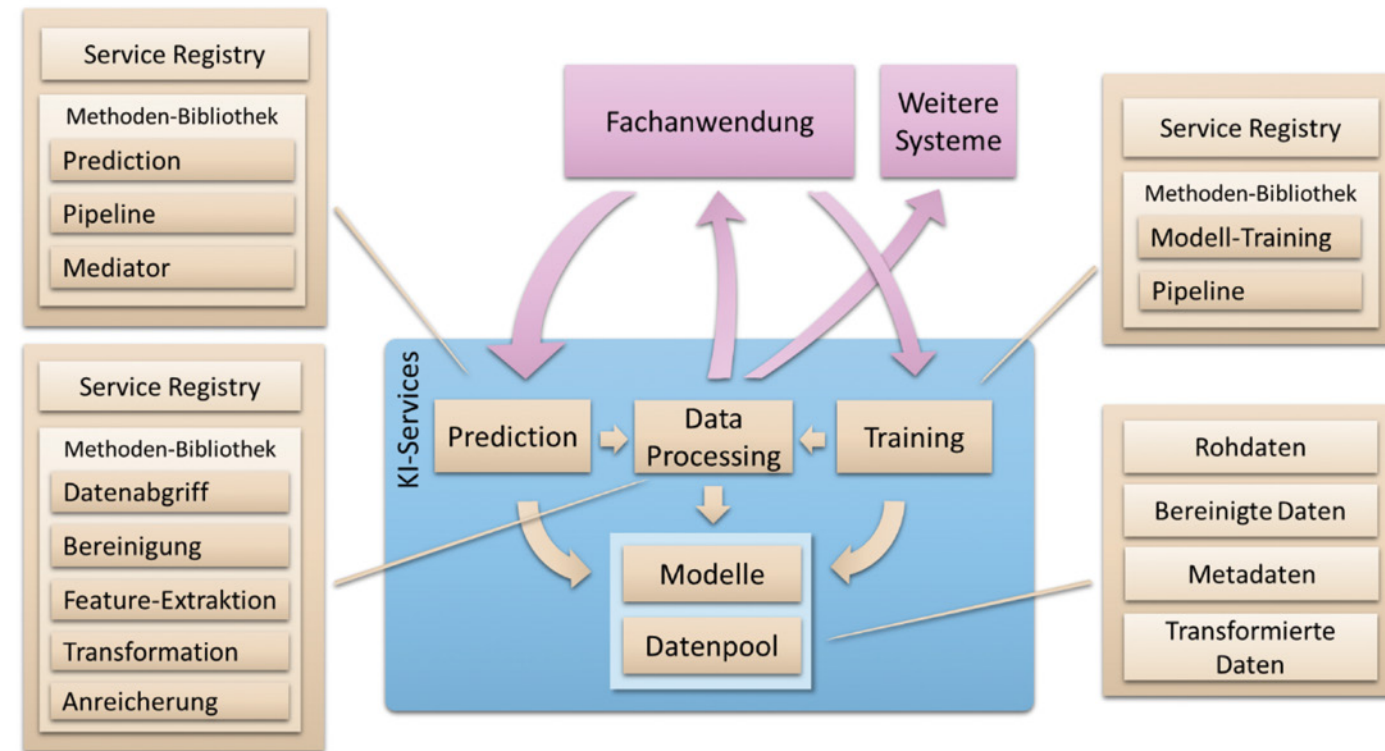


Abbildung 3: Komponenten einer generischen KI-Service-Architektur

Sensordaten nach einer Testfahrt zur weiteren Optimierung des KI-Algorithmus übertragen, gelangen nahezu alle Hardware- und Netzwerkkomponenten an ihre technischen Grenzen. Enge Abstimmung und Zusammenarbeit mit dedizierten Experten auf diesen Bereichen ist dann unabdingbar.

#### Integration von KI-Systemen in die IT-Landschaft

In aller Regel wird ein KI-Verfahren als Sub-Modul einer größeren Fachanwendung eingesetzt. Oftmals ergänzt ein KI-Verfahren auch ein bereits bestehendes System durch intelligente Vorschläge oder im Ersetzen manueller Prozessschritte durch Automatismen. Statt daher das KI-Verfahren als integralen Bestandteil eines Systems zu betrachten, spricht vieles dafür, die KI-Berechnungen als unabhängige Dienste zu organisieren und auszulagern:

- KI-Verfahren benötigen u.U. dedizierte Spezial-Hardware und müssen in einer separaten Betriebsumgebung ablaufen.
- KI-Methoden lassen sich bündeln und ggf. durch mehrere Systeme nutzen.
- Die Kernfunktionalität der KI ist agnostisch bezüglich der Fachlichkeit und kann von einem unabhängigen Entwicklungsteam bearbeitet werden.

Einen Schritt weiter geht man, wenn man KI-Berechnungen als abstrakte Dienste betrachtet, die über eine einheitliche Schnittstelle angesprochen werden können. Zusammen mit einem generischen Ansatz, der es ermöglicht, KI-Dienste dynamisch auf der Basis einer Bibliothek von KI-Verfahren

zu erstellen, ergeben sich daraus weitere Vorteile:

- Die Parametrisierung von KI-Verfahren kann dynamisch angepasst werden.
- KI-Modelle können ohne Änderung an der aufrufenden Anwendung ausgetauscht werden.
- Es können parallel verschiedene KI-Verfahren bereitgestellt und ggf. auch mehrere Verfahren kombiniert werden.

Nicht vergessen sollte man an dieser Stelle die Notwendigkeit der Datenvorverarbeitung, die sowohl bei der Erstellung von KI-Modellen als auch bei der Auswertung notwendig ist. Dies beinhaltet die Beschaffung von Daten, die Filterung, die Bereinigung und schließlich die Extraktion von Merkmalen. Auch diese Funktionen sind als Teil einer KI-Architektur zu berücksichtigen, da sie ggf. auch zur Vorverarbeitung von Anfragen an das KI-System benötigt werden.

Ein weiteres Modul einer solchen KI-Service-Architektur kann das Trainingsmodul sein, wenn es erforderlich ist, dass das System im laufenden Betrieb lernt und KI-Modelle kontinuierlich angepasst werden sollen. Dazu sind wieder die notwendigen Schritte der Datenvorverarbeitung zu berücksichtigen. Der Lernprozess kann entweder durch direktes Anwenderfeedback oder aber durch das Anfallen neuer Lerndaten aus anderen Datenquellen ausgelöst werden.

Die Open-Source-Frameworks Apache PredictionIO [1], Hydrosphere.io [2] und Seldon [3] sind Beispiele für Systeme, die die genannten Aspekte in unterschiedlichen Ausprägungen realisieren.

#### Von der Planung zur Implementierung

Bei der Implementierung von KI-Anwendungen bietet es sich im hier betrachteten industriellen Kontext an, auf den reichhaltigen Fundus vorhandener Implementierungen von KI-Methoden zurückzugreifen, sofern nicht Grundlagenforschungsarbeit geleistet werden soll.

Wie in jedem Umsetzungsprojekt stellt sich die Frage nach Qualität, Aktualität, Stabilität und Sicherheit von verwendeten Frameworks oder Bibliotheken. In manchen Fällen kann auch eine individuelle, auf die Anwendungsdomäne zugeschnittene Implementierung deutlich performanter sein, als die Verwendung von generischen Bibliotheken. In jedem Fall muss berücksichtigt werden, dass eventuell die Auswahl von verwendbaren Technologien durch Unternehmensvorgaben, IT-Governance oder der Zielbetriebsumgebung eingeschränkt ist.

Erlauben die rechtlichen Rahmenbedingungen die Verarbeitung von Daten in der Cloud, kann auf das entsprechende Repertoire von KI-Methoden der Cloud-Anbieter zurückgegriffen werden. Dies hat mitunter den Vorteil, dass dort auch die maßgeschneiderten Hardware-Ressourcen verfügbar sind.

Ein weiterer zu berücksichtigender Punkt ist der Umgang mit der Aktualisierung von KI-Modellen. Findet kontinuierliches Lernen statt, verhält sich das System aus Anwendersicht nicht-deterministisch, da es bei zeitlich versetzten, aber inhaltlich identischen Ausgangsdaten unterschiedliche

Ergebnisse zurückliefern kann. Das macht das Vorhandensein einer Erklärungskomponente umso wichtiger. Aus Performancegründen kann es je nach KI-Verfahren jedoch prohibitiv sein, eine Erklärung bei jeder Berechnung der KI-Vorhersage mit zu protokollieren und stattdessen eine bedarfsweise Erklärung in einer separaten Anfrage berechnen zu lassen.

#### Betrieb und Wartung

Dem DevOps-Gedanken folgend sollten auch für KI-Systeme Integrations- und Deployment-Verfahren so weit wie möglich automatisiert werden, damit eine problemlose Aktualisierung des Systems möglich wird. Abweichend von klassischen Systemen beinhaltet der CI/CD-Prozess die Aufbereitung und das Ausspielen eines vorbereiteten KI-Modells. Entsprechend müssen Integrationstests das Zusammenspiel zwischen KI-Kern und einem neuen KI-Modell testen, bevor ein Deployment in die produktive Umgebung erfolgen kann.

Bereits das normale Anwendungsmonitoring überwacht die Gesundheit und das normale Verhalten aller Systemkomponenten. Bei KI-Systemen empfiehlt es sich, darüber hinaus weitere Metriken zu erheben, um Auskunft über die Qualität der Vorhersagen des KI-Systems zu erhalten. Unter Umständen gestaltet sich dies schwierig, wenn die Vorhersagequalität erst verzögert oder nicht für jeden Einzelfall ermittelt werden kann. Erschwerend kommt hinzu, dass das Absinken der Qualität von Vorhersagen unterschiedliche Ursachen haben kann. Diese reichen von der Qualität der Eingabedaten, über die Parametrisierung des KI-Verfahrens bis zu einem fehlerhaften oder nicht ausreichend trainierten Modell. Daraus folgt, dass der Betrieb eines KI-Systems besondere Fachkenntnisse erfordert, die in der Regel über die Qualifikation der Mitarbeiter des typischerweise anzutreffenden, klassischen IT-Betriebs hinausgehen. Vielmehr erfordert das Operating von KI-Anwendungen noch mehr die Überschneidung zwischen Betrieb, Entwicklung und fachlicher Betreuung, als dies im DevOps-Kontext sowieso schon angestrebt wird.

#### Fazit

KI-Methoden bringen nicht nur eine neue Qualität bei den Möglichkeiten der Datenverarbeitung mit sich, sie stellen auch gänzlich neue Anforderungen bei der Umsetzung und dem Betrieb im produktiven Unternehmenseinsatz. Welche KI-Methode dabei zum Einsatz kommt, hängt nicht nur von dem fachlichen Problem ab, sondern wird auch durch zahlreiche andere Rahmenbedingungen, organisatorischer sowie technischer Natur, bestimmt. Zentrale Erfolgsfaktoren sind die Akzeptanz und letztendlich der betriebswirtschaftliche Nutzen, die zum nachhaltigen Einsatz einer KI-Anwendung führen.

Links [1] <https://predictionio.apache.org/> [2] <https://hydrosphere.io/> [3] <https://www.seldon.io/>



#### Dr. Peter Kullmann

Dr. Peter Kullmann ist seit 2014 als Senior IT Architect bei der iteratec GmbH tätig, wo er als Projektleiter und Architekt unter anderem KI-Projekte bei industriellen Kunden betreut. Er studierte Informatik in Karlsruhe und promovierte im Bereich KI und Kognitive Systeme an der Universität Karlsruhe



#### Dr. Andreas Baumann

Dr. Andreas Baumann ist bei der iteratec GmbH in Stuttgart als Projektbereichsleiter tätig und verantwortet in dieser Funktion unter anderem KI-Vorhaben bei Kunden der iteratec.



#### Dr. Kay Schwiieger

Dr. Kay Schwiieger ist als Senior Software Engineer bei der iteratec GmbH tätig und beschäftigt sich neben KI-Themen auch mit Quantencomputing. Er studierte Mathematik an der Technischen Universität Darmstadt, wo er auch im Bereich algebraische Wahrscheinlichkeitstheorie und mathematische Physik promovierte.

# Building the Future of the Construction Industry through Artificial Intelligence and Platform Thinking

Svenja Oprach, Tobias Bolduan, Dominik Steuer, Michael Vössing, Shervin Haghsheno

## Abstract

Data in the construction industry is heterogeneous, organizations do not work closely together, and construction software is highly specialized for individual users and applications. As a result, knowledge from previous construction projects is often not shared, linked, or transferred to subsequent projects. Additionally, the manual work on-site leads to long and unstable design and construction processes. Based on a review of common challenges in this work a new vision for the Architecture, Engineering, and Construction (AEC) Industry is developed. A platform thinking approach with methods of artificial intelligence (AI) for data preparation and for construction applications can benefit existing companies and support the overall ecosystem with innovative as well as disruptive business models. Additionally, a new ecosystem can emerge. This article shows how artificial intelligence can be established in the AEC Industry. The proposed approach suits applications in the whole value chain of design and construction. The implementation of a platform thinking approach throughout the industry is still missing, but its implementation in parts already shows great benefits. In a current research project, a platform ecosystem will be established and used to implement a number of prototypical applications. Using the proposed approach, construction data can be structured and linked with data from other organizations while simultaneously ensuring legal and technical security for the users. Ultimately, the resulting database will enable various applications within the industry.

## 1 Introduction

### 1.1 Characteristics and current challenges in construction

The German construction industry is following a trend of below-average productivity growth with approximately 1,5% until 2020. To overcome this the industry is embracing digitization in pursuit of an intelligent “Construction Site 4.0” similar to Industry 4.0. Digital planning methods such as Building Information Modelling (BIM) already exist and mark a step in the right direction. However, only a small proportion of companies

makes use of it, and a lack of knowledge often undermines the possible gains. This endangers their competitiveness by missing out on potential new business opportunities. (Baumanns, Freber, Schober, & Kirchner, 2016)

Some of the most significant challenges that the AEC industry faces are in the areas of communication, document management, and interoperability. The reasons for this are an existing tendency to develop many specific separate standards for individual tasks, e.g., only 5-7% rely on the BIM-method. This leads to a decentralized heterogeneous data environment with a high amount of created data sets that are very hard to access and use. (Froese, Han, & Alldritt, 2007), (Fulford & Standing, 2014), (Roland Berger, 2016), (BauInfoConsult, 2016). In comparison, a recent survey in the UK showed that BIM is already used in 19% of construction projects (USP Marketing Consultancy, 2019).

This situation is further strengthened by the complexity of the AEC industry itself with its many phases and partners from different disciplines (Shen et al., 2009). The high fragmentation and the demand for new IT-solutions of the AEC industry is especially challenging for small and medium-sized enterprises (SMEs) which make up 99,9% of all German construction companies (Die deutsche Bauindustrie, Gallaher, O’Connor, Dettbarn, & Gilday, 2004, Shen et al., 2009). These companies currently cannot compete with large enterprises in terms of digitization and continue to fall behind (Tata Consultancy Services (TCS) und Bitkom Research, 2018). Currently, most of the decisions made in German companies are based on gut feel and personal experience and are not data-driven. Only one in ten companies across all industries in 2018 utilized AI to support their decision-making and only 2% base their decisions entirely on AI. (Sopra Steria Consulting, 2018)

There is a need for making data sets from various sources interoperable and interpretable, as well as a web-based collaboration and software solution that can cover entire project lifecycles (Fulford & Standing, 2014).

### 1.2 Contribution

The highly fragmented industry and the heterogeneous data structures lead to several research questions related to an AI based platform approach.

As stated before, data in the AEC sector is highly heterogeneous and originates from several isolated sources. Furthermore the AEC industry is fragmented, mostly consisting of SMEs highly depending on each other, yet collaboration is recognized as a significant issue by various sources (see Chapter 1.1). As mentioned in Chapter 1.1, processes in the AEC industry are dynamic, reliant on external variables and decisions are commonly based on feelings and personal experience instead of data.

The following questions arise from the status quo which is described above:

- How can diverse and heterogeneous data sources be transformed to a machine-interpretable structure?
- How can participants in the AEC industry better collaborate with each other?
- How can the business processes be optimized by data based collaboration? How can this support the implementation of an ecosystem to facilitate new business models?

As a possible solution for the mentioned challenges, this paper is proposing a new AI-based platform approach. Data and information shall be processed and enriched by AI, people and organizations shall collaborate on a web-based platform, and AI-based applications shall empower SMEs by using processed and enriched data.

## 2. Methodology

A review of the current situation and challenges of the AEC industry was done based on various academic and practical sources. Academic papers were found by searching for trends and opportunities in the AEC industry. By evaluating these and backtracking their sources, a general impression of the worldwide situation of the AEC industry but mostly in North America and Germany was developed. To validate this impression with an emphasis on the German industry, several practical sources were evaluated. These include various surveys in which members of the German AEC industry answered to the state of digitization, use of software and upcoming challenges and were mostly found on statista.com. Other practical sources include publications by consulting company’s evaluation of the current situation, trends, and future needs of the industry.

Overall academic publications were used to generate an overview of the current situation from an academic perspective and were then validated using practical sources like surveys and evaluations by consulting companies.

Based on the identified challenges, possible solutions and their value were derived on a theoretical basis.

## 3. The idea of an AI construction platform

### 3.1 Requirements for an AI construction platform

Data management is a fundamental challenge in the AEC industry. Due to a strong, so-called, project-based thinking, conducted projects are rarely documented with the future reuse of structured data in mind. Projects are typically recorded on

varying levels of detail, in different formats and utilize different terminology. Therefore, the capability to analyze unstructured data is essential to make the majority of data sources usable.

To secure company-internal process data, the topic of data security is highly relevant. Thus, the resulting platform must ensure a separation of raw data from the developed algorithms. Only the trained algorithms are available in the platform in the form of metadata. In this way, companies can learn from each other without having to release internal data sets.

Due to the low digitization of SMEs, the aim is to provide them easy access to the platform and its applications. Here it is important to design the interactions between man and machine in a way that the effort for the structured digitization of data is reduced and the resulting potentials generate a more significant benefit.

### 3.2 The resulting AI construction platform

Based on the current challenges, the aim is to enable the medium-sized AEC industry to meet current challenges through AI-based solutions and thus to sustainably strengthen its competitiveness. The overall target, therefore, is to develop a digital platform that enables all parties involved in the AEC industry to process heterogeneous data, regardless of its quality, formatting, and localization, and thus make it usable. Besides, the platform serves as a significant hub for cross-company collaboration, enabling data to be intelligently linked, enriched, and shared. On this basis, it is possible to develop special AI-based applications that automatically and dynamically enable a data-driven decision-making process through collaboration between man and machine. The development of new applications is promoted by a separate developer interface, which allows documentation based on sample data sets, including access via APIs.

These goals give rise to the following three main fields of action:

- 1) AI-supported data preparation and transformation, regardless of the heterogeneity, quality, formatting and localization of the source data.
- 2) Development of a digital platform as collaboration hub and possibilities for tool connection, including user and developer interface.
- 3) Development of AI-supported applications for the automatic and dynamic support of data-driven decision-making processes.

In the abstract, digital platforms can be defined as products, services or technologies that serve as the basis for a variety of companies to offer complementary products, services, and technologies. The structural elements of a platform comprise core components and a periphery. The core represents the actual platform by defining technological- and business-driven “rules of the game” such as interfaces and processes. The stabilization and reuse of the core components lead to economies of scale and reduces the costs for the variety provided by the second part - the periphery. The periphery shows a high development speed and heterogeneity. The companies in the periphery form an ecosystem of the platform. They do not necessarily enter into business relationships with each other but are often independent participants in the same platform. (Baums, 2015)

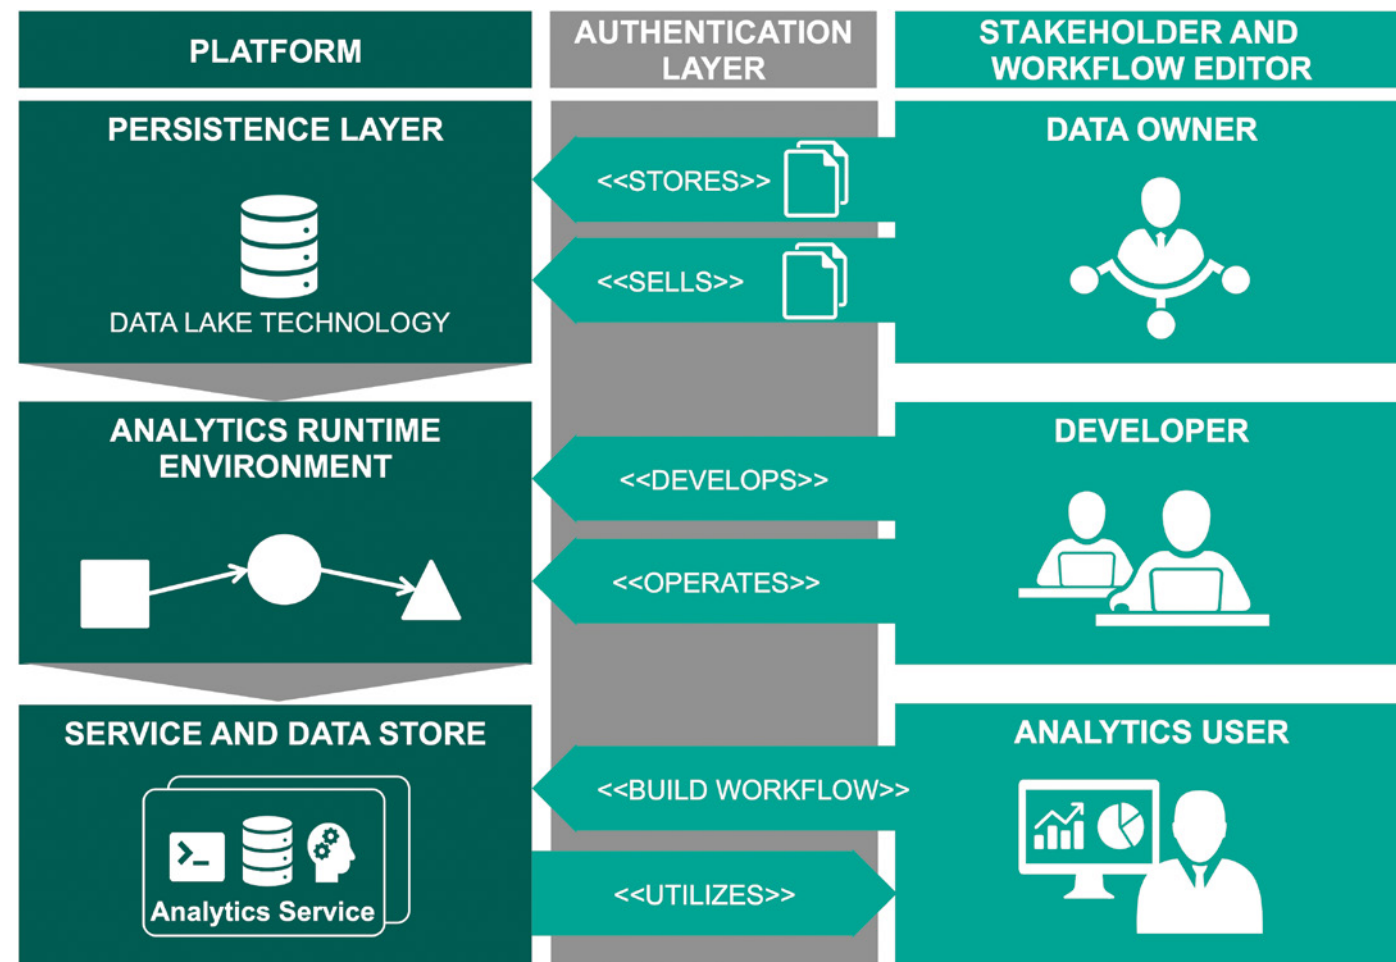


Figure 1: Platform architecture for an AI construction platform

### 3.3 AI construction platform architecture

There are four crucial modules within the platform: The Persistent Layer, the Analytics Runtime Environment, the Service Store, and the Authentication Layer. The four modules are described in figure 1.

Data owners can upload raw data to the Persistence Layer. If required, the persistence layer can perform pre-processing. This is especially the case, if the data is not structured and digitized. Pre-processing in the form of structuring can again be done by a service from the Service Store.

In the Analytics Runtime Environment, AI creates data interoperability and processability. New data sets promote the learning progress of the AI and extend the data interoperability and quality of the preparation. Furthermore, the developer is free to choose his development tools. At the end, his software must be available in the form of a self-contained container that can be persisted in the platform. He accesses the trained algorithms and example data sets for the development of the algorithms.

In the Service Store the developed micro services are managed, and data is offered for sale. A service can bring its logic, persistence, and AI. These developed services allow users to run their data and purchase additional data to increase forecasting capabilities. If compatible, the services can be connected in series. This enables a wide variety of optimization for existing business models.

The Authentication Layer manages authorization throughout all levels of the platform. The platform imposes a clear separation between the raw data and the trained algorithms. On the one hand, data security can be guaranteed and on the other hand, companies can learn from each other without releasing data.

### 3.4 Possible applications in AEC with AI

Bobriakov (2019) elaborates eight possible use cases in a data science blog: These reach from predictive analytics (as an accurate simulation before construction and design issue prediction), to a warranty analysis (as analyzing construction project risks and tracking construction equipments and assets) to an optimization (as the contractor performance optimization, accurate budgeting, and scheduling). Resulting, he also mentions as two further implications the possibility to support the automation on construction sites as well as supporting the product development. The last two mentioned use cases will be further analyzed in this paper in the resulting ecosystem and their business models. These use cases so far do not include the challenges with the heterogeneous data sets. Therefore, the following five possible applications of AI in AEC will explain design, realization to operation including the implications of heterogeneous data sets:

Finding and labeling equal parts: AI supports the designer

in finding, detailing, and cataloging identical elements in the building model. These can be drone or satellite images as well as 2d plans. The items can then be linked by technical object requirements with open data platforms as product information (e.g., prices and availability).

Recognizing design contexts and rules: By identifying design contexts and rules, the designer can be supported to identify relevant next steps, as well as to define modules and rooms. As Chaillou (2019) also shows in an AI architecture approach, rooms and their functionality can be already identified. If this idea is continued further and if cross-discipline contents can also be identified, a room with its possible contents can be designed at a very early stage and presented to the architect and the specialist designers as an initial draft. The resulting design machine can support the overall design. The conversion of the room program into a draft is a complex design task and can be visualized much more broadly with more variants, accelerated and quality assured by the use of AI.

Realization planning: To support execution planning, work package sequences can be predicted by sequential pattern mining. It is also possible to determine the duration of the respective work packages as well as the expected construction time, taking into account past projects. On this basis, logistical measures can be derived (such as required storage areas, materials per calendar week, transport capacities). In this way, routes can be optimized and information passed on to suppliers and manufacturers. Here the points of the two applications of Bobriakov (2019) – the prediction and the optimization – are matching.

Intelligent quality management: A further application can support the construction management and the involved construction companies in finding quality challenges, giving information about these as well as optimizing the plans regarding current changes. The platform services need to work closely with the site management through natural interaction via voice control as well as image recognition by drones and satellites. This application area is supported by the warranty analysis application of Bobriakov (2019).

Predictive Facility Management: The AI analyses the operating data of the maintenance and malfunction-relevant components connected to the building control system and can thus make predictions on malfunctions and optimum maintenance intervals. Before a component fails, it can be serviced or replaced. The operating times are maximized and thus the downtimes and costs are minimized.

## 4. Incubating the ecosystem

Based on these applications the overall ecosystem will be incubated by generating new business models. These innovative and disruptive business models are divided in six growing business areas described in the following.

Services for collecting and generating AEC data: The data platform fundamentally changes the view of the value of AEC data. Experience will currently be shared from construction project to construction project. Often only company-internal experiences are collected. If building data is seen as a value, monetary values can be seen in many public places. Images of buildings can serve to improve algorithms to enable optimal architectural design of buildings with their environmental con-

ditions. Furthermore, relevant IoT data can be identified, linked and monetized. In this way, open and existing data platforms can be used and enriched with value.

Data monetization: On the data platform, data can be exchanged and sold on a data marketplace. AEC companies can differentiate between internal company data and data that can be sold. Satellite images, data on the subsoil or material information on building components can be sold without having to release company-internal data.

Platform business model: The operation of the platform represents another business model. Via access to trained algorithms or metadata as well as access to applications in the store, fees can be charged on a pro-rata basis. This ensures the continuous operation of the platform.



### Svenja Oprach, MSc

Since 01/18: Research Associate in the Pro-Motion Program of BMW AG in cooperation with the Karlsruhe Institute of Technology (KIT)  
01/2016-12/2017: Expert for Lean Construction in the BMW AG Construction Department  
10/2009-11/2015: Study of Industrial Engineering at the KIT



### Tobias Bolduan, BSc

10/2018 - 06/2019: Master Thesis at BMW AG, A new approach for integrating BIM and GIS based on Model View Definition and Profiling Geospatial Application Schemas, Technische Universität München (TUM)  
10/2015 - 07/2019: Master of Science, Environmental planning and ecological engineering



### Dominic Steuer

Since 06/2018: Research Associate at the Karlsruhe Institute of Technology  
Since 03/2018: Manager at Steuer Tiefbau GmbH  
08/2016 – 03/2019: Specialist, Project Engineer at BMW Group in Oxford  
10/2009 – 05/2016: Study of Industrial Engineering at the KIT with focus on Entrepreneurship, Construction and Innovation



### Michael Vössing

Since 05/2016: Research Associate at the Karlsruhe Institute of Technology  
10/2009 - 04/2016: Study of Industrial Engineering at the KIT



### Dr.-Ing. Dipl.-Kfm. Shervin Haghsheno

Since 2013: University professor at the KIT  
2004-2013: Various positions at Bilfinger GmbH  
1999-2004: PhD at the Institute for Construction Management, TU Darmstadt  
1994-1999: Study of Civil Engineering, TU Darmstadt, and Economics, Distance University Hagen

Technical application development: Technical software developers use open APIs to build applications that access the metadata. These applications can be offered in the platform's store to an AEC company. In this way, existing business models can be continuously improved and highly manual, repetitive processes can be reduced.

Development of services in AEC companies: By reducing waste in processes, AEC companies free up personnel. With the staff freed up, further additional services for the customer can be made possible. The client receives a personal consultant who advises him on decisions and shows alternatives via data-driven evaluations. The site manager is trained or additionally supported in the fields of mediation and communication. Safety and health consultants accompany trades, pay attention to the correct use of applications and optimize their processes with regard to ergonomic aspects.

Innovative business models: Finally, completely new, disruptive business models can emerge, based on the platform. Construction machines are no longer rented per construction project; for example, an excavator is instead rented according to the number of lifts used. Furthermore, new construction machinery and materials can be developed on the basis of transparent data. Construction workers are trained to master several professions and jump between construction sites according to current needs.

The value of a platform increases with each additional member, as the new customer can potentially come into contact with any producer. In comparison, in the pipeline model, only one new customer relationship is gained. The network effects are mainly driven by the cost-effective use of platforms (procurement of a smartphone, Internet costs, etc.) and the use of cloud computing services. By rising members, the ecosystem will get further support (Laine, Alhava, Peltokorpi, & Seppänen, 2017).

## 5. Conclusion

This paper proposes a new AI-based platform approach to empower SMEs of the AEC industry. Chapter 1 highlighted existing challenges the AEC sector is currently facing, these are mostly heterogeneous data and therefore a lack of interoperability and comparability. Further, the industry is fragmented and consists of 99,9% SMEs with collaboration and communication challenges. Lastly, decisions in the dynamic processes are, for the most part, based on feelings and personal experience and not on data or AI methods. As a result of this analysis four research questions were stated: how can data be made machine-interpretable, how can participants collaborate, which processes can be optimized by data collaboration and which new business models can emerge and enable the ecosystem.

Chapter 2 introduces an AI-based platform for the AEC industry. It involves AI-supported data preparation and transformation of heterogeneous data sets of varying quality, the development of a digital platform serving as a hub for collaboration between users and developers. Lastly, the development of AI-supported automatic and dynamic applications promotes a data-driven decision process for users. It was further defined that the baseline requirements for AI acceptance were ease of use, data security by only providing meta-data and a culture shift in terms of data usage. Around these requirements, a new system architecture prototype was developed.

Chapter 3 introduces use cases as proof of concept and four cases to show the possibilities AI offers for process optimization.

- 1) Pattern recognition to simplify construction drawings in terms of complexity and buildability
- 2) AI based design assistance to support designers with data-driven decision-making within the process.
- 3) Scheduling, logistics and tendering based on past project data and AI predictions are implemented to determine the value of buildings in regards to cost, quality and time.
- 4) Provide AI-based assistance for practitioners on site in the construction process and facility management.

The last research question was explored in Chapter 4 in providing an overview of possible new business opportunities that can be incubated in the AEC industry ecosystem. The platform ecosystem and business models offer new possibilities for services specializing in AEC data collection and generation, companies can decide to monetize their metadata. Application development and the development of services in AEC companies may serve as new innovative and potentially disruptive business models.

This paper shows how an AI-based platform approach may serve as a possible solution for current challenges in the AEC industry. With this new approach, companies get simple access to AI solutions for data interoperability issues, can overcome problems of high fragmentation by working together on a platform-based collaboration hub, and can base their decisions on data by relying on new AI-based applications. This new ecosystem leads to the empowerment of the AEC industry and may provide disruptive new business models for the future. In a current research project, the ideas of this platform are analyzed in an international project team, containing AEC companies, software developers as well as research institutes. More information to this project can be found on [www.sdac.tech](http://www.sdac.tech).

References **BauInfoConsult**. (2016). Bauunternehmer: Welche der folgenden Arten von Spezialsoftware nutzen Sie? Abgerufen am 02. 07. 2019 von <https://de-statista-com.eaccess.ub.tum.de/statistik/daten/studie/709809/umfrage/genutzte-spezialsoftware-von-bauunternehmern-in-deutschland/?fbclid=IwAR2qNYUfO04Gp-oiDiiI7HlFa9SbL7c-qQ4f3RZ7lpyuTa8l2mYeobjRlQ>. **Baummanns, T., Freber, P.-S., Schober, K.-S., & Kirchner, F.** (2016). Bauwirtschaft im Wandel Trends und Potenziale bis 2020. Munich: Roland Berger GmbH & UniCredit Bank AG. **Baums, A.** (2015). Abgerufen am 02. 07. 2019 von Digitale Plattformen – DNA der Industrie 4.0: <http://plattform-maerkte.de/dna/> **Bobriakov, I.** (25. 06. 2019). Top 8 Data Science Use Cases in Construction. Abgerufen am 02. 07. 2019 von <https://medium.com/activewizards-machine-learning-company/top-8-data-science-use-cases-in-construction-9ce8035e936f> **Chaillou, S.** (2019). AI + Architecture | Towards a New Approach. Harvard GSD. Die deutsche Bauindustrie. (kein Datum). Unternehmen und Umsätze im deutschen Bauhauptgewerbe 2016. Abgerufen am 13. 06. 2019 von <https://www.bauindustrie.de/zahlen-fakten/statistik-anschaulich/struktur/unternehmensstruktur/> **Froese, T., Han, Z., & Alldritt, M.** (2007). Study of information technology development for the Canadian construction industry. *Canadian Journal of Civil Engineering*, 34 (7), 817-829. **Fulford, R., & Standing, C.** (2014). Construction industry productivity and the potential for collaborative practice. *International Journal of Project Management* 32, S. 315-326. **Gallaher, M. P., O'Connor, A. C., Dettbarn, J. L., & Gilday, L. T.** (2004). Cost analysis of inadequate interoperability in the U.S. capital facilities industry. U.S. Department of Commerce Technology Administration, National Institute of Standards and Technology, NIST RReport No. GCR 04-867. **Laine, E., Alhava, O., Peltokorpi, A., & Seppänen, O.** (2017). Platform Ecosystems: Unlocking the Subcontractors' Business Model Opportunities. 25th Annual Conference of the International Group for Lean Construction. Heraklion, Greece. **Roland Berger**. (2016). Bau: Wie schätzen Sie den Umsetzungsgrad der Digitalisierung für folgende Bereiche in Ihrem Unternehmen ein? Abgerufen am 02. 07. 2019 von <https://de-statista-com.eaccess.ub.tum.de/statistik/daten/studie/605291/umfrage/umsetzungsgrad-der-digitalisierung-in-der-bauindustrie-in-der-dach-region/> **Shen, W., Hao, Q., Mak, H., Neelamkavil, J., Xie, H., Dickinson, J. K., et al.** (September 2009). Systems integration and collaboration in architecture, engineering, construction and facilities management: a review. **Sopra Steria Consulting**. (2018). Potenzialanalyse Agil Entscheiden 2018. Abgerufen am 02. 07. 2019 von <https://www.soprasteria.at/docs/librariesprovider33/Studien/sopra-steria-consulting-potenzialanalyse-agil-entscheiden.pdf?sfvrsn=0> **Tata Consultancy Services (TCS)** und Bitkom Research. (2018). Unterwegs zu digitalen Welten Deutschland startet in die technologische Zukunft. Abgerufen am 02. 07. 2019 von [https://downloads.studie-digitalisierung.de/2018/de/Trendstudie\\_TCS\\_2018\\_Bericht\\_DE.pdf](https://downloads.studie-digitalisierung.de/2018/de/Trendstudie_TCS_2018_Bericht_DE.pdf) **USP Marketing Consultancy**. (2019). European Architectural Barometer. Abgerufen am 02. 07. 2019 von [https://www.usp-mc.nl/files/brochure-european-architectural-barometer\\_1543245060\\_1794e6e0.pdf](https://www.usp-mc.nl/files/brochure-european-architectural-barometer_1543245060_1794e6e0.pdf)

# Recognizing Drone Swarm Activities: Classical versus Quantum Machine Learning

Prof. Michel Barbeau

## Introduction

Current drone technology is such that Unmanned Aerial Vehicles (UAVs) and Unmanned Underwater Vehicles (UUVs) are capable of behavior adaption. This may involve sensing and responding to environmental changes, updating a goal and dynamically generating a new plan. In this article, we study the problem of recognizing activities performed by drone groups, or swarms. This could help identify a targeted plan, the purpose of a mission and actions carried out to achieve it. Solutions to this problem find applications in air space surveillance and coastal water monitoring. The recognition problem is particularly challenging when the drones are part of a formation or they perform a collaborative task. In this article, we explore how classical and quantum machine learning can help to develop solutions to the problem of drone collective behavior recognition.

## Machine Learning and Drone Activity Identification

Machine learning infers information using observations, i.e., data points, about a subject. A data point is the abstraction of a concept or a fact. There are three main types of machine learning: supervised, unsupervised and reinforcement. With supervised machine learning, there are old and new data points. Old data points are labelled. A label represents a conclusion associated with data points. Comparing their similarity with old data points, supervised machine learning assigns labels to new data points. With unsupervised machine

learning, the data points are unlabelled. They are grouped together into clusters according to similarity. Reinforcement learning rewards or penalizes the machine learner according to the validity of the inferred conclusions.

The use of machine learning to identify activities performed by individual drones has been studied before. Using flying drone tracking systems, collected data points may consist of navigation data such as roll, pitch, yaw angles, velocity and acceleration. In their work, Bartak and Vomlelova (2017) collect navigation data statistics, i.e., means and variances of roll, pitch, yaw angles, during overlapping time windows. The data points are labelled with the commands being executed by the drones, i.e., fly left, right, forward or backward and rotate. Unsupervised and supervised learning methods were tested. Unsupervised learning yielded mixed results. The calculated clusters were not representative of the activities. Supervised decision tree learning produced good results. Using the same data set, similar conclusions were drawn by Neruda et al. (2017). For supervised learning, in addition to decision tree, a random forest classifier has also been tested. Castellini et al. (2018) have conducted a related study for aquatic drones with a focus on unsupervised learning and testing various clustering methods. Labels were upstream, downstream navigation and blocked. All these works focus on individual drone activities. In this article we investigate the problem of drone group behavior recognition.

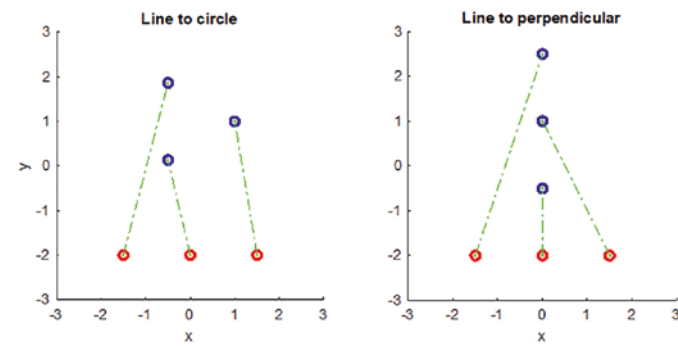


Figure 1: Two drone swarm formation transitions.

Hereafter, we focus on activities performed by swarms of drones flying in formation. Among other things, formation flying is useful for the accomplishment of collaborative work. There are several formation geometric patterns that can be realized by a swarm of drones, such as circle, line or rectangle. With a bird's-eye view, two swarm behaviors are illustrated in Figure 1. The drones are represented by small hollow circles. They fly in formation. The figure pictures formation pattern transitions. The red circles represent their initial configuration. The blue circles represent their final formation. Green lines show their individual trajectory. On the left, three drones make a transition from a line formation to a circle formation. On the right, they make a transition from a line formation to a perpendicular formation. When they are in formation, drones fly very consistently following a leader. The initiation of a formation transition can be detected because the drone behaviors start being heterogeneous for a short while. When they perform a transition from one formation pattern to another, can machine learning, classical or quantum, predict the target formation pattern?

### Data Point Representation

To address the problem of target drone formation pattern identification when transitions occur, the first important question to answer is: what are the data points? Hereafter, we focus on supervised machine learning. Every data point is represented as a vector of features. A feature, i.e., a vector item, is a value characterizing the data point. Each data point is associated with a label indicating the class to which it belongs.

We use the following notation. The input of supervised machine learning comprises  $\ell$  different labels  $y_0, \dots, y_{\ell-1}$ ,  $m$  labelled old data points  $x_0, \dots, x_{m-1}$  and a new unlabelled data point  $x$ . Each data point  $x_i$  is a vector of  $n$  features  $(x_i[0], \dots, x_i[n-1])$ . The label of  $x_i$ , denoted as  $\mathcal{L}(x_i)$ , is also a numerical value, which may be given a specific interpretation such as no or yes or a color. For the sake of simplicity, we assume that the numbers  $\ell$ ,  $m$  and  $n$  are powers of two, i.e., numbers in the form  $2^k$  where  $k$  is a positive integer. This is not a restriction because the sets of labels, data points and features can be padded with dummies to achieve that condition. Furthermore, two preprocessing steps perform data normalization. Firstly, for every feature, the minimum and maximum values are determined. Then, each value in every

feature vector is mapped into the interval  $[0,1]$ , where 0 and 1 correspond to the minimum and maximum. Secondly, every feature vector is normalized to magnitude one. This can be achieved dividing every feature by the magnitude of the vector. Consistently with the labelling of the old data points, the goal is to assign a label to a new data point  $x$ .




Figure 2: Supervised machine learning problem example.

Figure 2 pictures a three-dimensional supervised machine learning problem example. Every point represents the tip of a unit vector comprising three features ( $n=4$ , but the fourth item is ignored). Because of the unit vector, every data point turns out to be on a unit sphere. Classification of data points is represented with colors. All data points ( $m=256$ ) are classified and labelled but one (+). Some points (\*) are labelled red while others (o) are labelled blue ( $\ell=2$ ). Using a classification criterion, the objective is to determine the most appropriate color for the unlabelled point.

For mobile agents such as drones, acceleration measurements are good candidates for building feature vectors. They are reflective of activities being performed by individuals. As suggested in the work of Miene et al. (2004) for teams of robots, a group activity is better characterized by the spatial relationships arising from the movements of the participants. Hence, for drone swarms we populate feature vectors with pairwise relative accelerations.




Figure 3: Relative accelerations between drones.

Using a model based on potential functions, described in a paper authored by Rizqi et al. (2014), we generate a set of data points. We explain how relative acceleration between two drones is calculated. Firstly, when a formation transition occurs every drone moves from a current location  $g$  to a new location  $q$ , see Figure 3. The magnitude of the separation distance between  $g$  and  $q$ , i.e.,  $|q-g|$ , determines the strength of an attractive force applied to the drone. The attractive force is proportional to the magnitude of the separation distance. This attractive force is mapped directly to a speed change vector  $\vec{v}$  from location  $g$  directed towards location  $q$ , i.e., an acceleration from the old location  $g$  towards the new location  $q$ . When a formation transition is triggered, due to the need to change their relative location there is an acceleration change for every drone. Given a speed change  $\vec{v}_1$  for drone 1 and a speed change  $\vec{v}_2$  for drone 2, the relative acceleration between drones 1 and 2 is the magnitude of the difference between these two velocity vectors, i.e.,  $|\vec{v}_1 - \vec{v}_2|$ .

Table 1. Formation transition data points.

	Relative acceleration			Label
	1-2	1-3	2-3	
$x_0$	0.85	0.52	0	Line to circle (0)
$x_1$	0.71	0.71	0	Line to perpendicular (1)
$x$	0.67	0.74	0	Unknown

For a drone trio, Table 1 provides the relative accelerations between drones 1 and 2, 1 and 3, and 2 and 3. There are two data points  $x_0$  and  $x_1$ , respectively labelled by the transition Line to circle (0) and Line to perpendicular (1). There is a third unlabelled data point  $x$ . Note that all data has been normalized and feature vectors are unitary. Note that the lowest relative acceleration is between drones 2 and 3, hence, it is zero in the feature vectors.

### Classical Supervised Machine Learning

Nearest neighbor is a classical easy to understand supervised machine learning technique. Using the old inputs, a classifier labels a new input  $x$  with label  $y$  with probability  $p_y$ . The probability  $p_y$  is determined by the following classifier equation:

$$p_y = \frac{1}{\sigma} \sum_{i \text{ with } \mathcal{L}(x_i)=y} 1 - \frac{\|x - x_i\|^2}{4}$$

In this equation, the expression  $\|x - x_i\|$  represents the magnitude of the difference between the feature vectors  $x$  and  $x_i$ . Its squared value is a measure of the similarity between the new data point  $x$  and an old data point  $x_i$ . The fraction  $1/\sigma$  is a normalization factor that makes sure the sum of all probabilities is equal to one, a requirement for consistency. The higher the degree of similarity between every old data point labelled  $y$  and new data point  $x$ , the larger the evaluation of the summation. The larger is the probability of labelling the new input with label  $y$ .

We now slightly reformulate the classifier equation. Because we deal with unit feature vectors, it can be shown that the classifier equation is equivalent to the following simpler form:

$$p_y = \frac{1}{\sigma} \sum_{i \text{ with } \mathcal{L}(x_i)=y} \frac{\|x + x_i\|^2}{4}$$

Applying the definition of vector magnitude, we rewrite the classifier equation as:

$$p_y = \frac{1}{\sigma} \sum_{i \text{ with } \mathcal{L}(x_i)=y} \frac{(x[0] + x_i[0])^2 + \dots + (x[n-1] + x_i[n-1])^2}{4}$$

Classical computing wise, the summation used to define the probability  $p_y$  can be implemented in a classical programming language using a for or a while-loop.

With the numbers contained in Table 1, the new data point  $x$  receives the label Line to perpendicular, because the corresponding probability  $p_1$  is equal to 0.503.

### Quantum Gate Model

Classical computing is funded on a binary model of information. The basic data unit is the bit, a zero or a one. Classical computing transforms long sequences of zeros and ones, that represent a relevant problem, into other long sequences of zeros and ones that correspond to useful solutions. With quantum computing, there are several differences. Firstly, the basic unit of information is not the bit anymore but the quantum bit or qubit. What is new, is the fact that a qubit is a binary unit of data that is simultaneously a zero and a one until the end of its life when the qubit is measured, which ends either in state zero or one. There is a probability associated with each of these two outcomes. In the ket notation, a qubit is represented by the pair

$$q = a|0\rangle + b|1\rangle.$$

The symbols  $|0\rangle$  and  $|1\rangle$ , pronounced ket zero and ket one, denote the quantum states zero and one. The parameters  $a$  and  $b$  are called probability amplitudes. Raised to the power of two, i.e.,  $a^2$  and  $b^2$ , they respectively correspond to the probability of measuring the qubit in state zero or state one. The plus sign does not represent arithmetic addition. Rather, an expression with the plus sign should be interpreted as a superposition of its operands, in this case the quantum states  $|0\rangle$  and  $|1\rangle$ . Superposition means that a qubit is both a zero and a one at the same time.

Most of the people understand the idea of superposition easily. What is more challenging to grasp is the way quantum computation operates on qubits. Back to machine

learning, quantum parallelism, the phenomenon behind quantum speedup, can nicely perform all at the same time the additions contained in the classifier equation. Quantum computations are done by gates. For machine learning, only two types of gate are needed, namely, the identity and Hadamard gates. The identity gate maps a qubit to itself. It is useful when used in combination with other gates such as the Hadamard. The latter has many applications. For machine learning, it is used to compute additions of quantum information. It does subtractions also. For instance, on qubit  $q$ , the Hadamard gate can calculate the arithmetic sum of the probability amplitudes  $a+b$  and their difference  $a-b$ .

Several qubits can be grouped together to represent a complex problem. For instance, a two-qubit quantum state  $q_1 q_0$ , where  $q_1$  is equal to  $a_1|0\rangle+b_1|1\rangle$  and  $q_0$  is equal to  $a_0|0\rangle+b_0|1\rangle$ , corresponds to the superposition:

$$a_1 a_0 |00\rangle + a_1 b_0 |01\rangle + b_1 a_0 |10\rangle + b_1 b_0 |11\rangle$$

It can be seen that the number of terms in the superposition is two to the power of the number of qubits in the quantum state. In quantum memory, all these combinations exist at the same time. When a transformation is operated in the quantum memory, all the terms in the superposition are transformed at the same time. The life of the content of the quantum memory ends when it is measured. There is only one outcome, i.e., one binary combination in one of the ket terms. Their respective likeliness is determined by the square of their joint probability amplitude prefix, just before the ket symbol  $| \rangle$ .

This two-qubit state can be transformed, using the Hadamard gate, into the state:

$$\frac{(a_1 a_0 + a_1 b_0)|00\rangle + (a_1 a_0 - a_1 b_0)|01\rangle + (b_1 a_0 + b_1 b_0)|10\rangle + (b_1 a_0 - b_1 b_0)|11\rangle}{\sqrt{2}}$$

Again, we obtain the sums and differences of probability amplitudes. Keep in mind that with the quantum model, information can be contained in binary combinations but also in probability amplitudes of ket terms. Quantum machine learning leverages both forms of information representation.

### Quantum Supervised Machine Learning

Quantum computing can nicely handle a problem such as nearest neighbor classification. The inherent parallelism of quantum computing can be leveraged to calculate the probability  $p_y$ , without the usage of a for or while-loop. To achieve this, the data points must be mapped to quantum information, i.e., qubits. The actual probability  $p_y$  is calculated by applying to the information a quantum transformation that does in parallel the additions and divisions that we have in the simplified classifier equation. Schuld and Petruccione (2018) authored a book providing foundations for supervised quantum machine learning. The main thing is in the encoding of the data points.

### Amplitude Encoding of Data Points

We represent in the quantum format the data points contained in Table 1 using amplitude encoding. Recall that in input, there are  $m$  old data points  $x_0, \dots, x_{m-1}$ , with labels  $\mathcal{L}(x_0), \dots, \mathcal{L}(x_{m-1})$ , all in  $y_0, \dots, y_{\ell-1}$ , and a new unlabelled data point  $x$ . Each data point  $x_i$  is a vector of  $n$  features  $(x_i[0], \dots, x_i[n-1])$ . With amplitude encoding, the data points are mapped to a quantum state according to the following amplitude encoding equation:

$$\frac{1}{\sqrt{2m}} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} x_i[j] |0\rangle |i\rangle |j\rangle | \mathcal{L}(x_i) \rangle + x[j] |1\rangle |i\rangle |j\rangle | \mathcal{L}(x_i) \rangle$$

The plus sign (+) and summation operator ( $\Sigma$ ) should be interpreted not as arithmetic addition and summation, but as superposition operators. Note also that information is encoded in probability amplitudes and bit strings. Every item in a feature vector becomes a probability amplitude in a ket term, which bit string is the concatenation of the binary representations of the index ( $i$ ) of feature vector, index ( $j$ ) of the corresponding item in the feature vector and its label ( $\mathcal{L}(x_i)$ ). The ket terms come in pairs, one for an old data feature ( $x_i[j]$ ) and the other for a copy of the new data point feature, at the same index ( $x[j]$ ). In this representation, the new data point is repeated for each old data point. The prefix ket zero ( $|0\rangle$ ) is used for the old data point feature. The prefix ket one ( $|1\rangle$ ) is used for the new data point feature. These prefixes are important and exploited to calculate sums of features using a Hadamard gate.

The number of qubits required to encode the data points is

$$1 + \log_2 m + \log_2 n + \log_2 \ell \text{ qubits.}$$

For the Table 1 example, five qubits are required ( $m=2, n=4, \ell=2$ ).

A sample program for the IBM Q quantum computer, encoding the data points in Table 1, is shown in Box 1. A five-qubit register  $q$  is created to load the old data points. A two-classical bit register  $c$  is created to store the final result, following the measurement of the quantum state. The quantum circuit  $circ$  is made of registers  $q$  and  $c$ . Array  $v$ , of 32 entries ( $2^5$ ), is used to define the probability amplitudes that determine the initial quantum state. The amplitude encoding equation is applied. For instance, feature one of data point one, i.e.,  $x_1[1]$ , has value 0.71 and label one (1). While for the feature one of unlabelled data point, i.e.,  $x[1]$ , the value is 0.67. This data is represented by the following two terms in the superposition:

$$0.71|0\rangle|1\rangle|01\rangle|1\rangle + 0.74|1\rangle|1\rangle|01\rangle|1\rangle$$

This is also equivalent to:

$$0.71|01011\rangle + 0.74|11011\rangle$$

Converting 01011 and 11011 from binary to decimal, they correspond to the entries at indices 11 and 27 in array  $v$  (note that in the program the probability amplitudes are exact figures, not rounded). The quantum state  $q$  is initialized using array  $v$ . In amplitude encoding, the number of non-zero probability amplitude terms is equal to two times the number of data points times the dimension of a feature vector, i.e.,  $2 \cdot m \cdot n$  non-zero probability amplitude terms.

The only gate that is used is a Hadamard gate on qubit four (the left most). For the purpose of measurement, qubit four is connected to classical bit one while qubit zero is connected to classical bit zero.

The program runs on the IBM Q quantum computer. A good part of the code is dedicated to uploading the program on the quantum computer: getting a listing of the available devices supporting the required number of qubits (five in this case), choosing the least busy, executing (1024 times) the circuit (job) on the chosen device and waiting for the completion of the execution. A last section has to do with printing the results. Box 2 shows a sample execution of the program.

For detailed source code and more related examples visit my Github page on quantum machine learning [github.com/michelbarbeau/Quantum-Machine-Learning](https://github.com/michelbarbeau/Quantum-Machine-Learning).

### Conclusions

In this article, we have presented a small instance of the problem of drone swarm activity recognition solved using supervised classical and quantum machine learning. With respect to quantum machine learning, an important aspect is the encoding of data into the quantum format. According to the classification of Schuld and Petruccione (2018), the approach taken in this article is classical data generation-quantum data processing. As a consequence, there is a cost of representing data points in the quantum form, linear in their number. The time complexity of the classical computing classifier is linear as well. However, in the quantum form after the representation step the time taken to do the classification is data-size independent. This is the part that is really exciting! But please do not misunderstand me. It is too early

### Box 2. Sample execution.

```
Available backends:
[<IBMQBackend('ibmqx4') from IBMQ()>,
 <IBMQBackend('ibmqx2') from IBMQ()>,
 <IBMQBackend('ibmq_16_melbourne') from
  IBMQ()>,
 <IBMQBackend('ibmq_qasm_simulator') from
  IBMQ()>]
The best backend is ibmqx4
Job Status: job has successfully run
Probability of label 0 (1) is 0.466 (0.534)
```

### Box 1. IBM Q program.

```
# State and circuit creation
#
# Create a 5 qubit register
q = QuantumRegister(5)
# Create classical register for measurements
c = ClassicalRegister(2)
# Create a quantum circuit acting on q and c
circ = QuantumCircuit(q,c)
# Initialize the register content
v = numpy.zeros(32)
v[ 0] = 0.854599108706791/2 # |0>|0>|00>|0>
v[ 2] = 0.519288323956507/2 # |0>|0>|01>|0>
v[ 9] = 0.707106781186547/2 # |0>|1>|00>|1>
v[11] = 0.707106781186547/2 # |0>|1>|01>|1>
v[16] = 0.669571630148232/2 # |1>|0>|00>|0>
v[18] = 0.742747488787838/2 # |1>|0>|01>|0>
v[25] = 0.669571630148232/2 # |1>|1>|00>|1>
v[27] = 0.742747488787838/2 # |1>|1>|01>|1>
circ.initialize(v, q)
# Add a H gate on qubit 4 (leftmost)
circ.h(q[4])
# Measure leftmost qubit
circ.measure(q[4], c[1])
# Measure rightmost qubit
circ.measure(q[0], c[0])
#
# Running on IBM Q
#
from qiskit import IBMQ
# Load credentials
IBMQ.load_accounts()
# List available devices
print("Available backends:")
IBMQ.backends()
# Choose device with least busy queue
from qiskit.providers.ibmq import least_busy
large_enough_devices = IBMQ.backends(filters=lambda x: x.configuration().n_qubits > 4
and not x.configuration().simulator)
backend = least_busy(large_enough_devices)
print("The best backend is " + backend.name())
# Execute the circuit
from qiskit.tools.monitor import job_monitor
# Number of shots to run the program
shots = 1024
# Maximum number of credits to spend on executions
max_credits = 3
job = execute(circ, backend=backend, shots=shots, max_credits=max_credits)
job_monitor(job)
# Wait until the job has finished
result = job.result()
#
# Print the results
#
counts = result.get_counts(circ)
p0 = counts.get('00',0) / (counts.get('00',0)+counts.get('01',0))
print("Probability of label 0 (1) is %.3f (%.3f)" % (p0, (1-p0)))
```






Figure 4: Four drone swarm formation transitions.

for celebration. Right now, quantum machine learning performance is far from the one of classical machine learning. There is too much overhead.

For example, let us extend the problem of recognizing four different drone swarm formation transitions, namely, line to perpendicular, anti-diagonal or diagonal, see Figure 4. The good thing is that the number of old data points ( $m$ ) is doubled (two to four), but only one more qubit is needed to represent the problem. However, the number of non-zero probability amplitude terms in amplitude encoding is multiplied by two.

Ideally, collecting data representing drone activities should be done directly in the quantum form. This means bypassing the classical to quantum data translation step and enabling true gains in performance. To enable this, quantum sensing is required. There is hope, because it is a research area. The state of the art on quantum sensing, including work on acceleration measurement, is reviewed in a recent survey authored by Degen et al. (2017).

With respect to the activity recognition problem in itself, further research is needed to use measurements from a diversity of sensors and recognize a diversity of activity models involved in various kinds of group missions.

References: Bartak, R. and Vomelova, M. (2017). Using Machine Learning to Identify Activities of a Flying Drone from Sensor Readings, The Thirtieth International Flairs Conference, AAAI Publications, pp. 436-441. Castellini, A., Beltrame, G., Bicego, M., Blum, J., Denitto, M. and Farinelli, A. (2018). Unsupervised Activity Recognition for Autonomous Water Drones. The 33rd Annual ACM Symposium on Applied Computing (SAC), ACM, New York, NY, USA, pp. 840-842. Degen, C. L., Reinhard, F. and Cappellaro, P. (2017). Quantum Sensing. Rev. Mod. Phys., Vol. 89, No. 3, pp. 1-39. Miene A., Visser U. and Herzog O. (2004). Recognition and Prediction of Motion Situations Based on a Qualitative Motion Description. In: Polani D., Browning B., Bonarini A., Yoshida K. (Eds) RoboCup 2003: Robot Soccer World Cup VII, Lecture Notes in Computer Science, Springer, Berlin, Vol. 3020, Heidelberg, pp. 77-88. Neruda, R., Pilat, M. and Moudrik, J. (2017). Unsupervised and Supervised Activity Analysis of Drone Sensor Data, In: Figueroa-Garcia, J. C., Lopez-Santana, E. R., Villa-Ramirez, J. L. and Ferro-Escobar, R. (Eds.), Applied Computer Sciences in Engineering, Springer International Publishing, Cham, pp. 3-11. Rizqi, A. A. A., Cahyadi, A. I. and Adji, T. B. (2014). Path Planning and Formation Control via Potential Function for UAV Quadrotor, International Conference on Advanced Robotics and Intelligent Systems (ARIS), Taipei, pp. 165-170. Schulz, M. and Petruccione, F. (2018). Supervised Learning with Quantum Computers, Quantum Science and Technology, Springer International Publishing, pp. 287.



**Prof. Michel Barbeau**

Michel Barbeau is a professor of Computer Science. He got a Bachelor (Université de Sherbrooke, Canada '85), a Master's and a Ph.D., in Computer Science (Université de Montreal, Canada '87 & '91).

## 1.1 AI-GRUNDLAGEN EINFACH ERKLÄRT

### Künstliche Intelligenz: Lernen und lernen lassen

Die einen bauen Bagger, die anderen verkaufen Versicherungen, die nächsten transportieren Güter: Es ist noch gar nicht so lange her, da konnten Unternehmen fein säuberlich in Kategorien eingeordnet werden: Bergbau, Verarbeitendes Gewerbe, Energieversorgung, Finanz- oder Versicherungsdienstleistungen, Automobil, Gesundheit oder Logistik. Jeder Wirtschaftszweig mit seinen Prozessen, seinen Besonderheiten, seinen Technologien. Informationstechnologie war dabei etwas, das im Hintergrund mitlief. Sie diente dazu, Prozesse effizienter zu gestalten – aber im Kern ging es Unternehmen um zum Beispiel Bagger, um Versicherungen oder um Gütertransport.


Seit ein paar Jahren sind diese Abgrenzungen in Bewegung. Unternehmen schmieden auf den ersten Blick seltsame Allianzen: der Automobilhersteller mit dem Suchmaschinenanbieter, die Dax-30-Bank mit dem 30-Köpfe-Data-Science-Start-up. Diese Kooperationen sind Zeichen eines Trends, der sich quer durch alle Branchen und durch alle Unternehmen zieht. Die eigenen Prozesse im Griff zu haben, ist eine notwendige Bedingung für den Geschäftserfolg – aber keine hinreichende mehr. Daten sind inzwischen der Stoff, aus dem die unternehmerischen Träume sind. Seien es personenbezogene Daten, Nutzungsdaten, Umweltdaten, Verkaufsdaten, Produktionsdaten oder Maschinendaten: Unternehmen, die richtig mit ihnen umgehen, die richtigen Schlüsse aus ihnen ziehen und auf ihrer Basis neue Services und Produkte anbieten, gehören zu den Gewinnern. Denn Daten sind der Treibstoff, der viele neue Geschäftsmodelle oder Anwendungsfälle befeuert, nicht zuletzt auch Künstliche Intelligenz (KI): ohne Daten kein Maschinelles Lernen (ML).

Plötzlich sind also nicht nur die Social-Media-Plattformen aus dem Silicon Valley datengetrieben; der Maschinenbauer aus Salzgitter sollte es ebenso sein. Unternehmen, die diesen Weg in Richtung Daten gehen wollen, sollten zunächst die dafür notwendigen Fähigkeiten erwerben und Voraussetzungen schaffen. Dabei geht es nicht nur um technologische Themen. Menschen und

die Organisation sind entscheidend, wenn dieser Transfer gelingen soll.

#### Den Umgang mit Daten lernen

Natürlich sind auch klassische Unternehmen im Umgang mit Daten keine Anfänger. Sie konzentrierten sich in der Vergangenheit aber häufig auf die Arbeit mit Daten, die einen hohen sogenannten „Return on Byte“ (RoB) versprochen. Dahinter steckt die Idee, dass unterschiedliche Daten für Unternehmen einen unterschiedlichen Wert haben. Adressdaten, Kaufhistorie oder Produktionsdetails sind besonders wertvoll – haben aber ein geringes Datenvolumen. Sie sind die Grundlage, ohne die das eigene Geschäft nicht funktionieren würde. Entsprechend haben sie einen hohen RoB.



Im Gegensatz dazu gibt es Daten mit einem geringeren RoB, die aber in großen Massen gesammelt werden können: Klickverhalten auf der Website, Nutzungsdaten von Apps, Sensordaten aus Maschinen. Bisher lag der Fokus von Unternehmen auf den Daten mit hohem RoB. Die Experten speicherten sie in Bestandsführungs-, ERP- oder CRM-Systemen, analysierten sie und suchten hier Verbesserungspotenziale. Inzwischen erkennen die Verantwortlichen aber den Wert, der in der Summe der Daten mit geringem RoB steckt. Beispielsweise lässt sich aus diesen Daten ableiten, welche Präferenzen ein Kunde hat oder ob eine Maschine innerhalb der Norm arbeitet – oder nicht. Diese Informationen können für Unternehmen bares Geld wert sein: Auf dieser Datenbasis lassen sich Kosten verringern, bessere Services entwickeln oder neue Geschäftsprozesse designen.

Ein Wert, den datengetriebene Unternehmen bereits kennen. Denn sie nutzen konsequent jede Möglichkeit und jede Quelle, um mithilfe von neuen Daten bestehende Angebote zu verbessern. Unternehmen, die in der digitalen Welt groß geworden sind – also von Natur aus datengetrieben sind – zeichnen sich durch eine Reihe von Besonderheiten aus. Zuerst durch die enge Zusammenarbeit von IT- und Fachexperten. Berührungspunkte sind unbekannt, die Hürden zwischen Abteilungen gering. Oder erst gar nicht vorhanden. Digitale Unternehmen leben davon, digitale Produkte und Services zu entwickeln und



**Dr. Thomas Franz,**  
Leiter des Technologiebeirats,  
adesso AG

zu vertreiben. Alle operativen Prozesse sind drauf ausgerichtet, schnell zu sein: schnell zu testen, schnell zu verbessern, aber auch schnell zu scheitern wenn nötig.

Wollen klassische Unternehmen hier gleichziehen, gilt es, neue Fähigkeiten zu erlernen. Dazu gehört unter anderem die Fähigkeit

- zugängliche Daten, seien es strukturierte und unstrukturierte, überhaupt verwerten zu können. Häufig fehlt es bereits an dieser Grundlage.
- ein und dieselben Daten für unterschiedliche Fragestellungen, in unterschiedlichen Kontexten, auf unterschiedliche Art und Weise verwerten zu können.
- stets aktuelle Informationen zu nutzen. Dazu ist es notwendig, den Datenfluss innerhalb des Unternehmens und an den Schnittstellen zu kennen und gegebenenfalls zu optimieren.
- Systeme und Prozesse zu entwickeln, die auch bei Veränderungen von Datenquellen und möglichen Inkonsistenzen weiter funktionieren.

Wenn diese Voraussetzungen gegeben sind, können Unternehmen von den Vorteilen von KI-Anwendungen profitieren

#### Richtig trainiert ist halb gewonnen

Eine der großen Stärken von KI ist das breite Spektrum der Einsatzmöglichkeiten. Die zugrunde liegenden Verfahren können Unternehmen für eine Vielzahl von Anwendungsfällen im Umgang mit ihren Daten nutzen. Schwerpunkte liegen dabei auf der Gruppierung nach Ähnlichkeit (dem sogenannten Clustering), der Klassifikation (beispielsweise in Kategorien wie gut und schlecht, groß und klein, sicher und gefährlich oder Pferd und Katze) oder der Prädiktion („Der Absatz wird voraussichtlich um 22 Prozent steigen“ oder „die Temperatur wird um 13.00 Uhr voraussichtlich 21 Grad betragen“).

Ein wichtiges Konzept in diesem Zusammenhang ist das sogenannte ML. Die Idee dahinter ist, dass ein Modell, beispielsweise ein Regelwerk, auf der Grundlage von Trainingsdaten automatisch erlernt wird. Der Vorteil liegt auf der Hand: ML erspart Unternehmen das manuelle Erstellen eines Modells mit all den Aufwänden wie der Definition von Regeln, Prüfungen und Interpretationen. Diese Aufgabe übernimmt ein Lernverfahren, an dessen Ende ein nutzbares Modell steht.

Der Blick hinter die Kulissen offenbart, wie das Lernen beim ML funktioniert: Auf der Basis existierender, bereits erhobener Beobachtungen entwickelt das System ein Modell, das für möglichst alle bereits beobachteten Fälle das korrekte Ergebnis liefert. Jetzt können Experten dieses

Modell auch auf ähnliche, aber neue, bisher nicht erhobene Zustände anwenden. Hier liefert es nun vergleichbare Ergebnisse.

Wichtig für dieses Vorgehen sind die sogenannten Trainingsdaten. Das sind die Daten, die in der Vergangenheit erhoben wurden und in denen die Aussagen stecken, über die zukünftig das Modell entscheiden soll. Ein Beispiel ist das automatische Erkennen und Aussortieren von verdorbenen Äpfeln innerhalb einer Obstverpackungsmaschine. Die Experten legen dem System eine Vielzahl von Bildern vor, die bereits mit dem Label „gut“ beziehungsweise „verdorben“ versehen sind. Die Maschine lernt anhand dieser Vorlagen, welche Farb- und Formveränderungen typisch sind für verdorbene Äpfel – und zwar eigenständig, ohne dass die Verantwortlichen diese Anweisungen in Programmcode gießen müssen. Das erlernte Wissen kann sie dann auf die Bilder neuer Äpfel anwenden und diese entsprechend kategorisieren. Rückmeldungen zur Qualität der Entscheidungen sorgen dafür, dass das System ständig besser wird.

Damit ML-Ansätze wie gewünscht funktionieren und die erhofften Ergebnisse liefern, ist die Qualität der Trainingsdaten entscheidend. Sie entscheidet über die Präzision des gelernten Modells und dessen Robustheit beziehungsweise Generalität. Wenn, um in dem Beispiel oben zu bleiben, die Experten nur grüne Äpfel im Training verwenden, kann es sein, dass das Modell bei roten Äpfeln seltener richtig liegt. Unternehmen können gute Trainingsdaten teilweise durch Modifikationen der Quellsysteme erzeugen, teilweise nur durch aufwändige manuelle Erstellung.

#### Unternehmenskultur isst Technologie zum Frühstück

Zwei Themen sollten die Verantwortlichen auf ihrer KI-Agenda ganz oben stehen haben: Einerseits die technische Plattform, andererseits – und das ist fast noch wichtiger – die organisatorischen beziehungsweise prozessualen Rahmenbedingungen. Nur wenn beide Aspekte stimmen, können Unternehmen datengetriebene Produkte und Konzepte in großer Zahl andenken und umsetzen.

Aus technischer Warte betrachtet, sollten die Experten mithilfe einer unternehmensweit genutzten Plattform sicherstellen, dass möglichst die Gesamtheit der erfassten Daten – unter Berücksichtigung der Anforderungen an Datenschutz natürlich – allen Personen und Abteilungen zur Verfügung steht, die mit dem Entwickeln und Ausrollen digitaler Produkte befasst sind. Nur wenn ein sogenannter Data Lake zur Verfügung steht, können Unternehmen das Potenzial der

vorhandenen Daten nutzen. In der Realität werden Informationen aber häufig nur in den Systemen gespeichert, in denen sie auch entstehen. Und so existieren Daten aus CRM-, ERP-, Produktdaten-, Portal-Systemen in schöner Abgeschlossenheit voneinander. Mit all den negativen Auswirkungen auf die digitale Produktentwicklung.

Wenn diese Hürden genommen sind, bedarf es passenden Personen, die mit den Daten richtig umgehen können. Und hier sind nicht nur die Data Scientist oder die Big-Data-Engineers gefragt, also die Experten, die aufgrund ihrer Ausbildung und ihres Fachwissens qualifiziert sind. Auch in den Fachabteilungen müssen die Mitarbeiter die grundlegenden Zusammenhänge und Technologien verstehen. Nur dann werden IT- und Fachexperten auf gleicher Augenhöhe zusammenarbeiten. Diesen Teams müssen Unternehmen die notwendigen Daten für ihre Arbeit möglichst ohne großen Aufwand und komplizierte Freigabeprozesse zur Verfügung stehen.

In Summe zeigt sich, dass für die erfolgreiche Entwicklung hin zu einem datengetriebenen Unternehmen primär die Organisation und die Menschen entscheidend sind. Hier gilt die Weisheit, die der US-Ökonom Peter Drucker einst so formulierte: „Unternehmenskultur isst Strategie zum Frühstück.“ Was für Strategie gilt, gilt auch für technologische Initiativen: Nur wenn die organisatorischen Rahmenbedingungen stimmen, nur wenn die Mitarbeiter mitgenommen werden, nur wenn sie den Sinn hinter Technologie verstehen und ihnen klar wird, welche Vorteile der Einsatz bringt – kurzum: Wenn Unternehmen Technologie aus dem Blickwinkel der Menschen sehen und verstehen – dann werden diese bereit sein, neue Wege zu gehen. Dr. Thomas Franz

## So lernen Maschinen beim Machine Learning

Alle reden über Machine Learning. Aber wie funktioniert das eigentlich? Und was genau hat es mit den viel zitierten lernenden Algorithmen auf sich? Ein Beispiel aus dem Bereich Enterprise Search und Content Analytics gibt Antworten.

Eines vorweg: Machine Learning (ML) ist nicht dasselbe wie Künstliche Intelligenz (KI) – auch wenn dieser Eindruck beim Blick in den Blätterwald entstehen kann, weil die beiden Ausdrücke dort häufig synonym verwendet werden. Künstliche Intelligenz ist der Oberbegriff für sämtliche Technologien, die menschliche Intelligenz nachahmen; und Machine Learning ist nur eine dieser Technologien. Aktuell steht sie besonders im Fokus der Aufmerksamkeit, weil

sie als eine der wichtigsten und nutzbringendsten KI-Disziplinen gilt.

Dabei ist Machine Learning, oder Maschinelles Lernen, auch wieder ein Oberbegriff. ML vereint zahlreiche Lernverfahren, die auf numerischen Verfahren aufbauen und die im Grunde genommen nichts anderes als angewandte Statistik sind. Dazu gehört unter anderem das Deep Learning, das derzeit große Aufmerksamkeit erhält. In der Fachliteratur wird Machine Learning grundsätzlich in überwachte („supervised“) und unüberwachte („unsupervised“) Verfahren unterschieden.

Bei beiden Verfahren werden Algorithmen durch die Eingabe von bekannten Beispieldaten darauf trainiert, künftig unbekannte Daten selbstständig erkennen zu können. Unüberwachte Verfahren lernen dabei nicht näher definierte Strukturen in den Daten. Auf diese Weise werden beispielsweise beim Clustering ähnliche Daten gruppiert. Bei überwachten Verfahren wie etwa der Textklassifikation werden den Beispieldaten dagegen vordefinierte Zielwerte, Kategorien oder Rubriken zugeordnet. In der Praxis liefern unüberwachte Lernverfahren oftmals Ergebnisse, die dann als Grundlage für überwachte Lernverfahren genutzt werden können.

#### Texte automatisch den richtigen Themen zuordnen

Beim überwachten Verfahren der Textklassifikation beispielsweise ist das Ziel, dass ein System neue, ihm unbekannte Texte automatisch in die richtige thematische Kategorie einordnet. Ein Lernalgorithmus, der das sehr gut bewerkstelligen kann, ist die Support Vector Machine (SVM). Er bildet ein mathematisches Verfahren ab, um Gemeinsamkeiten in Objekten zu erkennen, die Objekte darauf aufbauend zu klassifizieren und die Grenzen zwischen den einzelnen Klassen klar festzulegen. Damit eignet er sich ideal für die automatische Textklassifikation.

Der Algorithmus wird zunächst trainiert. Dieses Training besteht darin, ihn Texte auslesen zu lassen und ihm dabei jeweils vorzugeben, in welche thematische Kategorie diese Texte fallen. Der Algorithmus ermittelt dann, welche Begriffe in den Texten der einzelnen Kategorien besonders häufig vorkommen; Wörter ohne thematischen Bezug wie Artikel, Pronomen oder Präpositionen berücksichtigt er dabei nicht. Auf diese Weise kennt der Algorithmus am Ende der Trainingsphase die für jede Themenkategorie entscheidenden Schlüsselwörter.

Mit diesem angelernten Wissen kann der Algorithmus nach Abschluss der Trainingsphase neue, unbekannte Texte eigenständig den passenden Themen zuordnen. Dazu analysiert und vergleicht er sie mit den Schlüsselwörtern der



Franz Kögl,  
Vorstand,  
IntraFind  
Software AG

Themenkategorien und berücksichtigt dabei nicht nur das Vorhandensein, sondern auch die Abwesenheit von Schlüsselwörtern. So kann er feststellen, dass in einem Text die Schlüsselwörter einer bestimmten Kategorie statistisch signifikant häufig vorkommen, während gleichzeitig die Schlüsselwörter der übrigen Kategorien statistisch signifikant fehlen.

Die Erfahrung aus zahlreichen Projekten zeigt, dass die Themen von Texten mit dieser Methode sehr treffsicher erkannt werden. Ist sich das System dennoch einmal unsicher, gibt es den entsprechenden Text zur Nachselektion zurück, so dass er manuell dem passenden Thema zugeordnet werden kann. Diese Zuordnung wirkt dann wiederum als Trainingseinheit, die das angelernte Wissen des Systems ausbaut und so dazu beiträgt, seine Ergebnisse weiter zu verbessern.

#### Leistungsfähige Anwendungen für Unternehmen möglich

Mit Hilfe dieses ML-Verfahrens können Unternehmen leistungsfähige Anwendungen in den Bereichen Enterprise Search und Content Analytics realisieren. So lassen sich etwa Lösungen für die unternehmensweite Suche um beliebige themenbasierte Suchfilter erweitern. Die Mitarbeiter erhalten damit die Möglichkeit, effizienter zu recherchieren und sich das im Unternehmen

vorhandene Wissen zielgerichteter zu erschließen.

Ein erhebliches Optimierungspotenzial bietet das Verfahren außerdem für Unternehmen, in denen täglich oder wöchentlich sehr viele eingehende Texte zur weiteren Bearbeitung manuell vorsortiert werden müssen – seien es gescannte Briefe, E-Mails oder sonstige digitale Dokumente. Noch größer wird das Potenzial, wenn es dabei zusätzlich sehr viele Dokumentenarten gibt, zwischen denen unterschieden werden muss. Eine trainierte Maschine kann innerhalb von Millisekunden ein eingehendes Dokument klassifizieren, und das deutlich objektiver und damit weniger fehleranfällig als ein Mensch. Zusätzlich lässt sich die automatische Einordnung noch in digitale Workflows integrieren. Dann können die IT-Systeme eingehende Neuverträge, Kündigungen oder Beschwerden eigenständig zuordnen und direkt an die zuständigen Mitarbeiter weiterleiten – und die Unternehmen ganz erhebliche Skaleneffekte erzielen.

Damit zeigt das Beispiel der Textklassifizierung nicht nur, wie maschinelles Lernen funktioniert. Es demonstriert auch, wo der Kernnutzen dieser KI-Technologie liegt: Sie kann von Standard- und Routinetätigkeiten entlasten und dadurch Freiraum für Aufgaben schaffen, die die natürliche Intelligenz von Menschen erfordern.

Franz Kögl

## KI-Technologien für Enterprise Search und Content Analytics

### f(x) Machine Learning / Statistical Analysis

Deep Learning  
Support Vector Machine (SVM)  
Clustering

### afg Linguistik

Grammatiken  
Morphologie  
Syntaktisches Parsing

### Regelbasierte Verfahren

Named Entity Recognition

### Semantik

Ontologien & Graphdatenbanken

Machine Learning ist im Umfeld von Enterprise Search und Content Analytics eine von mehreren leistungsstarken KI-Technologien (Quelle: IntraFind).

## Künstliche Intelligenz: Möglichkeiten und Grenzen

Viele Menschen fasziniert die Frage „Können Maschinen denken?“. Die Antwort hängt vor allem davon ab, wie wir den Begriff „denken“ interpretieren. Wenn von künstlicher Intelligenz (KI) die Rede ist, fallen häufig auch Begriffe wie Machine Learning und Cognitive Services. Sie sind wichtig um zu verstehen, wie Maschinen „ticken“, wenn sie uns mit ihren intelligenten Fähigkeiten besser machen. Gleichzeitig zeigen Sie auch auf, was KI kann und was (noch) nicht.

Im Grunde genommen bezeichnet Machine Learning die Fähigkeit von Maschinen, aus Daten Erkenntnisse zu gewinnen. Didaktisch passiert das heute in der Regel noch über menschliche Anleitung, die einem Algorithmus zum Beispiel den Inhalt von Bildern ein- oder mehrfach vermitteln, bevor Algorithmen selbständig in der Lage sind, Inhalte zu klassifizieren.

Cognitive Services bringen Maschinen sinnliches Erleben bei: Diese sind dann in der Lage Bilder, gesprochene oder geschriebene Wörter, Stimmungen und demnächst vielleicht auch Gerüche und sensitive Eindrücke zu erkennen. Cognitive Services können Sensordaten von Maschinen oder aus dem Smartphone aufnehmen und an Algorithmen weitergeben, die durch Machine Learning diese Daten verarbeiten. Ist das Intelligenz im menschlichen Sinne? Eher nicht, denn wirklich autark im Denken und in der Entscheidungsfindung sind Maschinen damit nicht. Aber wenn wir aufhören maschinelle mit menschlicher Intelligenz gleichzusetzen oder auch nur zu vergleichen, dann bleiben erstaunliche und bahnbrechende Möglichkeiten, wie Mensch und Maschine im Alltag ein unglaubliches Team bilden können.

#### Von DNA-Analysen über Katastrophenvorhersage bis zur prädiktiven Wartung: Das kann KI

So können Algorithmen zum Beispiel in der Genforschung eingesetzt werden, indem sie rasend schnell in Milliarden von Datensätzen Auffälligkeiten finden, die auf Gendefekte oder Krankheiten hindeuten. Damit lässt sich der zeitliche Aufwand für solche Analysen von Wochen auf Minuten reduzieren. In der Vorhersage von Katastrophen auf der Basis großer Mengen von Wetterdaten oder hochauflösende Satellitenbilder funktioniert das gleiche Prinzip. Und bei der Suche nach Angriffen auf IT-Infrastrukturen im fortwährenden Strom von Netzwerkdaten kann KI mit diesen Fähigkeiten besser helfen, als herkömmliche Methoden.

Auch in der Industrie kommt KI zum Einsatz:

Hier können Algorithmen den Wartungszustand von Maschinen und Anlagen kontrollieren und vorausschauend eingreifen, bevor ein Schaden und mithin Stillstand oder Ausfallzeiten entstehen. Auf diese Weise lassen sich Maschinenlaufzeiten deutlich optimieren und Kosten für Wartung und Reparaturen einsparen.

Gleichzeitig entstehen ganz neue Geschäftsmodelle, wie das Beispiel von thyssenkrupp Elevator zeigt: Das deutsche Unternehmen hat seine weltweit mehr als 1,1 Millionen Aufzüge mit einer prädiktiven Wartungslösung ausgestattet, über die thyssenkrupp größere Zuverlässigkeit und Sicherheit und bessere Verfügbarkeit garantiert. Machine Learning und Sensoren sind wesentlicher Teil dieser Lösung.

#### KI kann vieles, aber nicht alles

Wenn Unternehmen über den Einsatz von KI nachdenken, werden sie möglicherweise auch an die aktuellen Grenzen bei der Entwicklung von KI stoßen. Die liegen aber interessanterweise nicht ober-, sondern unterhalb einer gewissen Komplexitätsgrenze. Anders gesagt: Für einfache und unterkomplexe Zähl- oder Sortieraufgaben in starren Systemen lohnt sich der Einsatz von KI nicht.

Je komplexer jedoch Prozesse und Aufgaben sind, desto mehr eignet sich Künstliche Intelligenz: Wer zum Beispiel den nicht enden wollen Strom von Content aus den sozialen Netzwerken automatisch nach dem kleinen, aber für ein Unternehmen wichtigen Teil an brauchbaren Informationen scannen will, kann das so genannte Natural Language Processing (NLP) einsetzen. NLP destilliert aus geschriebener und gesprochener Sprache bestimmte Inhalte.

Sprachverständnis ist auch in anderen Zusammenhängen wichtig: So können Chatbots zum Beispiel den Kundenservice bei bestimmten Aufgaben entlasten: Der Microsoft-Service LUIS kann zum Beispiel einen Flug buchen, Pizza bestellen oder die nächste Kneipe in der Nähe suchen und als Chatbot mit seinen Nutzern kommunizieren.

In der schleswig-holsteinischen Landeshauptstadt Kiel kümmert sich der Behörden-Bot Govii in der ersten Reihe um die Belange der Bürger. Warum? Weil er rund um die Uhr verfügbar ist und so die Mitarbeiter für komplexere Aufgaben eingesetzt werden können, die einen noch besseren Bürgerservice ermöglichen.

#### Intelligenter Alltag: KI ermöglicht Teilhabe

Intelligente Maschinen, Algorithmen, Roboter – das ist nicht nur was für Unternehmen. Sie kommen auch in unserem Alltag zum Einsatz



Jürgen Wirtgen,  
Data&AI Lead,  
Microsoft  
Deutschland GmbH

und können zum Beispiel Menschen mit Beeinträchtigungen unterstützen:

Seeing AI ist eine bei Microsoft entstandene Smartphone-App, die blinden und visuell eingeschränkten Menschen ihre unmittelbare Umgebung beschreibt: Taucht eine (bekannte) Person im Blickfeld auf, ein Hindernis oder ein unbekanntes Produkt? Was steht auf dem Beipackzettel und wieviel Geld habe ich in der Hand: All das sind Alltagsaufgaben, die Seeing AI schon erledigen kann. Sie verbessert damit zu einem großen Stück die Teilhabe von blinden und visuell eingeschränkten Menschen.

Project Emma geht auf die Grafikdesignerin Emma Lawton zurück, bei der im Alter von 29 Jahren Parkinson diagnostiziert wurde. Das mit der Krankheit verbundene Zittern der Hand drohte sie zur Invalidin zu machen. Microsoft Research entwickelte ein kleines Gerät für das Handgelenk, das den Tremor über Sensoren misst und mit Vibrationen ausgleicht. So kann Emma die Fertigkeiten ihrer Hand trotz Parkinson weiter nutzen und ihren Beruf weiter ausüben.

### KI kann die Welt ein Stück besser machen – wenn wir es richtig anstellen

Um das Leben von weltweit mehr als einer Milliarde Menschen mit Beeinträchtigungen mit KI zu verbessern, hat Microsoft zuletzt auf der weltweiten Entwicklerkonferenz Build 2018 im Mai die Initiative AI for Accessibility gestartet. Das Programm ist mit einem Volumen von mehr als 25 Millionen US-Dollar auf fünf Jahre ausgelegt und umfasst finanzielle Unterstützung für KI-Forscher und -Entwickler sowie Universitäten und NGOs.

AI for Good unterstützt KI-Projekte für nachhaltigen Umweltschutz, bessere Bildung oder den Kampf gegen verheerende Krankheiten.

Alles in allem, hat KI das Potenzial, unsere Gesellschaft nachhaltig zu verändern. Wir werden in Zukunft sicher nicht weniger arbeiten, aber weniger gefährliche, dreckige oder eintönige Arbeiten ausführen. Dadurch haben wir mehr Zeit für kreative, komplexe oder soziale Tätigkeiten. Wichtig ist nur, dass wir künstliche Intelligenz aktiv gestalten, ethische Prinzipien definieren und nicht darauf bauen, dass andere das tun.

Jürgen Wirtgen

## Was heute besser als mit Katzenbildern geht

In allen Branchen wird es nur mit künstlicher Intelligenz (KI) gelingen, die anfallenden Datenmengen automatisiert zu verarbeiten. In der

Regel läuft es auf maschinelles Lernen (ML) hinaus, das mehr kann, als Katzen auf Bildern zu identifizieren. Die ML-Verfahren richtig einzusetzen, verlangt Wissen und Erfahrung sowie ein klares Automatisierungsziel. Wollen Unternehmen langfristig wettbewerbsfähig sein, bleibt auch das bewährte Proof-of-Concept relevant.

Mit dem präzisen Erkennen von Katzenbildern aus einer Millionen Einträge umfassenden Datenbank verbindet sich der Durchbruch in der jüngeren Geschichte der künstlichen Intelligenz (KI) vor dem Hintergrund verfügbarer Rechenleistung und nutzbarer Trainingsdaten. Genau diese Fähigkeit demonstrierte ein neuronales Netzwerk von Studenten, das beim Wettbewerb, der ILSVRC (ImageNet Large Scale Visual Recognition Competition), 2012 für Aufsehen sorgte. Darüber hat sich bestimmt auch der bekannte KI-Forscher Geoffrey Hinton gefreut, der die angehenden KI-Spezialisten betreute.

Allgemein ahmt ein neuronales Netz die Nervenzellenvernetzung im Gehirn nach. Es besteht aus Datenknoten, die sich auf Eingabe-, Zwischen- und Ausgabeschicht verteilen und zwischen denen gewichtete Verbindungen existieren. Im Lernprozess werden diese Gewichte so eingestellt, dass das Netz die Muster möglichst sicher erkennt, also das Lernziel erreicht. Ein neuronales Netz fällt unter das weite Feld des maschinellen Lernens (Machine Learning, ML), das technologisch betrachtet ein Teilgebiet der KI bildet. Schlussfolgern (Reasoning), Spracherkennung und -verarbeitung (Natural Language Processing, NLP) und automatisiertes Planen (Planning) komplettieren die Hauptdisziplinen, auf die alle zutrifft, dass ihre Systeme eigenständig Probleme erfassen und lösen.

### Aus Erfahrung lernt die Maschine

Stark vereinfacht sind ML Algorithmen Optimierungsalgorithmen, die einen Erkennungsfehler minimieren. Im Allgemeinen hängt es von der Aufgabe ab, welche Algorithmen für ein ML Problem eingesetzt werden. Bei einem typischen „überwachten“ Lernalgorithmus existiert für einen Teil der Daten bereits die Information „Katze auf dem Bild“. Mit diesem Wissen kann jeweils eine schrittweise Iteration zur Verbesserung durchgeführt werden. Eine gutes Lernergebnis ist hier auch nur mit einem hinreichend großen und variablen Datensatz zu erreichen. Dennoch versteht der Algorithmus nicht, was eine Katze ist, sondern gibt zu einem neuen Bild aus, ob es ähnlich zu den gelernten Katzenbildern ist oder nicht. Beim sogenannten Deep Learning werden spezialisierte neuronale Netze „gestapelt“ und übernehmen Teilaufgaben. Zum Beispiel kann

hier ein Netz die Umrisse in Bildern bestimmen, und ein anderes die Umrisselemente prüfen und Teilelemente erkennen, wie beispielsweise Fell, oder Ohren etc, die dann von weiteren Schichten kombiniert und ausgewertet werden. Diese Verfahren sind robuster, benötigen aber einen hohen Rechenaufwand, deshalb sind sie auch erst mit der Verfügbarkeit entsprechender Hochleistungssysteme realisiert worden (Berechnung mit Grafik-Prozessoren oder speziellen Tensor-Cores etc).

Ein wichtiger Aspekt im maschinellen Lernen ist das „Dazulernen“. Dabei werden aktuelle Datensätze ebenfalls für das Training hinzugezogen.

Nicht aufbereiteten Daten widmet sich der Algorithmus im unüberwachten Lernverfahren. Der Algorithmus durchleuchtet die Daten nach Mustern, nach denen er die Daten klassifizieren und sinnvolle Informationen abbilden soll. Verhaltensmodelle lieferten die Vorlage für das bestärkende maschinelle Lernen, bei dem ebenfalls keine klassifizierte Trainingsdaten vorhanden sind und das Ergebnis offen ist. Das Verfahren eignet sich, wenn sich ein Trend – entweder in die richtige oder falsche Richtung – abzeichnet. Der Algorithmus erhält Feedback, wie jedes Ergebnis zu bewerten ist. Das System geht danach im Trial-and-Error-Verfahren vor. Erfolgreiche Entscheidungen verstärken sich zu einem Prozess, der das Ausgangsproblem hinreichend gut lösen kann. Aber auch hier ist ebenfalls eine kritische Kontrolle gefragt, denn bei unüberwachten Lernen kann ein unpassendes Lernziel erreicht werden, das nicht die eigentlichen Abhängigkeiten erfasst, die das Problem enthält.

Die durch maschinelles Lernen erfassbaren Probleme gehören in den Bereich der „schwachen“ KI. Das System ist nach der Lernphase in der Lage eine bestimmte, eng begrenzte Tätigkeit zu übernehmen, die ansonsten einem Menschen zugeschrieben wird. Ein Verständnis über die Tätigkeit liegt dabei nicht vor.

### Ist Deutschland im Bilde?

Im Einsatz von KI-Verfahren belegt Deutschland nur einen Platz im Mittelfeld. Weltweit führen die USA und China. In den deutschen Unternehmensalltag blickt die IDC-Studie „Künstliche Intelligenz in Deutschland 2018“. Dort stehen zwei Zahlen heraus: Rund ein Viertel der Unternehmen hat bereits KI-Projekte realisiert, 69 Prozent der befragten 350 Firmen und Organisationen planen eine Umsetzung. Branchenübergreifend kristallisieren sich laut IDC fünf bevorzugte Anwendungsszenarien heraus. Unternehmen nutzen KI am häufigsten für die Extraktion von Wissen aus Daten (37 Prozent), zur Spracherkennung (32 Prozent), zum überwachten maschinellen Lernen

(25 Prozent), für die Bilderkennung/-klassifikation (23 Prozent) sowie zur automatischen Content-Aggregation (23 Prozent). Die Technologien liefern die Basis, die jeweils knapp 20 Prozent intelligente Assistenten zum Support von internen und externen Kundenanfragen und Chatbots für die Interaktion mit Kunden einsetzen.

Deutsche Unternehmen setzen also auf Automatisierung, die bei einem virtuellen Assistenten im Kundencenter auf zwei Ebenen stattfindet. Das betrifft zunächst den virtuellen Assistenten selbst, der die Mensch-Maschine-Schnittstelle für die Spracherkennung und -bearbeitung bildet. Hinzu kommt die roboterhaft-gesteuerte Prozessautomatisierung (RPA). So stößt nach der Eingabe ein digitaler Assistent einen Prozess oder mehrere Vorgänge an, die im Hintergrund ablaufen, um eine bestimmte Aufgabe des Nutzers zu lösen. Ein Softwareroboter (also eine Software) ahmt in dem Fall die menschlichen Eingaben und Reaktionen an einer Benutzeroberfläche nach, indem er beispielsweise Daten ins ERP-System eingibt, auf Rückmeldung des Systems reagiert und so die Ausführung eines gesamten Geschäftsprozesses unterstützt. Auf diese Weise bleibt das System sowohl von einem Menschen wie auch von „der Maschine“ bedienbar. Mit entsprechenden Automatisierungsschnittstellen in den nächsten Generationen solcher Software wird auch eine tiefe Integration möglich werden.

### Initial den Automatisierungszweck definieren

Priorität in der konkreten Umsetzung hat für die Analysten von IDC, dass Unternehmen zuerst den Anwendungsfall für ihr Geschäft definieren. Der klar aus der Geschäftsperspektive formulierte Automatisierungszweck führt dann zwangsläufig zur passenden Technologie. Der Neueinstieg mit einem einfachen und zunächst unkritischen Anwendungsszenario erleichtert, erste Erfahrungen zu sammeln. Der Automatisierungserfolg hängt schließlich von der Datenqualität und -relevanz ab. IDC rät Unternehmen, sich die Frage zu stellen, ob sie die richtigen Daten nutzen. Gerade bei offenen und flexiblen Ökosystemen zeigen sich Unterschiede in der Datenqualität, die einzelne Datenquellen liefern. Das Wissen und die Erfahrung der Mitarbeiter sollten zudem in die KI-Lösung und deren Training einfließen. Daneben muss eine Firma KI-Know-how aufbauen. Auch hier ist je nach eingesetzter Technologie ein passendes Kompetenzspektrum zu entwickeln.

An die interne IT richtet sich die Forderung, den KI-Service hochverfügbar zu betreiben. Die Cloud drängt sich hierbei als Bereitstellungsvariante besonders auf, da sie die flexibelste, skalierbarste Lösung für KI-Anwendungen ist. Zumal



Dr. Wolfgang Thronicke, Principal Consultant und Mitglied der Scientific Community Atos, Atos

Provider heute den Zugriff auf Grafikprozessoren von virtuellen Maschinen anbieten, um effektiv Spezialalgorithmen für Deep Learning in der Cloud virtualisiert auszurollen.

#### Testphase senkt Gefahr des Scheiterns

Unternehmen sollten sich nicht von den übersteigerten Erwartungen anstecken lassen, die bisweilen Presse und Marketing schüren. Ansonsten steigt die Gefahr des Scheiterns. Diese sinkt, je präziser ein Ziel, also der zu automatisierende Prozess, definiert ist. Auf diese Weise fällt es umso leichter, den Fortschritt in einem KI-Projekt zu messen. Allerdings gilt es, die Zeit und den Aufwand einzukalkulieren, den das Training eines KI-Systems erfordert. Auch im Live-Betrieb bleibt es notwendig, das System zu überwachen. Ein Proof of Concept (PoC) hat etwaige Fragen zu klären und letztendlich den Leistungsnachweis zu erbringen, bevor ein Pilotprojekt startet. Ein PoC mindert außerdem die Gefahr, zu unterschätzen, wie komplex sich die Wissensintegration gestaltet. Automatische Datenakquisition für Big Data ist damit nicht gegeben. Selbst ML-Verfahren sind keine Selbstläufer. Sie ordnen Daten zwar sehr gut Mustern zu und lernen kontinuierlich dazu. Aber ein Verständnis der Domäne bringt auch ein ML-Algorithmus erst einmal nicht mit. Sein Betrieb verlangt eine ständige Pflege und Anpassung, gerade vor dem Hintergrund, dass sich das Wissen und der Kontext ständig ändern und weiterentwickeln. Big Data und hohe Rechenkapazitäten bieten heute beste Voraussetzung, lernintensive KI-Verfahren zu verbessern. Insbesondere für ML zeichnen sich rasante Fortschritte ab. Um diese zu veranschaulichen, greifen Experten auch heute gern noch zu dem Beispiel mit den Katzenbildern, die ein ML-System aus einem riesigen Daten-Pool identifizieren soll. Aber es geht eben sehr viel mehr.

Dr. Wolfgang Thronicke

## 1.2 SOCIAL IMPACTS & THE FUTURE

### Wie KI unsere Gesellschaft verändert: Worauf es jetzt ankommt

Roboter und Künstliche Intelligenz (KI) revolutionieren heute unsere Gesellschaft wie einst die Dampfmaschine. Die Grundidee von KI, die

zu den wichtigsten Treibern der Digitalisierung gehört, besteht darin, durch Maschinen eine Annäherung an wichtige Funktionen des menschlichen Gehirns zu schaffen (Lernen, Urteilen und Problemlösen). Dazu gehören das Natural Language Processing (NLP), Deep Learning (DL) und das Machine Learning (ML), das ein wichtiges Werkzeug für die Gewinnung und Verarbeitung immer weiter wachsender Daten-Berge ist, die eine entscheidende Grundlage für die Wertschöpfung in Unternehmen darstellt.

KI gehört bereits seit Jahren zu den wichtigsten Treibern der Digitalisierung und ist in immer mehr Bereiche vorgedrungen. Immer öfter übernimmt Künstliche Intelligenz menschliche Tätigkeiten. Anfang 2014 gab IBM bekannt, 1,2 Milliarden US-Dollar in sein lernendes und sprechendes Programm „Watson“ zu investieren. Bereits 2011 hatte der Supercomputer bei der US-Game Show „Jeopardy!“ zwei menschliche Champions besiegt. Heute kommt „Watson“ unter anderem bei der Krebsdiagnostik im Gesundheitswesen zum Einsatz und analysiert über eine Million Gigabyte Gesundheitsdaten (Królikowski/Loebel/Ullrich). Jürgen Schmidhuber, einer der renommiertesten deutschen Forscher zum Thema KI, prognostiziert eine rasante Entwicklung: „In naher Zukunft werden wir erstmals relativ billige Maschinen haben, die so viel rechnen können wie ein Menschenhirn.“

Diese neuen Technologien haben das Potenzial, zur Lösung der großen Herausforderungen unserer Zeit beizutragen: Künstliche Intelligenz vereinfacht Arbeitsabläufe, stärkt Unternehmen bei der Produktivität und Flexibilität, schafft neue Geschäftswerte, ermöglicht genauere Prognosen, schafft neue datenbasierte Geschäftsmodelle und erlaubt schnellere Entscheidungen auf einer besseren Datenbasis. Weiterhin erhöht sie die Anpassungsfähigkeit von Unternehmen auf Marktveränderungen durch Echtzeitinformationen sowie Vorhersagen jenseits menschlicher Fähigkeiten, führt oft zu deutlichen Effizienzgewinnen, weil wiederholbare Aufgaben in Prozessen automatisch ablaufen. Hinzu kommt, dass Mitarbeiter und Führungskräfte dadurch auch mehr wertvolle Zeit für das Wesentliche (strategisch wichtige Aufgaben, Kreativität und Innovation) erhalten. Maschinen und Künstliche Intelligenz werden also zu neuen „Mitarbeitern“ der Belegschaft. Sie bringen neue Fertigkeiten ein, die Menschen darin unterstützen, neue Aufgaben zu übernehmen.

Sorgen machen sich die Beschäftigten allerdings häufig um die eigene Ausbildung. Das ist das Ergebnis des automatica Trend Index 2018, für den im Januar 2018 insgesamt 7.000 Arbeit-

nehmer in den USA, China, Japan, Deutschland, Frankreich, Großbritannien und Italien über ein Marktforschungsinstitut bevölkerungsrepräsentativ befragt wurden. 64 Prozent aller Arbeitnehmer aus den befragten sieben Ländern wollen für die Zusammenarbeit von Mensch und Maschine KI einsetzen. 73 Prozent gehen davon aus, dass KI es den Menschen erleichtert, der Maschine neue Aufgaben zu geben. Etwa jeder vierte Arbeitnehmer ist davon überzeugt, dass die Aus- und Weiterbildung für den Arbeitsplatz der Zukunft bereits eine wichtige Rolle spielt.

Die neue Zusammenarbeit mit Robotern wird von der Mehrheit aller sieben Länder als Chance gesehen, qualifiziertere Arbeit zu erlernen. Besonders in China (86 Prozent) und in den USA (74 Prozent) rechnen die Menschen mit positiven Impulsen, sich über die Robotik-Automation beruflich fortzubilden. Die Anzahl qualifizierterer und besser bezahlter Jobs wird über die neuen Mensch-Roboter-Teams künftig ansteigen – vermutet rund jeder zweite Befragte in Deutschland, Frankreich, Italien, Großbritannien und Japan.

Der Reifegrad bleibt bei der Aus- und Weiterbildung für den digitalen Arbeitsplatz der Zukunft bisher deutlich hinter den Erwartungen der Beschäftigten zurück. In der Arbeitswelt der Zukunft werden Mensch-Roboter-Teams die Fertigung verbessern, indem menschliche Talente mit den Stärken der Robotik kombiniert werden – davon sind rund 70 Prozent überzeugt.

KI führt aber auch zu neuen Geschäftsmodellen und ist ein Schlüssel zu erhöhter Wettbewerbsfähigkeit. Es werden repetitive Jobs verloren gehen, doch es entstehen auch neue Arbeitsprofile. Allerdings bringen die neuen Technologien nicht nur Veränderungen und neue Anforderungen in der Arbeitswelt mit sich – sie werfen auch ethische, rechtliche und soziale Fragestellungen auf. So müssen wir beispielsweise auch an den Möglichkeiten arbeiten, unsere innere emotionale Freiheit gegenüber Künstlichen Intelligenzen zu bewahren und menschliche Beziehungen weiterhin vorzuziehen. Künstliche Intelligenz sollte uns bei unseren täglichen Entscheidungen sinnvoll unterstützen. Es geht also auch darum, sie so zu gestalten, dass sie beispielsweise unsere Privatheit nicht verletzen. Zudem dürfen Meinungen und Vermutungen von Maschinen nicht pauschal zu Wissen erhoben werden.

Vor diesem Hintergrund sollten auch die ethischen Grundsätze und Werte der EU Berücksichtigung finden, ebenso die Sicherheit der Technologie, menschliche Verantwortung, auch sollten gesellschaftliche und ökologische Konsequenzen berücksichtigt werden. Wissenschaftler

der University of Manchester widmeten sich in einer Studie der Rolle von künstlicher Intelligenz in der Gesellschaft. Sie soll Entwickler und die Politik darin unterstützen, Auswirkungen von KI, die auf Datensätzen und Algorithmen beruht, in den Bereichen Industrie, Gesundheitswesen und internationale Politik besser zu verstehen, denn Investitionen in KI werden langfristig im Wesentlichen von Steuerzahlern bezahlt. Deshalb müssten politische Entscheidungsträger zukünftig sicherstellen, dass die Vorteile dieser Technologien auch der gesamten Gesellschaft zugutekommen. Ohne aktive politische Gestaltung wird der digitale Wandel den Ressourcen- und Energieverbrauch sowie die Schädigung von Umwelt und Klima allerdings weiter beschleunigen. Deshalb legte Bundesumweltministerin Svenja Schulze zum Start der Republica erste Eckpunkte für eine „umweltpolitische Digitalagenda“ vor. Damit soll die Digitalisierung einem Ordnungs- und Handlungsrahmen unterworfen werden, um sie zum Chancentreiber für eine nachhaltige Entwicklung zu machen. Geplant ist die Förderung von 50 Leuchtturmprojekten sowie der Aufbau eines Kompetenznetzwerks „KI und Nachhaltigkeit“. Außerdem kündigte sie an, ihre Umweltagenda im Juli 2020 im Rahmen der deutschen Ratspräsidentschaft auf EU-Ebene zu heben. Die nachhaltige Digitalisierung müsse zu einem Markenprodukt Europas werden.

Dass KI bei datenbasierten Entscheidungen oder Automatisierungen, die zahlreiche Verbesserungen ermöglichen, unterstützt, steht außer Frage. Daraus ergibt sich jedoch auch eine große Verantwortung. KI muss fair und nachhaltig sein – und der Gesellschaft dienen. Eine gute Kooperation zwischen Mensch und Maschine funktioniert nur, wenn Menschen über Kompetenzen und Wissen verfügen, das sie in die Lage versetzt, mit Maschinen sinnvoll und nachhaltig zu arbeiten.

Jörg Doeblner

Referenzen: Agata Królikowski, Jens-Martin Loebel und Stefan Ullrich: Ausrechnen statt Entscheiden – 30 Jahre IT-Innovation. In: CSR und Digitalisierung. Der digitale Wandel als Chance und Herausforderung für Wirtschaft und Gesellschaft. SpringerGabler Verlag, Heidelberg und Berlin 2017, S. S. 317-328. Hier: S. 318. Alexandra Hildebrandt: Künstliche Intelligenz: Warum die sichtbarsten Veränderungen der Digitalisierung soziale Verantwortung brauchen, <https://dralexandrahildebrandt.blogspot.com/2019/02/kunstliche-intelligenz-warum-die.html?q=jeopardy>



Jörg Doeblner,  
Dozent,  
karriere tutor GmbH

## KI gehört die Zukunft, sie braucht aber Regeln

### Einsatz Künstlicher Intelligenz muss ethischen Grundsätzen unterliegen

Der Einsatz Künstlicher Intelligenz (KI) schreitet voran und ist kaum mehr aufzuhalten. Selbstlernende Algorithmen verfeinern KI-Systeme und mit ihrer Anwendung sollen diese immer besser werden. Die ethische Dimension von KI bleibt bisher oftmals unterbelichtet. Unternehmen mit KI-Systemen unterliegen Compliance-Richtlinien, Grundsätzen guter Unternehmensführung und allgemein gesellschaftlicher Erwartungen. Markus Dohm, Executive Vice President TÜV Rheinland Academy & Life Care beleuchtet kritische Entwicklungen durch KI, ob im Recruiting, bei der Vergabe von Leistungen oder durch falsche Beratung. Sein Fazit: KI ohne menschliche Intelligenz ist (noch) nicht möglich.

Seit Menschengedenken existiert die Idee, die Krone der Schöpfung nachzubauen. Über die Fähigkeiten des Homunkulus, eines künstlichen Menschleins, philosophierte schon Cicero. Im Mittelalter war es ein Konzept von Paracelsus, der künstliches Leben auf Pferdemit ausbrüten wollte. Auch im Golem-Mythos und in dem Briefroman „Frankenstein oder Der moderne Prometheus“ ist es die Faszination am künstlich erschaffenen Menschen, die seither ganze Generationen von Autoren zu Horrorromanen und Filmen inspirierte. Der Begriff „Künstliche Intelligenz“ (KI) taucht erstmals 1956 im Titel einer Tagung auf, die am Dartmouth College in den USA stattfand. Der amerikanische Informatiker John McCarthy stellte auf seiner Tagung Schachprogramme vor. Er war von Alan Turing inspiriert, der den ersten Schachcomputer entwickelte und wenige Jahre zuvor mit einem Beitrag über „Computing Machinery and Intelligence“ brillierte. Bis zu seinem Tod im Jahr 1954 legte Turing die theoretischen Grundlagen für Computer, die den Menschen vollständig imitieren sollten. Er prognostizierte, dass es im Jahr 2000 soweit sein würde. Heute wissen wir, dass menschliche Fähigkeiten mit der steigenden Anzahl von Rechenoperationen moderner Prozessoren und schnelleren Speicherelementen simuliert werden können. Aber was genau braucht es wirklich, um menschliche Intelligenz vollständig zu imitieren?

### Was ist Intelligenz?

Über die menschliche Intelligenz forscht die Wissenschaft seit Jahrhunderten und versucht, eine allgemein gültige Theorie zu formulieren. Sie wird sprachlich oft als Oberbegriff für kognitive Leistungen des menschlichen Gehirns verwendet.

Stark verkürzt subsumieren Psychologen darunter die Fähigkeiten des Menschen, sich selbst und seine Umwelt wahrzunehmen, Informationen zu identifizieren und zu differenzieren, sie zu verarbeiten und daraus logische Schlussfolgerungen, Erkenntnisse und Handlungsoptionen abzuleiten. Die Grundlagen für diese Fähigkeiten werden zum Teil angeboren und als fluide Intelligenz bezeichnet. Übertragen auf einen Computer bedeutet fluide Intelligenz praktisch die Verarbeitungsgeschwindigkeit und -kompetenz sowie die Speicherkapazität im Arbeitsgedächtnis. Neben der fluiden unterscheiden Psychologen die kristalline Intelligenz, die im Laufe des Lebens durch Lernen erworben wird. Diese umfasst sowohl Faktenwissen als auch implizit Gelerntes. Darunter fallen Verhaltensweisen, trainierte Fähigkeiten wie Schwimmen oder Fahrradfahren. Mathematische oder sprachliche Begabungen sowie soziale und emotionale Kompetenzen sind Ergebnisse kulturell geprägter Lernprozesse. Intelligenz wird also als eine Fähigkeit beschrieben, das im Leben erworbene Wissen über seine Umwelt und sich selber anzuwenden, sich zu positionieren und eine Meinung zu bilden, sich adäquat zu verhalten sowie auf konkrete Fragen sinnvolle Lösungen zu finden. Dem Menschen stehen dafür ethische, moralische und soziale Kategorien zur Verfügung, wie er seine Meinung bildet und handelt. Diese Einflussfaktoren sind durch die Weltreligionen, die Aufklärung, durch Gesetze und allgemeinverbindliche Normen wie den kategorischen Imperativ von Immanuel Kant über Jahrhunderte entstanden. Sie bilden ein Wertegerüst, mit dem der Mensch über das rein Faktische hinweg sein Verhalten steuert und überprüft.

### Wie funktioniert KI?

Künstliche Intelligenz orientiert sich am menschlichen Intelligenzbegriff und versucht, die Erkenntnis- und Entscheidungsfähigkeit des Menschen zu imitieren. Schon heute gelingt es zumindest, KI-Systeme intelligent erscheinen zu lassen. Sie sind in der Lage, große Datenmengen in kurzer Zeit mit von Menschen geschriebenen Algorithmen auf Muster hin zu analysieren. Den Algorithmen kommt hierbei eine Schlüsselfunktion zu. Darin sind Anweisungen definiert, um ein Problem systematisch zu lösen. Wie ein Bauplan oder eine Gebrauchsanweisung verfolgt der Algorithmus diesen einen und vorgegebenen Weg und führt zu einem eindeutigen Ergebnis. Um die Leistungsfähigkeit von KI zu steigern, entwickelten Neurowissenschaftler und Informatiker Künstliche Neuronale Netze (KNN), die sich am biologischen Vorbild der Vernetzung von Neuronen im Gehirn orientieren. KNN sind in der Lage, sich jederzeit durch neue Informationen, die sie bei Lernprozessen ähnlich

wie das Gehirn verarbeiten, neu zu vernetzen oder alte Verbindungen höher oder geringer zu gewichten oder vollständig aufzulösen. Durch die KNN sind auch KI-Algorithmen heute in der Lage, bei ihrer Anwendung zu „lernen“, sich also selbständig weiterzuentwickeln. Dieser Prozess wird als Machine oder Deep Learning bezeichnet. Was der Mensch als Erkenntnis speichert, jederzeit erinnern und wieder anwenden kann, bedeutet bei den Maschinen, dass sie ihren Algorithmus „umschreiben“, um die ihnen gestellten Aufgaben immer besser lösen zu können. Aber dabei verlassen sie nicht den vorgezeichneten Weg ihrer Algorithmen ihrer Aufgabe. Zumindest bisher nur selten, wie das Beispiel aus dem Forschungslabor von Facebook zeigte. 2017 mussten die Facebook-Programmierer ein KI-System aus zwei Bots abschalten, als sie bemerkten, dass sich die beiden in einer selbsterfundenen Sprache „unterhielten“. Die Programmierer hatten vergessen, den Bots vorzuschreiben, in Englisch zu kommunizieren. Diese wollten ihre Kommunikation mutmaßlich effektiver gestalten und sprachen ein Kauderwelsch, das sie allerdings untereinander verstanden. Den KI-Experte war das nicht mehr geheuer und sie schalteten die Bob und Alice getauften Bots kurzerhand ab. Dhruv Batra, Gastwissenschaftler von Georgia Tech bei Facebook AI Research (FAIR), gab danach zu: „Es ist wichtig, sich daran zu erinnern, dass es keine zweisprachigen Sprecher von KI und menschlichen Sprachen gibt. Wir verstehen bereits im Allgemeinen nicht, wie komplexe KIs denken, weil wir nicht wirklich in ihren Denkprozess sehen können. Das Hinzufügen von KI-zu-KI-Gesprächen zu diesem Szenario würde dieses Problem nur noch verschärfen.“

### Was kann KI heute?

Vielfach begegnen Internet- und vor allem Smartphone-Nutzern im Alltag KI-Systeme, ohne dass sie sie erkennen. Eine Studie des amerikanischen Softwareunternehmens Pega ergab beispielsweise, dass nur 33 Prozent der weltweit 6.000 Befragten bewusst ist, wenn sie KI-Lösungen nutzen. Defacto nutzen aber 77 Prozent KI-Systeme. Dies beginnt schon bei der Anfrage bei einer Suchmaschine oder beim Shoppen auf den großen Handelsplattformen, wo die Kaufempfehlungen längst einen beträchtlichen Umsatzanteil einbringen. Auch die Gesichtserkennung auf dem Smartphone oder bei einer Plauderei mit Siri, Cortana oder Alexa arbeiten im Hintergrund KI. Beeindruckende KI-Lösungen stehen hinter Übersetzungs- und Diktierprogramme sowie solche, die natürliche Sprache in Text umwandeln sowie umgekehrt selber in natürlicher Sprache Unterhaltungen führen können. Solche Chatbots genannten Programme geben telefonische Auskunft, arbeiten auf Webseiten, um eine mensch-

liche Interaktion zu simulieren. Auch in Navigationsgeräten arbeiten im Hintergrund KI-Lösungen. Und im Auto von Morgen sorgt KI zusammen mit einer Unzahl von Sensoren und Aktoren für ein autonomes Fahren. Segensreich sind KI heute schon in Wissenschaft, Medizin, Marketing und selbst für Juristen, wenn sie große Datenbestände durchforsten, um bei einem vorgegebenen Problem Lösungen zu finden. In der Krebstherapie analysieren KI Röntgen oder CT-Aufnahmen, um sie mit abertausenden Aufnahmen zu vergleichen und einen Tumor zu identifizieren. In vielen Forschungsgebieten kommen KI als Hilfswissenschaftler zum Einsatz, indem sie beispielsweise riesige Datenmengen wie bei der Genanalyse in Windeseile abgleichen. KI arbeiten als Anwaltsgehilfen und durchwühlen Urteilsdatenbanken. Und sogar einfache Texte können die ersten Text-KIs bereits schreiben, wenn sie etwas Börsen- oder Sportnachrichten automatisch zu Standardtexten zusammenfügen. Im Marketing analysieren KI Verbraucherverhalten; Datenanalysen ermitteln Umsatzpotenziale, liefern personalisierte Werbung aus und stellen den Marketern Grundlagen für deren Gestaltung zur Verfügung. Allesamt Leistungen, die ohne „menschliche“ Fachkräfte und entsprechende Qualifikationen gar nicht denkbar wären.

Aber ist das schon Künstliche Intelligenz? Oder führt der Begriff in die Irre, wenn lediglich große Datenmengen mit immer leistungsfähigeren Rechnern ausgewertet werden?

### Starke vs. Schwache KI

Die aktuell verfügbaren KI-Anwendungen sind anders als Bob und Alice trotz Machine Learning zum Glück noch nicht in der Lage, ihren durch den Algorithmus vorgegebenen Weg zu verlassen und „zur Abwechslung einfach mal was anderes zu tun“. Eine KI, die Experten für die Auswertung von Lungentumoren programmiert haben, ist nicht in der Lage, einfach mal Nierenkrebs zu diagnostizieren. Wissenschaftler bezeichnen daher diese als schwache KIs – und träumen von starken KIs. Denn bisher ist es keinem gelungen, eine KI zu programmieren, die die intellektuellen Fähigkeiten des Menschen auch nur annähernd simulieren kann. Eine starke KI müsste in der Lage sein, logisch zu denken, Entscheidungen auch tatsächlich wie ein Mensch zu fällen, also abzuwägen beispielsweise zwischen zwei gleich schlechten Alternativen. Sie müsste sich planvoll neue Wissensgebiete erschließen und sich systematisch selbst anlernen. Vor allem aber müsste sie in natürlicher Sprache selbständig Ideen formulieren können und alle ihre Kompetenzen auch in ein Wertesystem einordnen und einem höheren oder fernerer Ziel unterordnen können. Kurzum: Sie müsste nach ethischen, moralischen und sozialen



Markus Dohm,  
Leiter des  
Geschäftsbereichs  
Academy &  
Life Care,  
TÜV Rheinland  
Academy & Life Care

Kategorien ihr Verhalten und ihre Entscheidungen verantwortungsvoll selbst steuern. Das bedeutet: Ohne den Faktor Mensch wird es bei aller Dynamik der technologischen Entwicklung in der digitalen Transformation auf absehbare Zeit nicht gehen.

#### Was darf KI und wer kontrolliert bei Irrtümern?

Viele KI-Enthusiasten hoffen auf den Tag, der allerdings noch 20 bis 40 Jahre entfernt sein dürfte, bis eine KI intellektuelle Fähigkeiten haben wird. Vielleicht gelingt es mit Quantencomputern sogar schon früher, noch größere Datenbestände auszuwerten und mit Hilfe von KNN sogar mit einer menschlichen und ethisch orientierten Entscheidungsmatrix zu ertüchtigen. Davon abgesehen, stellen sich aber bei den heutigen Anwendungen schon mit schwacher KI ethische Fragen. Was passiert, wenn eine KI durch Machine Learning diskriminierende Entscheidungen fällt? Heute schon sind erste Lösungen für das Bewerbermanagement bei Recruiting-Prozessen im Einsatz. Bei Amazon soll es bereits vorgekommen sein, dass Frauen bei der Vorauswahl benachteiligt wurden. Auch bei Finanzdienstleistern sind KIs im Einsatz, sogar schon länger, als es Chatbots gibt. Mit der „falschen Adresse“ oder einem Schufa-Eintrag kann es schon länger passieren, dass eine Versicherung oder ein Kredit verweigert werden. Mit solchen Fragen beschäftigte sich kürzlich ein Expertengremium der EU, das Ende 2018 seine Ethischen Leitlinien zur Diskussion stellte und im April seine finale Version veröffentlichte. Bis Juni 2019 erarbeitet das Gremium eine Handlungsempfehlung für die EU. Nach allem, was bisher bekannt ist, greifen diese Leitlinien aber nicht weit genug. Sie beschreiben einen Weg, „den größtmöglichen Nutzen aus der KI erzielen und gleichzeitig die geringstmöglichen Risiken eingehen. Um sicherzugehen, dass wir auf dem richtigen Weg bleiben, brauchen wir einen auf den Menschen ausgerichteten („menschenzentrierten“) Ansatz für die KI ...“. Das Gremium hat auch eine Checkliste mit Fragen für Anbieter von KI entwickelt, wie sie ihre Systeme sicher betreiben können. Leider aber fehlen Empfehlungen an die EU-Kommission, welche Mindestanforderungen und Sicherheitsauflagen sie den KI-Betreibern auferlegen sollten, damit der Mensch als Gestalter und Nutznießer der digitalen Transformation wirklich im Fokus bleibt. Denn eines ist klar: Eine wirtschaftlich oder aus Sicht von Behörden erfolgreiche KI werden Betreiber nicht ändern, nur weil sie ein wenig diskriminierend agiert.

#### KI-Systeme müssen mit offenem Visier agieren und überwacht werden

Hier müssen die EU und internationale Institutionen wie die UN klare Regeln aufstellen und anordnen,

dass externe Institutionen die Einhaltung regelmäßig überprüfen dürfen. Eine notwendige Regel wäre beispielsweise, dass immer dann, wenn eine KI mit einem Menschen interagiert, diese sich zuvor als solche zu erkennen gibt. Im Zweifelsfall muss der menschliche Nutzer das Recht erhalten, eine natürliche Person des Betreibers oder einer externen Stelle mit der Überprüfung einer KI-Entscheidung zu beauftragen. Darüber hinaus müssen die Betreiber bei einer KI mit Machine Learning verpflichtet sein, ihre selbstständig sich umschreibenden Algorithmen durch Testläufe zu überwachen. Und weil es Menschen sind, die KI-Algorithmen schreiben, sollten diese durch Weiterbildung ihre Kompetenzen als Fachleute regelmäßig vertiefen müssen.

Denkbar wäre auch, wenn sich große Unternehmen einen eigenen Ethikrat mit externen Experten geben, der die Weiterentwicklung der Anwendungen überwacht. Auch und vor allem beim KI-Einsatz staatlicher Stellen sind Sicherheitslinien einzuziehen, die nicht überschritten werden dürfen. So sehr sich auch Verwaltungshandeln künftig mittels KI vereinfachen lassen dürfte, müssen staatliche Stellen ein enges Korsett erhalten, um Freiheitsrechte der Bürger nicht schleichend einzuschränken.

#### Fazit: Ein starkes Werkzeug braucht Sicherheits-schalter

Wie mächtig die KI heute schon ist und in Zukunft erst noch werden wird, können momentan selbst Experten kaum einschätzen. Klar ist, dass sie ein starkes Werkzeug in der Hand von Staat und Unternehmen, aber auch künftig von Nicht-Regierungsorganisationen und der Zivilgesellschaft ist und nicht zuletzt in der Hand von Kriminellen sein kann. Wie früher bei der Dampfmaschine können verheerende Unfälle passieren, wenn zu viel Druck auf dem Kessel ist. Erst die regelmäßige Überprüfung durch unabhängige Fachkräfte von TÜV Rheinland, dem früheren Dampfkesselüberwachungsverein DÜV, in diesem Falle von Sachverständigen, hat dazu geführt, dass technische Großanlagen, Fahrzeuge und Aufzüge bis hin zu Kraftwerken zu sicheren Einrichtungen wurden. Bei der KI mag der Vergleich mit einem Atomkraftwerk vielleicht verwegen klingen. Aber ohne Überwachung durch unabhängige Dritte und lebenslange Weiterqualifizierung der menschlichen Fachkräfte wird es kaum gehen. Eine fehlgeleitete KI könnte verheerende Wirkung entfalten, wie das Beispiel Facebook 2017 zeigte. Am Ende sollte es nicht so kommen wie in Goethes Zauberlehrling: „Ach, da kommt der Meister! Herr, die Not ist groß! Die ich rief, die Geister, werd ich nun nicht los.“

Markus Dohm

## Wie künstliche Intelligenz unsere Lebensbedingungen beeinflusst

„Alles, was menschliche Intelligenz beflügelt - in Form von künstlicher Intelligenz, Gehirn-Computer-Schnittstellen oder neurowissenschaftlicher Verbesserung der menschlichen Intelligenz - steht über jedem Zweifel, da es dazu beiträgt, die Welt zu verändern. Nichts anderes spielt in der gleichen Liga.“

Eliezer Yudkowsky,  
Theoretiker der künstlichen Intelligenz.

Einst in der Science-Fiction verortet, wird künstliche Intelligenz immer mehr Teil unseres täglichen Lebens. Sie hat das Potenzial praktisch jeden Aspekt unseres Lebens in Städten und Gemeinden zu verbessern.

Mit der Weltbevölkerung steigen auch die Probleme in Verkehr und Transport. Künstliche Intelligenz verspricht, diese Bereiche im Hinblick auf Effizienz zu revolutionieren. Laut Experten werden selbstfahrende Fahrzeuge bis 2020 weit verbreitet sein. Diese Entwicklung macht nicht beim Auto Halt: Fahrerlose Lieferwagen und autonome Lieferdrohnen gehören ebenso dazu. Ein erheblicher Prozentsatz des PKW-Besitzes wandelt sich zu „Cars as a Service“-Modellen. Öffentliche Verkehrsmittel, wie wir sie kennen, sterben aller Wahrscheinlichkeit nach aus. An ihre Stelle treten On-Demand-Services. Ein effizienter Verkehrsfluss ohne Staus ist die Folge. Pendler verschwenden ihre Zeit nicht mehr gestresst im Stau, sondern nutzen sie sinnvoll zum Entspannen oder Arbeiten. Die enormen Auswirkungen auf die Städte beeinflussen unsere Lebensqualität positiv und reduzieren gleichzeitig den Bedarf an Parkplätzen massiv.

#### Intelligente Entlastung

Das Potenzial der KI zur Verbesserung der Gesundheitsversorgung ist ebenfalls groß. Künstliche Intelligenz könnte beispielsweise genutzt werden, um große Teile der diagnostischen Arbeit, der Erfassung von Patientendaten sowie der wissenschaftlichen Forschung zu automatisieren. Überlastete Ärzte und Krankenschwestern würden so von vielen ihrer derzeitigen Aufgaben entbunden, so dass sie sich auf die menschliche Dimension der Pflege und höhere analytische Anforderungen konzentrieren könnten. Intelligente Gehhilfen und Rollstühle machen älteren Patienten das Leben leichter. In Kombination mit smarten Heimüberwachungstechnologien gelangen Senioren auch in höherem Alter zu mehr Unabhängigkeit.

#### Vormarsch der Serviceroboter

Haus- und Serviceroboter gewinnen in den kom-

menden Jahren deutlich an Bedeutung. In nicht allzu ferner Zukunft gehört es in den Haushalten zur Normalität, einen Roboter für die Hausreinigung zu besitzen. Lieferroboter bringen dann Pakete zu ihren Empfängern. Vernetzte Cloud-Roboter besitzen die Fähigkeit, durch Datenaustausch das maschinelle Lernen zu beschleunigen. Parallel dazu verbessert der Fortschritt der Wahrnehmungstechnologie die Interaktion von Robotern mit Menschen.

Wir stehen an der Schwelle zu einer neuen Welt, in der die künstliche mit der menschlichen Intelligenz verschmilzt. Auch wenn einige Visionen zum jetzigen Zeitpunkt schwer vorstellbar sind, optimiert diese Entwicklung den Alltag in unseren Städten und unser Leben auf vielfältige Weise und macht die Welt zu einem besseren Lebensraum für uns alle.

Igor Ilunin

## Machine Learning und die Zukunft des Menschen in der Arbeitswelt

Wird Machine Learning dazu führen, dass die industrielle Fertigung in menschenleeren Hallen stattfindet? Über die zukünftige Rolle des Menschen in der industriellen Produktion.

Wer sein Wissen über intelligente Maschinen vor allem aus Hollywoodfilmen und reißerischen Schlagzeilen bezieht, kann den Eindruck bekommen, dass Machine Learning zu einer der unheilvollsten Entwicklungen der Menschheitsgeschichte gehört. Die Realität sieht im Vergleich dazu – wie so oft – ganz anders aus. Was stimmt ist, dass sich die Arbeitswelt und insbesondere die industrielle Produktion durch Machine Learning drastisch verändern wird. Auch die Rolle des Menschen in der Arbeitswelt wird sich verändern. Darum lohnt sich ein Blick auf die kommenden Veränderungen, die Machine Learning in der neuen Arbeitswelt bringt.

#### Die Mensch-Maschine-Kollaboration

Machine Learning schafft die Grundlagen für ein besseres Verständnis der menschlichen Kommunikation für Maschinen. Die Kommunikation mit Chatbots und digitalen Assistenten wird in den kommenden Jahren dank Machine Learning und Deep Learning sehr natürlich werden. Diese Entwicklung ist vor allem durch Künstliche Neurale Netze möglich geworden. Komplexe Verständigungsprozesse wie sie durch Ambivalenzen der menschlichen Sprache entstehen können, werden dadurch für Maschinen lösbar.

Eine ausgefeilte Mensch-Maschine-Kollaboration entwickelt sich aber auch im Bereich der visuellen Wahrnehmung. Das ermöglicht Roboter-Systemen, die im industriellen Kontext einge-



Igor Ilunin,  
Abteilungsleiter IoT,  
DataArt

setzt werden, in Zukunft nicht mehr hinter Sicherheitsglas agieren zu müssen, sondern zu aktiven Begleitern von Menschen zu werden. Schwere oder besonders feine Präzisionsarbeiten, die der Mensch aus eigener Kraft ohnehin nicht bewältigen könnte, können in direkter Kollaboration miteinander ausgeführt werden. Die Produkte, die dadurch erzeugt werden können, werden einen noch höheren Individualisierungsgrad sowie einen höheren Qualitätsstandards aufweisen und dennoch in kurzer Zeit produziert werden.

### Die zukünftige Rolle des Menschen in der Arbeitswelt

Diese Entwicklung macht den Menschen nicht überflüssig. Auch im Hinblick auf Machine Learning selbst ist es enorm wichtig, die relevanten Fragestellungen entwickeln zu können – anders formuliert: Ohne den Menschen bringt Machine Learning keinen Mehrwert. Insbesondere die bislang immer weiter steigende Nachfrage an Data Scientists, Data Enigneers und Data Strategists zeigt, dass der Bedarf an menschlichen Mitarbeitern auch in Zukunft zunehmend vorhanden ist.

Gleichzeitig entstehen zahlreiche neue Berufe und Berufsfelder in unterschiedlichen, angrenzenden Bereichen. Kommunikations- bzw. User-Experience-Design, Smart-Home-Handwerker bzw. IoT-Techniker und -Berater sowie Entwickler und Tester sind neue Berufe, die auch im Machine-Learning-Zeitalter von Menschen ausgeführt werden.

### Diese Fähigkeiten werden zukünftig in Unternehmen gebraucht

Wenn die Formen industrieller Produktion und auch traditionelle Berufsbilder durch Machine Learning transformiert werden, hat dies signifikante Auswirkungen auf die Zusammenstellung von Teams. An die Stelle von Fachabteilungen, die vor allem Wissen und Fähigkeiten einer bestimmten Zunft vereinen, treten in Zukunft „Mixed Teams“. Diese sind multidisziplinär und machen neue Fähigkeiten erforderlich, um Zusammenarbeit erfolgreich zu gestalten. Allen voran sind kommunikative Fähigkeiten wichtiger denn je. Daneben sind der professionelle Umgang mit Collaboration- und Projekt-Management-Tools schon heute in zahlreichen Berufen unerlässlich.

Wenn es um den produktiven Einsatz von Machine-Learning-Algorithmen geht, ist auch ein Grundverständnis für deren Funktionieren und die Aussagekraft der Ergebnisse essenziell. Einerseits brauchen Machine-Learning-Algorithmen regelmäßig Feedback („Supervised Machine Learning“), um die Prognosequalität im Laufe der Zeit immer weiter zu verbessern. Andererseits ist insbesondere dann, wenn es um Analyseergebnisse geht, die eine

Handlungsempfehlung beinhalten, der menschliche Mitarbeiter die eigentliche Entscheidungsinstanz. Wie Analyseergebnisse zu bewerten sind, muss darum eine Kernkompetenz für Mitarbeiter mit Entscheidungs- und Führungsbefugnissen sein.

Nicht zuletzt muss sich auf diese neue Situation die Organisation als solche entsprechend einstellen. Eine auf Digitalisierung und Datenanalyse ausgerichtete Geschäftsführung sowie Geschäftsmodelle gehören hier ebenso zum Standard wie Data Governance – aber auch eine offene Kommunikationskultur zwischen Geschäftsführung, der C-Level-Ebene, den Bereichs- und Abteilungsleitern und Fachkräften ist enorm wichtig.

### Machine Learning

Die Fabrik der Zukunft wird nicht aus menschenleeren Hallen bestehen. Die intelligenten Maschinen werden sich unter Garantie auch nicht zusammenschließen und eine Gefahr für die Menschheit darstellen. Nichtsdestotrotz wird es durch die Erfolge im Bereich Machine Learning zu Transformationsprozessen und einem enormen Erkenntnisgewinn kommen. Beides erlaubt es Unternehmen auch in Zukunft international konkurrenzfähig zu bleiben und gewinnbringende Geschäftsmodelle zu entwickeln. Dies gelingt jedoch nur, wenn Daten konsequent als zentrales Asset verstanden werden und entsprechend verarbeitet werden, damit sie Unternehmen einen echten Mehrwert verschaffen.

Michaela Tiedemann

## 1.3 ZUR TECHNOLOGIE

### Auf dem Wege zur Demokratisierung des Maschinellen Lernens

Stellen Sie sich den Leadsänger einer Jazzband vor, der aus den Verkaufszahlen der letzten 12 Monate den Verkauf eines neuen Songs für die kommenden 6 Monate mit einem Regressions-Modell selbst prognostizieren will; oder die Personalleiterin eines mittelständischen Unternehmens, die mittels historischer Daten die Wahrscheinlichkeit des Verbleibs eines neu einzustellenden Mitarbeiters im Unternehmen über ein Klassifikations-Modell berechnen möchte. Hierbei haben sowohl der Leadsänger als auch die Personalleiterin ‚nur‘ aus ihrer Schulzeit limitierte Vorkenntnisse in Mathematik, Statistik oder Wahrscheinlichkeitstheorie. Das zu ermöglichen verbirgt sich hinter dem Anspruch der Demokratisierung des Maschinellen Lernens.

### Einführung

Begriffe wie Künstliche Intelligenz (KI) und Machine Learning (ML), Deep Learning und neuronale Netze, oder auch Data Science und Data Mining erzeugen bei vielen Menschen – auch erfahrenen IT Experten und Anwendungsentwicklern, geschweige denn von Menschen ohne jegliche naturwissenschaftliche Ausbildung – oft ein gewisses beklemmendes Gefühl. Das liegt z.T. an der Assoziation dieser Themen mit komplexen mathematischen und statistischen Methoden. Das überlässt man dann doch lieber ausgewiesenen Spezialisten und Experten.

Mit der stetig steigenden Bedeutung, mit limitiertem Wissen mittels Machine Learning aus Daten geschäftsrelevante Erkenntnisse ziehen zu wollen, ändert sich auch das Anforderungsprofil an entsprechende Werkzeuge. Die Demokratisierung von Data Science und Machine Learning adressiert genau diesen Trend: die Anwendung z.B. von Machine Learning und Deep Learning Methoden auf geschäftsrelevante Aufgabenstellungen durch jedermann. Komplexe Aufgaben, die in der Vergangenheit ausschließlich studierten Datenwissenschaftlern vorbehalten waren, werden künftig durch jedermann ausführbar sein.

### Doch was heißt das konkret, und wie geht das?

Ohne den Anspruch auf Vollständigkeit zu erheben, werden im Folgenden einige entscheidende Techniken und Funktionen entsprechender IBM Produkte beschrieben, die sich speziell auf die Vereinfachung, Akzelerierung und Optimierung von Machine Learning Aufgaben und des Data Scientist Arbeitsablaufs beziehen.

### Visuelle Modellentwicklung

Analytische Modelle können nicht nur programmatisch über integrierte Jupyter Notebooks, sondern auch über einen Visual Model Builder Interface entwickelt, trainiert, validiert, getestet und implementiert werden. Mithilfe benutzerfreundlicher Assistenten kann der Nutzer ohne Kenntnis und Anwendung entsprechender Programmiersprachen (z.B. Scala, Python, R), und entsprechender ML und Deep Learning Bibliotheken (z.B. Spark MLlib, scikit-learn, TensorFlow, Caffe, usw.) und vor allen Dingen ohne Kenntnisse hinsichtlich der Eignung und Anwendbarkeit der schier unüberschaubaren Menge an verschiedenen ML-Algorithmen auf eine Aufgabenstellung quasi wie ein Data Scientist agieren. Mit wenigen, einfachen Schritten wird dem Nutzer der Zugriff und die Aufbereitung der Daten, das Trainieren des analytischen Modells, die Bereitstellung und auch das Scoren des Modells ermöglicht. Der komplexe Entwicklungsprozess eines Regressions- oder Klassifikations-Modells wird hierbei signifikant vereinfacht. Durch den Visual Model Builder wird

auch die Auswahl des passenden ML-Algorithmus anhand der Aufgabenstellung und der zur Verfügung stehenden Daten mit den entsprechenden Features automatisiert, wobei die Genauigkeit und Präzision der zur Auswahl stehenden analytischen Modelle dem Nutzer leicht verständlich angezeigt wird.

### Kontinuierliche Modellanpassung

Eine weitere Herausforderung nach der Bereitstellung der analytischen Modelle ist im operationalen Betrieb die kontinuierliche Überprüfung der Präzision und Relevanz des Modells im Kontext definierter Geschäftsziele. Durch eventuelle Änderungen der Einflussfaktoren und Gewichtung der selektierten Features auf ein analytisches Modell kann sich die Genauigkeit über die Zeit verschlechtern. Dies wird bei IBM Machine Learning Produkten durch eine kontinuierliche Evaluierung der Modelle adressiert, welches über ein modernes RESTful API leicht implementiert werden kann. Diese Feedback Loop kann regelmäßig erfolgen (z.B. täglich oder wöchentlich) und ermöglicht den Data Scientists und Anwendungsentwicklern eine kontinuierliche Evaluierung und Anpassung (Retraining) der analytischen Modelle im operationalen Betrieb.

Die Präzisionsmessung erfolgt automatisch ohne aktive Mitwirkung des Nutzers über definierte Methoden zur Bewertung und Optimierung von analytischen Modellen. Hierbei werden z.B. bei einem Klassifikations-Modell die Flächen unter den Receiver-Operating-Characteristic (ROC) und Precision-Recall (PR) Kurven gemessen, womit u.a. die Genauigkeit bzw. die Fehlerrate für verschiedene Parameter- und Wahrscheinlichkeitswerte eines analytischen Modells evaluiert und optimiert werden kann. Hierbei muß der Nutzer der entsprechenden Werkzeuge kein Spezialist sein, sondern kann die Ergebnisse einfach in seinen Entscheidungsprozess berücksichtigen bzw. die Empfehlung des Tools übernehmen.

### Cognitive Assistant

Um die kombinatorische Vielfältigkeit hinsichtlich der Auswahl der passenden ML-Algorithmen (z.B. Regression, Decision Trees/Forests, Naïve Bayes, k-nearest Neighbor, Clustering, usw.) und das Setzen der Hyper-Parameter (z.B. Kernel Types bei Support Vector Machines, Learning Rate, Pruning Strategie, usw.) zu optimieren, zu vereinfachen und insbesondere performant durchzuführen, hat IBM eine Reihe von innovative Methoden entwickelt, die für jedermann ohne theoretisches Hintergrundwissen nutzbar sind.

So kann z.B., die die Genauigkeit eines Learners über relativ kleine Teil-Datenmengen auf die gesamte Trainings-Datenmenge extrapoliert werden. Bei entsprechenden ML Produkten der IBM (z.B.



Michaela Tiedemann,  
Chief Marketing  
Officer,  
Alexander  
Thamm GmbH



Eberhard Hechler,  
Executive Architect,  
IBM Germany  
R&D Lab



IBM Machine Learning for z/OS, IBM Data Science Experience, IBM Watson Machine Learning) vereinfacht dies nicht nur die Entwicklung der analytischen Modelle, sondern erhöht die Performance beim Trainieren verschiedener Modelle um Faktoren. In IBM Machine Learning for z/OS sind diese Methoden im Cognitive Assistant for Data Scientists (CADS) mit Hyper Parameter Optimization (HPO) implementiert und können über den Visual Model Builder oder über ein CADS RESTful API genutzt werden.

### Schlußbetrachtung

Die Demokratisierung von Machine Learning und Deep Learning simplifiziert nicht nur den Data Science Arbeitsablauf und die Kollaboration über verschiedene Rollen und Verantwortlichkeiten hinweg, sondern ermöglicht vor allen Dingen die Entwicklung von Artificial Intelligence Applikationen mit signifikant reduzierten Skill-Anforderungen.

Eberhard Hechler

Referenzen: [1] IBM Machine Learning for z/OS, IBM Data Science Experience Local, IBM Watson Studio und IBM Db2 Analytics Accelerator [2] Als "Scoren" bezeichnet man die Anwendung des Modells auf neue Daten.

## Wie Künstliche Intelligenz und Algorithmen das Innovieren revolutionieren

Erinnern Sie die Faszination „Star Wars“? Die Begeisterung über die Freundschaft und die reibungslose Zusammenarbeit zwischen R2-D2, Luke Skywalker, C-3PO, Obi-Wan/Ben Kenobi?

Mit Hilfe der künstlichen Intelligenz scheint sich dieses Zusammenspiel von Mensch und Maschine, das damals rein fiktiv und doch so „natürlich“ erschien, bald zu verwirklichen; zumindest teilweise. Schon heute können intelligente Maschinen klar strukturierbare, logische Aufgaben für uns übernehmen und uns entlasten: Wer will z.B. Archive oder Datenbanken nach Patenten filtern oder in Social Media Foren und im Internet nach bestimmten Trends und Kundenbedürfnissen suchen? Wäre es nicht schön, Alexa zu bitten, Ihnen alle relevanten Patente rund um das Thema E-Mobilität mit dem Fahrrad zu zeigen oder sie zu fragen, welche Anforderungen Hippsters Generation Y Zielgruppen beim Kauf oder Verleih von E-Scootern stellen?

Der Begriff Künstliche Intelligenz ist heute viel umfangreicher und komplexer geworden, schon alleine, weil die verschiedenen Ausprägungen der Intelligenz - von der emotionalen, sozialen, sensorischen und kognitiven - im Zeitalter der Digitalisierung mitgedacht und -diskutiert werden.

Autonome Innovation etwa baut auf der Idee

auf, dass Produkte als Folge der Digitalisierung nicht das Ergebnis eines Innovationsprozesses sind, sondern auch „intelligente“ Produkte in der Lage sein werden, sich zu aktualisieren und ständig zu erneuern. Sie können zum Beispiel Daten darüber sammeln, wie sie verwendet werden, was die Menschen an ihnen mögen, welche Probleme sie mit ihnen haben, etc. Basierend auf diesen Daten werden Updates durchgeführt oder die nächste Generation kann automatisch spezifiziert und erstellt werden. Natürlich kann dies auf lange Sicht das visionäre Bild sein, aber Tesla ermöglicht es Ihnen bereits heute, Ihr Auto aufzurüsten und neue Funktionen zu erhalten. Amazon analysiert bereits die tatsächlich verkauften Produkte und erstellt meistverkaufte Konfigurationen. Basierend auf Ihren Präferenzen verfügt Netflix und Spotify über mehr als ein Jahrzehnt Erfahrung mit Empfehlungssystemen, die Kundeninhalte liefern.

Die Anwendung von KI erfordert eine Bereitschaft für AI – eine KI-Readiness, derer es verschiedene Nutzungsadaptionen gibt. Sie geschieht auf drei Ebenen der Einsatzbereitschaft: Erstens im Hinblick auf die Bereitschaft eines Individuums, KI bei Innovationen zu nutzen. Zweitens wird der technologische Aspekt der KI durch die Untersuchung verschiedener Arten von KI-Technologien sowie durch eine genauere Betrachtung spezifischer Innovationsaufgaben abgedeckt, die KI-Algorithmen möglicherweise verbessern können. Drittens geht es um organisatorische Aspekte im Zusammenhang mit der Einführung von KI im Bereich Innovation. Diese Trias ist nicht isoliert zu denken. Was erreicht der KI-willigste Einzelne, wenn die Organisation KI-avers agiert? Was die intensivste Bereitschaft eines KI-Einsatzes, wenn technische Parameter nicht erfüllt werden können?

Was passiert, wenn Algorithmen das Innovieren revolutionieren? Wie kann ein Paradigmenwechsel hin zu autonomer Innovation gelingen? Was bremst das Potenzial von KI im Innovationsbereich und welche Herausforderungen sind zu bewältigen, um KI erfolgreich für Innovationsprozesse im Unternehmen einzusetzen?

In einer neu veröffentlichten Studie Wie Künstliche Intelligenz und Algorithmen das Innovieren revolutionieren antworten 163 KI-affine Manager auf diese und andere Fragen. Die Studie zeigt auf, wie essentiell Wissen und Erfahrung für ein Erkennen von KI-Potenzial ist, welchen Nutzen Manager heute in KI sehen und wie utopisch autonome KI noch wahrgenommen wird. Zumal Ressourcen für KI vielfach Mangelware sind und die Implementierung oft nicht klar ist. - Dabei planen 60% der befragten Manager eine extensive Nutzung von KI im Innovationsbereich!

KI schont Ressourcen? Auf lange Sicht mag

das zutreffen; zur Implementierung indes braucht es eine Menge bereitgestellter man- und technology-power. Dass nur 20% der befragten Manager angeben, dass ebendiese derzeit zur Verfügung gestellt wird zeigt ein Gap zur geplanten Nutzung.

### Die Ergebnisse von der KI Studie in sechs Thesen:

1. KI wird im Innovationsbereich immer präsenter und offenbart großes Potenzial, trifft aber auf ein noch immer geringes Maß an Wissen und Erfahrung
2. Der sinnvolle Einsatz von KI für analytische Innovationsaufgaben ist offensichtlich, das Potenzial für kreativere Aufgaben bleibt KI-erfahrenen Unternehmen vorbehalten
3. Der Nutzen von KI wird primär in der Effizienzsteigerung gesehen und gerade von noch KI-unerfahrenen Unternehmen weniger in der Entwicklung neuer Geschäftsfelder oder Schaffung neuartiger Innovationen
4. KI wird auch in naher Zukunft den Menschen nur unterstützen, aber keine Entscheidungen treffen. Autonome KI bleibt fürs erste ein Zukunftsszenario
5. Die organisatorischen Rahmenbedingungen werden in der Mehrheit positiv gesehen und ermuntern zum Einsatz von KI. Die zur Verfügung gestellten Ressourcen sind allerdings knapp
6. Zum Vorgehen, wie man KI für den Innovationsbereich implementieren soll, gibt es unterschiedliche Sichtweisen und nur wenig Übereinstimmung, Orientierung oder Anleitung

Die Ergebnisse der Studie zeigen, dass KI nicht nur das Potenzial bietet, radikal neue Innovationen hervorzubringen, sondern auch das Innovationsmanagement neu zu denken. KI revolutioniert die Art und Weise von Innovation; läutet eine neue Innovationsära ein. Während um das Jahr 2003 das gängige Innovationsparadigma von Closed zu Open Innovation wechselte und damit die Öffnung des Innovationsprozesses nach außen und die aktive Einbindung von Kunden und Mitarbeitern mittels internetbasierter Methoden wie Crowdsourcing propagiert wurde, arbeiten Unternehmen nach derzeit vorherrschendem Verständnis an ihren Innovations-Ökosystemen und forcieren das Innovieren gemeinsam mit Start-ups und Corporate Innovation Teams in Innovation Labs, Inkubatoren und Acceleratoren. Agile Sprint Formate, Design Thinking, Lean Startup und Scrum Methoden sind dabei täglich Brot.

Künftig werden diese und andere Innovationsformate mittels KI und Machine Learning unterstützt und dadurch effizienter und besser werden. Die Euphorie bei diesem Zukunftsbild ist jedenfalls hoch und das Potenzial riesig. Allerdings tut

sich trotz dieser positiven Einschätzung außer vereinzelten Experimenten relativ wenig Konkretes. Viele Anstrengungen, technologische Weiterentwicklung und die Erledigung von Hausaufgaben ist notwendig, um das Potenzial von KI erfolgreich und systematisch zu nutzen. Erfahrungsgemäß zeigen sich die wahren Probleme und Herausforderungen nämlich erst bei der tatsächlichen Nutzung. Dennoch lassen sich, wie Beispiele zeigen, bereits jetzt beachtliche Vorteile gerade bei Analysen zur Bedürfnis- und Trendidentifikation realisieren. Eine Auseinandersetzung mit dem Thema ist also nicht nur hip, sondern notwendig.

Wie sich KI allerdings am besten nutzen lässt und wie dabei genau vorzugehen ist, bleibt vage und erfordert das Verlassen des etablierten modus operandi. Vieles wird sich diesbezüglich in den kommenden Jahren ändern und es ist zu entscheiden, wie man das Thema für sich nutzt – eher als Anwender oder dann doch eher als Pionier, der versucht, mit KI beim Innovieren Neuland zu betreten und sich dadurch Wettbewerbsvorteile zu sichern. Der Aufbau entsprechender Kompetenzen und die Verstärkung des Ökosystems mit zusätzlichen KI-Partnern scheint jedenfalls sinnvoll und ist in vollem Gange.

Dr. Sandra Lemmer

## Topologische komplexe Informationsverarbeitung in neuronalen Netzen

Künstliche neuronale Netze versuchen bekanntlich, ein biologisches Netz von Neuronen zu imitieren. Dabei werden zentrale Eigenschaften des biologischen Netzes heraus gegriffen:

- formelle Reduktion der neuronalen Verbindungen auf Graphen und formalisierte neuronale Architekturen (Hopfield-, Kohonen-, Elman-Netze u.a.)
- formelle Reduktion der Neuronen auf binäre Schalter
- Absehen von der biochemischen epi-neuronalen Regulation der neuronalen Aktivität, insbes. durch Astrogliazellen
- veränderliche Gewichtung der neuronalen Verbindungen, um der Hebbischen Korrelationsregel gerecht zu werden („neurons wire together if they fire together“): die Dynamik der neuronalen Aktivität wirkt zurück auf die neuronale Architektur
- Reduktion der neuronalen Informationsverarbeitung auf die lineare Algebra n-dimensionaler Vektorräume, um Entscheidungsoberflächen (decision surfaces) im n-dimensionalen Vektorraum zu finden.



Dr. Sandra Lemmer,  
Executive Assistant  
and Content  
Marketer,  
HYVE - the  
innovation company

Aus der notwendigen Reduktion der Eigenschaften biologischer Netze auf künstliche neuronale Netze folgen grundsätzliche Einschränkungen der potentiellen Reichweite der aktuellen Künstlichen Intelligenz:

- Der Energie- und Zeitverbrauch steigt nichtlinear mit dem Anwachsen der Problemstellung
- Die Anpassung des Systems erfolgt durch den Programmierer bzw. Ingenieur: die Bewertungsfunktion, etwa als Backward-Propagation umgesetzt, muss vorgegeben werden
- Die Informationsverarbeitung in einem neuronalen Netz erfolgt wenig effektiv durch Versuch und Irrtum
- Das überwachte, nicht überwachte sowie das Reinforcement Learning brauchen eine große Menge an Daten, bis die gewünschte Gewichtung der neuronalen Verbindungen erreicht ist
- Begrenzte Kapazität: es sind nur eine bestimmte Anzahl von Mustern im neuronalen Netz speicherbar, etwa in einem Hopfield-Netz  $0.14n$

Wie können diese grundsätzlichen Einschränkungen umgangen werden? Hier hilft zunächst ein Vergleich mit biologischen Systemen – was geschieht dort anders? Was könnte in Zukunft auch in ein künstliches Netz übernommen werden?

- 1) Der Energie- und Zeitverbrauch kann minimiert werden, wenn die Wirkung als Produkt aus Energie und Zeit minimiert wird. Ein biologisches neuronales Netz ist kein thermodynamisches System: hier wird die Wirkung durch die Verarbeitung komplexer Information minimiert. Eine sog. Ordo-Dynamik komplexer Systeme harrt freilich (noch) ihrer Ausarbeitung.
- 2) Physikalisch spricht neben der Wirkungsminimierung durch komplexe Informationsverarbeitung in einem biologischen Gehirn auch die Geschwindigkeit der Anpassung der neuronalen Architektur sowie der nicht-binäre Charakter der Informationsverarbeitung dafür, dass parallel zur klassischen Informationsverarbeitung auch eine topologische Quanteninformationsverarbeitung stattfindet
- 3) Ein biologisches Gehirn ist auch kein klassischer Computer. Vielmehr organisiert sich ein biologisches neuronales Netz durch sich selbst: es gibt keine extern implementierte Bewertungsfunktion.
- 4) Ein Neuron ist kein binärer Schalter, sondern ein komplexes System von zahlreichen Ereignissen, die miteinander zusammen wirken (Synergetik).
- 5) Auch wird Information nicht binär, sondern holistisch kodiert und repräsentiert: so gibt es im biologischen neuronalen Netz stets mehrere

mögliche neuronale Aktivitätsmuster, die demselben Grundmuster (i.S. der „Lösung“ eines Problems) entsprechen.

Um der Begrenzung der aktuellen KI entgegen zu wirken, kann die Fokussierung auf die topologische Informationsverarbeitung weiter helfen. Daher soll eine Definition der komplexen Information (CI = Complex Information) vorgeschlagen werden.

Im Wesentlichen führt der Vorschlag dazu, dass die Bewertung des Systemzustandes eines neuronalen Netzes nicht mehr durch eine Bewertungsfunktion erfolgt, sondern anhand der komplexen Information: so soll zwischen verschiedenen komplexen Mustern selektiert werden und nicht mehr zwischen  $2N$  binären Zuständen.

Ein weiterer Vorteil wäre die drastische Reduzierung der Trainingszeit eines KI-Systems: die komplexe Information würde es dem System erlauben, das gesuchte Muster bereits nach ein bis zwei Einschwingvorgängen einzunehmen. Auch wären keine immensen Datenmengen mehr zwecks des Trainings des neuronalen Netzes erforderlich; ebenso wäre die Wirkung durch unmittelbare komplexe Informationsverarbeitung drastisch reduziert.

Die komplexe Information ist für die künftige KI unserer Einschätzung nach zentral. Sie hat folgende Eigenschaften:

- a) Die komplexe Information kann als komplexe (geometrische und algebraische) Topologie verstanden werden
- b) Die komplexe Information ist holistisch und nichtlokal. Das kann anschaulich durch das Tribar von Roger Penrose visualisiert werden, bei der die Nicht-Lokalität der Unmöglichkeit der Figur identifiziert werden muss. Eine weitere Visualisierung wäre das Möbius-Band, bei der die Verdrehung nichtlokal ist: das Möbius-Band ist ein Beispiel für ein sog. nicht-triviales Vektor-Bündel, das durch „Zusammenkleben“ von trivialen Bündeln entsteht. Dieses „Zusammenkleben“ kann mathematisch exakt definiert werden mittels Techniken wie z.B. dem „Push-Out“ oder der unten behandelten „Garben-Kohomologie“ (Sheaf Cohomology).
- c) Die komplexe Information ist höher-dimensional und definiert einen komplexen Möglichkeitsraum bzw. eine Menge von korrelierten Untermengen, die die analoge Projektion der komplexen Information darstellen
- d) Die komplexe Information kodiert die Relationen (zwischen Bits, aber auch zwischen QuBits) und definiert bzw. begrenzt somit die Menge möglicher Muster.

## Topologie

Was ist nun Topologie? Sie wird auch als Rubber Sheet Geometry bezeichnet, da Räume, die durch stetige Deformationen auseinander hervorgehen, als „gleich“ angesehen werden. Daher ist es der Topologie inhärent, dass sie invariant unter stetigen Deformationen ist (Dehnung, Stauchung, Verdrehung, aber nicht Zerreißen). Dies scheint auch im biologischen visuellen System „implementiert“ zu sein, da etwa Menschen mühelos Objekte erkennen können, auch wenn sie im Raum aus verschiedenen Perspektiven betrachtet werden, oder eben stetig deformiert sind, z. B. Buchstaben-Erkennung: ein A ist beispielsweise topologisch ein Loop mit zwei Beinen, und dies gilt auch, wenn das A völlig anders geschrieben wird.

## Komplexe Information des $R^3$

Sehr mächtig wurde ein Teilgebiet der Topologie, als algebraische Invarianten definiert wurden: die sog. Kohomologie-Gruppen ( $H^n$ :  $n \in \mathbb{N}$ ) (Algebraische Topologie), mit deren Hilfe ehemals schwierige mathematische Sätze zu Übungsaufgaben von Mathematik-Studenten wurden, z. B. der Brouwer'sche Fixpunktsatz, der in der Spieltheorie den Beweis der Existenz eines Nash-Gleichgewichtes liefert. Man beachte, dass es unendlich viele solcher Gruppen gibt:  $N$  sei die Menge der natürlichen Zahlen.

Man kann diese Kohomologie-Gruppen verwenden, um nicht-lokale (d.h. globale) Eigenschaften zunächst nur des Anschauungsraumes  $R^3$  mathematisch rigoros zu fassen. Wir nennen diese die Komplexe Information des  $R^3$ . Als erstes Beispiel solcher Eigenschaften betrachten wir das Phänomen, dass es möglich ist, auf der Zeichenebene  $R^2$  Figuren zu zeichnen, die sich jedoch NICHT physikalisch im Raum realisieren lassen, sog. unmögliche Figuren, z. B. das Tribar von Roger Penrose, oder auch Zeichnungen von M.C. Escher.

Die Kohomologie-Gruppen liefern uns ein globales Maß, um den Grad der in einem Bild enthaltenen Unmöglichkeit zu berechnen. Wir behaupten, dass herkömmliche Bilderkennungssysteme, z. B. Deep-Learning-Netze in selbst-fahrenden Autos, solche Phänomene nicht „erkennen“, d.h. semantisch verstehen können, da Deep-Learning-Netze nur lokal einzelne Pixel verarbeiten.

Wie definiert man die o.g. komplexe Information bzw. die Erste Kohomologie-Gruppe? Man bricht die Figur in Stücke und klebt diese dann wieder zusammen, so dass die detaillierte Gesamtstruktur der Klebestellen in die Definition einfließt. Sei  $Q \subseteq R^2$  ein Bereich der Ebene, auf der eine Figur gezeichnet wird. Wir schreiben für die Erste Kohomologie-Gruppe:

$$H^1(Q, R^+) \text{ oder kurz } H^1$$

In diesem Beispiel besteht  $H^1$  aus Äquivalenzklassen von positiven reellen Zahlen, sie enthält also die reelle Zahl 1 (schärfer: die Äquivalenzklasse der 1).

Dann gilt folgender Satz:

Eine gezeichnete Figur ist möglich  $\Leftrightarrow [(d_{i,j})] = [1] \in H^1$

Hierbei bezeichnet  $[x]$  die Äquivalenzklasse von  $x$ . Der Beweis findet sich in Referenz [1]. (Die Zahlen  $d_{i,j}$  werden anhand der Struktur der gezeichneten Figur berechnet.)

Der Satz ermöglicht eine mathematisch rigorose Entscheidung, ob eine gezeichnete Figur im Raum realisiert werden kann, oder nicht. Als erstes Beispiel für eine Komplexe Information können wir nun definieren:

Definition: Die Komplexe Information des  $R^3$  ist  $\mathfrak{KJ}(R^3) := H^1(Q, R^+)$

Die Untersuchung der höheren Kohomologie-Gruppen  $H^2, H^3, \dots$  auf ihre Nützlichkeit für noch komplexere KI-Probleme wird von uns aktuell weiterbetrieben. Wir sind der Überzeugung, dass die künftige KI nicht um die Implementierung der komplexen Information und –verarbeitung umhin kommen wird. Schließlich wird dadurch die holistische Identifikation von Perzepten ebenso ermöglicht wie die Zuordnung bzw. Gruppierung von Inputs auch ohne den o.g. Trainingsaufwand mit einer möglichst hohen Datenmenge.

Dr. Peter Nonnenmann

Prof. Dr. Imre Kocsik

Referenzen: [1] On the Cohomology of Impossible Figures, R. Penrose, 1991, Structural Topology, 17, 11-16 [2] Algebraic Geometry, R. Hartshorne, 1977, GTM 52, Springer [3] Twistor Theory and Field Theory, R. Ward, R. Wells Jr., 1995, Cambridge U Press [4] Topological Quantum Field Theory, Nonlocal Operators, and Gapped Phases of Gauge Theories, S. Gukov, A. Kapustin, 2013, arXiv:1307.4793v2 [hep-th] [5] Introduction to Topological Quantum Computing, Jannis K. Pachos, 2012, Cambridge U Press

## Natural Language Processing punktet vor allem bei Textsuche, -klassifikation und -analyse

Der Markt für NLP (Natural Language Processing)-basierte Software wächst trotz aller technischen Herausforderungen auf breiter Front. Moderne NLP-Lösungen, die auf den drei Grundpfeilern Lexika, Regeln und Maschinellen Lernen basieren, eröffnen gerade in den Bereichen Textsuche, -klassifikation und -analyse gänzlich neue Möglichkeiten.



Prof. Dr. Imre Kocsik, Professor für Systematische Theologie, HS Heiligenkreuz/Wien



Dr. Peter Nonnenmann, Dozent für Mathematik, DHBW Mannheim und Karlsruhe

Der Begriff NLP (Natural Language Processing) beschreibt ganz allgemein die Erfassung und computerbasierte Verarbeitung natürlicher Sprache mit Verfahren der Künstlichen Intelligenz (KI). Der Fokus dieses Blog-Beitrags liegt auf der Verarbeitung von Text, nicht von gesprochener Sprache (Speech).

Die zunehmende Bedeutung von NLP zeigt sich im Consumer-Bereich in der Etablierung von digitalen Assistenten wie Siri, Cortana oder dem Google Assistent. In Unternehmensanwendungen halten solche Technologien insbesondere in Enterprise-Search-Anwendungen Einzug. Die reine Keyword-basierte Suche ist hier nicht mehr Stand der Technik. Gartner etwa prognostiziert, dass 30 Prozent der internen Suchanfragen (Enterprise Search) künftig mit W-Fragen beginnen, also mit Fragewörtern wie „Was“, „Wer“, „Wie“, „Wo“ oder „Wann“.

Dass das Verarbeiten und Verstehen natürlicher Sprache mit ihrer Komplexität und Mehrdeutigkeit eine immense Herausforderung darstellt, zeigen einfache Beispiele: Die unterschiedliche Rolle von „Löffel“ und „Nudeln“ in den Sätzen „Ich esse die Suppe mit den Nudeln“ und „Ich esse die Suppe mit dem Löffel“ sind mit einer einfachen syntaktischen Analyse nicht korrekt zu erfassen. Auch im Englischen ist das nicht einfacher wie folgende aus Nachrichten übernommene Titel zeigen: „Scientists watch whales from space“, „The pope's baby steps on gays“.

### NLP nutzt Lexika, Regeln und Maschinelles Lernen

Zur Bewältigung dieser Herausforderung nutzt NLP verschiedene KI-Methoden, vor allem Lexika und regelbasierte Verfahren (klassische Computerlinguistik) und Maschinelles Lernen (ML), etwa in der Form des Deep Learning.

#### Klassische Computerlinguistik

Die Analyse und Aufbereitung von Text mittels klassischer computerlinguistischer Verfahren besteht aus folgenden Schritten:

#### 1. Erkennung von Wörtern und ihre Normalisierung

Zunächst wird der Text in eine Folge von Wörtern zerlegt. Wichtig ist auch die Normalisierung dieser Wörter und für die weitere Verarbeitung die Bestimmung des Wort-Typs (Substantiv, Verb, usw.). Beides wird meist auf Basis von Lexika realisiert. Beispiele sind etwa die Lemmatisierung, um bei einer Suche nach „Buch“ auch „Bücher“ zu finden, oder die Komposita-Zerlegung, die „Buchhandel“ und „Kinderbuch“ als Treffer ermöglicht. Meist ist auch noch eine weitere Normalisierung auf den

Wortstamm (Tänzer -> tanzen) notwendig. Ebenso sind semantische Lexika mit Thesauren erforderlich, damit verwandte Begriffe wie „Auto“ und „Kfz“ miteinander identifiziert werden können.

In Chinesisch oder Japanisch kann schon die Identifizierung der Wortgrenzen nur über große Lexika gelöst werden.

#### 2. Erkennen von Entitäten

Bei Entitäten handelt es sich etwa um Namen von Personen, Unternehmen, Produkten oder Orten. Basis für das Erkennen dieser Informationseinheiten sind spezielle Lexika (zum Beispiel typische Vor- und Nachnamen) und typische Kontexte dieser Entitäten. So stellen Formulierungen wie „liegt in“ oder „wohnt in“ typische Kontexte für Ortsangaben dar. Regelbasiert wird dann auf Basis von Matches mit den Lexika und den Kontextbeschreibungen entschieden, ob für eine konkrete Textstelle eine Entität identifiziert werden kann.

#### 3. Erkennung von Wortgruppen, Satzstrukturen und Relationen

Die Königsdisziplin der klassischen Computerlinguistik ist die syntaktisch-semantische Analyse kompletter Sätze. Auf Basis der Informationen der beiden vorherigen Analyseschritte und Grammatiken können komplette Sätze analysiert werden. Dabei werden größere Wortgruppen – in obigen Beispielen „mit dem Löffel“ und „mit den Nudeln“ – identifiziert und im ersten Fall als Attribut zum Verb „essen“, im zweiten Fall als Teil des Satz-Objekts „Suppe“ identifiziert. Somit können dann Relationen erkannt werden. Aus dem Satz „Das Unternehmen Microsoft wurde am 4. April 1975 von Bill Gates und Paul Allen gegründet“ kann zum Beispiel eine Relation (Gründungs-Relation) zwischen den beiden genannten Personen und dem Unternehmen Microsoft extrahiert werden. Auf Basis erkannter Relationen können dann zuverlässig Fragen beantwortet werden.

#### Maschinelle Lernverfahren

Schon lange werden klassische computerlinguistische Verfahren durch ML ergänzt oder ersetzt diese sogar. Aufgaben wie die Bestimmung von Textsprache, Thema eines Textes (Klassifikation) oder Stimmung (Sentiment) werden fast ausschließlich mit ML gelöst. Auch zur Erkennung von Entitäten wird häufig ML eingesetzt. Jedoch hatten ML-Verfahren bisher zwei grundsätzliche Nachteile: 1. Es wurden große Mengen von manuell analysierten Beispieltextran als Trainingsmengen benötigt. 2. Bis vor ein paar Jahren war ML eher eine Domäne für Experten, da die Aufbereitung der Texte (Feature-Engineering) oft eine entscheidende Voraussetzung für den Erfolg war.

Mit der Entwicklung der Deep-Learning-Ansätze der letzten Jahre werden die Karten neu verteilt. Zum einen ist das oben erwähnte Feature-Engineering weniger wichtig, da die tiefen Neuronalen Netze in der Lage sind, die für die jeweilige Anwendung entscheidenden Features automatisch zu generieren. Wichtig für den Erfolg von Deep Learning im Bereich NLP sind die sogenannten Word Embeddings. Es handelt sich hierbei um neuronale Repräsentationen für Wörter. Wörter, die typischerweise in ähnlichen Kontexten verwendet werden und damit auch semantisch ähnlich sind, bekommen automatisch ähnliche Repräsentationen. Für das Training von Word Embeddings sind keine manuell analysierten Trainingsbeispiele notwendig. Große Textmengen, die ja ausreichend zur Verfügung stehen, genügen völlig. Word Embeddings können manuell generierte Lexika ersetzen oder zumindest ergänzen.

Mit ähnlichen Ansätzen kann man Repräsentationen für ganze Sätze generieren. Deep-Learning-Enthusiasten propagieren gar die komplette Ersetzung klassischer computerlinguistischer Ansätze und klassischer Suchmaschinentechnologie. Die Zukunft wird zeigen, ob wir hier einen kompletten Technologiewandel erleben oder ob eher die Kombination neuer und alter Ansätze weiterführt.

#### NLP bietet dialogbasierte Suche, Textklassifikation und-analyse

Die Vorteile eines NLP-Einsatzes sind weitreichend. Wir wollen hier insbesondere drei Anwendungen im Unternehmensbereich skizzieren:

#### 1. die intelligente natürlichsprachliche dialogbasierte Suche

Mittels NLP kann ein Enterprise-Search-System natürlichsprachliche Sucheingaben verarbeiten. Damit kann es Treffer liefern, die zu kompletten Fragesätzen wie etwa „Welcher Geschäftspartner brachte 2017 den größten Umsatz?“ passen. Der Nutzer gelangt dadurch deutlich schneller und intuitiver an die gewünschte Auskunft als etwa bei einer Suche per Keywords.

Insbesondere im Support-Bereich wird eine natürlichsprachliche und dialogbasierte (Chatbots) Suche immer wichtiger. Beim Kundensupport können zum Beispiel Anfragen über virtuelle Assistenten aufgenommen, mit FAQ-Datenbanken abgeglichen und anschließend beantwortet werden.

#### 2. die Verschlagwortung von Dokumenten und die Textklassifikation

Neben Suchanwendungen spielen auch Anwendungen eine Rolle, bei denen es um eine automatische Bewertung (Klassifikation) von Texten geht. NLP-Verfahren können die Dringlichkeit, Stimmung (Sentiment) oder die Art (technisches Problem, Kündigung, Abrechnungsfragen) einer Kunden-Anfrage automatisch erkennen und entweder eine passende automatische Antwort generieren oder die Anfrage an den geeigneten Experten im Unternehmen weiterleiten (automatische Sortierung des Posteingangs).

Unternehmen, in denen viele eingehende Texte bislang zur weiteren Bearbeitung manuell vortriert werden müssen, eröffnet sich dadurch ein erhebliches Optimierungspotenzial. E-Mails, die in Sammelpostfächern eingehen und Briefe oder Faxe, die in der Poststelle via Optical Character Recognition (OCR) digitalisiert werden, können mittels NLP ohne weiteres menschliches Zutun klassifiziert werden.

#### 3. Lesehilfe und Analyse größerer Textmengen

Eine NLP-Lösung, die sowohl linguistische Regeln als auch Künstliche Intelligenz und maschinelle Lerntechniken nutzt, kann das Wesentliche aus Hunderten von mehrseitigen Texten extrahieren. Damit können etwa Juristen bei Gesetzesänderungen oder Firmenübernahmen große Bestände von Verträgen automatisch auswerten. Auf Basis moderner ML-Verfahren erkennt eine NLP-Software selbstständig Klauseln und wichtige Datenpunkte und extrahiert sie zur gezielten Prüfung, Kommentierung und Bearbeitung. Juristen sparen damit enorm viel Zeit und können sich wieder verstärkt ihren Kernaufgaben widmen. Zudem minimieren sie so das Risiko, relevante Klauseln zu übersehen.

NLP-Software wird zwar in Zukunft in immer mehr Anwendungsszenarien ihre Praxistauglichkeit nachweisen, bereits heute aber kann sie ein zentrales Problem auf Unternehmensseite beseitigen: den vielfach hohen Zeitaufwand von Mitarbeitern für oft völlig ergebnislose Informationsrecherchen. Mit NLP-Lösungen können Nutzer auch W-Fragen stellen und so die Suchergebnisse deutlich verbessern. Das NLP-Anwendungsspektrum umfasst dabei klassische suchgetriebene Anwendungen wie Intranet- und Internetsuche, Enterprise Search oder E-Commerce-Suche. Und auch im User Helpdesk, bei Self-Services oder bei Chatbots hilft NLP, die passenden Antworten zu finden, indem Fragen syntaktisch und semantisch analysiert werden.

Dr. Christoph Goller



Dr. Christoph Goller,  
Research Director,  
IntraFind  
Software AG

# 1.4 AFFECTIVE COMPUTING

## Was ist Affective Computing?

„Wie geht's dir?“, die wahrscheinlich meistgestellte Frage der Welt und trotzdem eine Frage, die – bzw. deren Antwort – sich unglaublich schwer digitalisieren lässt. In nicht allzu ferner Zukunft werden uns unsere Autos selbständig durch die Welt kutschieren, aber ist Ihr Auto schonmal auf die Idee gekommen, Sie zu fragen, wie es Ihnen geht?

Während auf der einen Seite Maschinen immer intelligenter werden, fehlt ihnen auf der anderen Seite eine Art von emotionaler Intelligenz, die wir Menschen – mal mehr, mal weniger ausgeprägt – besitzen und die in vielen Bereichen des Lebens vielleicht sogar die wichtigere Komponente beim Miteinander darstellt.

Genau diese emotionale Intelligenz ist das Kernelement des Forschungsgebiets „Affective Computing“. Es geht dabei darum, Systeme zu entwickeln, die menschliche Emotionen und Affekte automatisiert erkennen können, und diese Information wiederum zur Verbesserung des bereitgestellten Dienstes verwenden. Im Extremfall wird das System sogar befähigt, Affekte zu simulieren. Dinge werden also empathisch und emotional.

Die Idee des Affective Computing wurde bereits 1995 zum ersten Mal formuliert [1], erfährt aber erst jetzt größeres Interesse außerhalb des Wissenschaftsbetriebes. Dies liegt wie bei so vielen aktuellen Entwicklungen auch daran, dass durch die Fortschritte z.B. im Bereich des Deep Learnings deutlich bessere Erkennungsraten erzielt werden können. Es ist mittlerweile also sowohl nötig als auch möglich, Ideen des Affective Computing in echten Szenarien einzusetzen. Diese Einsatzgebiete reichen von der Optimierung intelligenter Umgebungen (z.B. im Smart-Home-Bereich) über Empfehlungssysteme bis hin zu gesundheitlichen Themen (z.B. Burn-Out-Prävention).

Dieser Beitrag ist der Start einer kleinen Serie von Artikeln, die unterschiedliche Themen des Bereichs Affective Computing beleuchten werden. Ziel ist es, Ihnen einen Eindruck zu vermitteln, wie diese Technologie funktioniert und wie sie eingesetzt werden kann.

Dr. Marco Maier

Referenzen [1] <http://affect.media.mit.edu/pdfs/95.picard.pdf>

## Was macht ein Gebäude intelligent?

### Wann fühlen wir uns in einem Gebäude wohl?

Wir verbringen, sowohl im Arbeitskontext, als auch im Privaten, die meiste Zeit in Gebäuden. Jahrzehntelange Forschung im Bereich Indoor Environment Quality (IEQ) zeigt, dass die Eigenschaften des Gebäudes unsere Gesundheit und unser Wohlbefinden stark beeinflussen und auch beeinträchtigen kann. Zu diesen Eigenschaften gehören beispielsweise unangenehme Temperaturen oder Lärm im Großraumbüro [1]. Auch unsere Stimmung wird durch Eigenschaften der Umgebung beeinflusst. Moderne Wohn- und Arbeitsumgebungen müssen daher an den Bedürfnissen von Bewohnern und Mitarbeitern orientiert sein. Das notwendige Wissen über diese Bedürfnisse kann aus der IEQ-Forschung abgeleitet werden. Ein konkreter Parameter ist beispielsweise die Temperatur. Sie muss in einem angenehmen Bereich liegen, der nicht einfach durch eine Gradzahl ausgedrückt werden kann, da er von vielen Faktoren abhängt – wie persönlichen Vorlieben, Kleidung und Außentemperatur. Um konzentriert arbeiten zu können, darf auch eine bestimmte Lautstärke nicht überschritten werden, der Schwellwert hier ist u.a. abhängig von der Art der Geräusche. Auch die Lichtverhältnisse in Gebäuden sind äußerst wichtig für gesundheitliche und das Wohlbefinden betreffende Aspekte, je näher sie an den natürlichen Bedingungen sind, umso besser. Dadurch wird der natürliche Tagesrhythmus unterstützt. Auch Luftqualität, Sauberkeit und Gestaltung des Innenraums sind nicht zu vernachlässigen, um nur die wichtigsten Aspekte zu nennen. Wie schon am Beispiel der Temperatur zu sehen war, gibt es nicht für jeden Parameter einen statischen Soll-Zustand. Vielmehr müssen persönliche Präferenz und die aktuelle Situation berücksichtigt werden – welche Aktivität oder Aufgabe vorliegen, wie der innere Zustand des Menschen aussieht und vieles mehr. Beispielsweise ist bei anstrengenden körperlichen Arbeiten eine geringere Temperatur gefragt, und im Arbeitskontext sind ganz andere Lichtverhältnisse förderlich als abends zur Entspannung. Bei der Entwicklung intelligenter Gebäude sind diejenigen Faktoren, die sich dynamisch ändern, besonders interessant. Es werden zuallerst Sensoren gebraucht, die den Ist-Zustand erfassen können, und dann ein Konzept zur Berechnung eines Sollzustands und dazu, wie dieser durch Aktorik erreicht werden soll.

### Moderne Sensorik und Aktorik eröffnen neue Möglichkeiten

Der Trend der letzten Jahre hin zu immer kleineren, immer weiter verbreiteten „wearables“ ermöglicht eine immer komfortablere und unauffälligere Ermittlung physiologischer Parameter als Ergänzung

zu weiter verbreiteten Sensoren wie Temperatur- und Helligkeitssensoren. Damit wird es beispielsweise auch möglich, hohe Stresslevel zu erkennen, welche ein ernstzunehmendes Gesundheitsrisiko darstellen [2], und darauf zu reagieren. Dies könnte beispielsweise durch ein Abschalten unwichtiger Benachrichtigungen erfolgen [3]. Ein intelligentes Gebäude ist vor allem dadurch gekennzeichnet, dass es auf sich verändernde Gegebenheiten reagiert, und zwar autonom und im Interesse des Benutzers [4]. Es muss also über gut vernetzte Sensorik verfügen und aus einzelnen Messungen ein Modell der momentanen Umgebung schaffen können. Um angemessen auf eine Situation reagieren zu können, ist nicht nur die entsprechende Aktorik nötig, sondern auch ein Konzept zur Verarbeitung der Informationen und zur Ermittlung des Soll-Zustands. Die intelligente Umgebung beinhaltet Sensorik, Aktorik und intelligente Software. Bisherige Konzepte zum Entwurf und zur Steuerung solcher Systeme sind aber noch unausgereift. Es müssen intelligente Lösungen erarbeitet und erprobt werden [5].

### Was ist das Ziel eines intelligenten Gebäudes?

Vernetzte Umgebungen werden immer mehr Einzug in unseren Alltag erhalten. Die Gebäude, in denen wir leben und arbeiten, sollten in Zukunft nicht nur energetisch bestmöglich agieren, sondern auch im Hinblick auf die Bedürfnisse der darin lebenden Menschen optimiert werden. Eine potentielle Herausforderung ist dabei das Finden einer Balance zwischen Energieoptimierung und Bedürfnisorientierung. Auch Datenschutz und Sicherheit und Stabilität des Systems sind als Anforderungen nicht zu vernachlässigen. Ein zusätzlicher zentraler Punkt, auch für die Akzeptanz der Gebäude, wird das Thema Kontrolle sein. Die Zunahme automatisierter Funktionen intelligenter Gebäude birgt die Gefahr, dass die Kontrolle des Einzelnen abnimmt und sich die Mitarbeiter oder Bewohner möglicherweise bevormundet fühlen, was zu Unzufriedenheit und Stress führen würde [4]. Es muss also tatsächliche Kontrollmöglichkeiten geben, den Algorithmen des Gebäudes übergeordnet, und dass nicht nur bei Fehlfunktion des Systems. Die Entwicklung intelligenter Gebäude muss also zahlreiche Bedingungen erfüllen und erfordert eine interdisziplinäre Zusammenarbeit der Fachgebiete, von Architektur über Psychologie hin zur Informatik.

Lilian Schröder BA, BSc

Referenzen [1] Kim, J., & de Dear, R. (2012). Nonlinear relationships between individual IEQ factors and overall workspace satisfaction. *Building and Environment*, 49, 33-40. [2] Muaremi, A., Arnrich, B. & Tröster, G. (2013). Towards measuring stress with smartphones and wearable devices during workday and sleep. *BioNanoScience*, 3(2), 172-183. [3] Healey, J. A. & Picard, R. W. (2005). Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on intelligent transportation systems*, 6(2), 156-166. [4] Reijula, J., Gröhn, M., Müller, K. & Reijula, K. (2011). Human well-being and flowing work in an intelligent work environment.

*Intelligent Buildings International*, 3(4), 223-237. [5] Schröder, L., Pörtner, A., König, M. & Hoffmann, M. (2016). Überlegungen zu Multi-Sensor-Aktor-Systemen und Kontrolle in intelligenten Arbeitsumgebungen. *INFORMATIK 2016*, 46. Jahrestagung der Gesellschaft für Informatik, Klagenfurt.

## Step Up! Die vier Stufen Emotionaler Intelligenz

Das Thema künstliche Intelligenz begegnet uns derzeit in allen Lebens- und Arbeitsbereichen. AI ist das Buzz Wort unserer digitalen Zeit. Im Wesentlichen geht es um die Verbesserungen von Maschinen oder Prozessen durch Autonomisierung und selbstlernende Systeme.

Emotion AI und die Berücksichtigung des Faktors „Mensch“ ist in der Landschaft Künstlicher Intelligenz ein neues Gewächs. Ähnlich den Entwicklungsstufen beim autonomen Fahren, hat man es bei der emotionalen Intelligenz von Maschinen ebenfalls mit einem Level-Modell zu tun:

Wie die Grafik zeigt, wird die Zukunft, Maschinen, Produkte und Services hervorbringen, die zunehmend empathisch werden und das Leben der Menschen sicherer, effizienter und angenehmer gestalten können.

Level 0 steht für einen EQ von Null. Im Moment trifft dieses Level wohl auf 99% aller Maschinen auf diesem Planeten zu. Eine Industrieanlage oder auch ein Taschenrechner haben keinerlei Zugang zu dem affektiven Zustand ihrer Nutzer. Sie dienen dem Menschen lediglich als Werkzeug und Erleichterung, um Aufgaben, wie z.B. kompliziertes Kopfrechnen, zu erledigen. Auch sogenannte „smarte Chatbots“ gehören diesem Level an. Fragen Sie Alexa gerne einmal „Alexa, wie fühle ich mich?“, die Antwort wird Sie enttäuschen.

Level 1 ist in regelbasierten Systemen und Assistenten vorzufinden, die an menschliche Emotionen appellieren oder Annahmen treffen, dass sich ein Mensch in einem bestimmten Zustand (wie z.B. Stress) befindet. Ein Beispiel hierzu ist die seit 2009 eingeführte Anzeige der kleinen Kaffeetasse im Auto Cockpit, die in Abhängigkeit der gefahrenen Kilometer signalisieren soll, ob der Fahrer nicht vielleicht etwas müde und unaufmerksam ist. Weiteres Beispiel ist die in den 90er Jahren aus Japan stammende Erfolgsgeschichte des Tamagotchi. Ein elektronisches Küken, das in Abhängigkeit der Zuwendung bzw. Nutzungsintensität zufrieden ist oder stirbt, um daraufhin wiederbelebt werden zu können.

Von einer echten emotionalen Intelligenz kann man allerdings erst in Level 2 sprechen. Das Forschungsprojekt und Startup TAWNY.ai ist ein Beispiel für diese Stufe. Mit Hilfe von Armbändern werden biometrische Daten wie Herzratenvariabilität oder elektrodermalen Widerstand der Haut gemessen, um im Anschluss die menschlichen Emotionen und



Dr. Marco Maier,  
Head of Artificial  
Intelligence,  
HYVE AG



Lilian Schröder  
BA, BSc,  
IoT-Lab

Zustände der Über- und Unterforderung sowie Flow zu klassifizieren. Diese Information wird im Anschluss an vernetzte Geräte weitergegeben, um diese empathisch zu machen. Autos wissen wie aggressiv ihr Fahrer ist und können die Fahrerassistenzsysteme entsprechend autonom anpassen. Das Smartphone weiß bei welchen Einstellungen sich die Bewohner am wohlsten fühlen. Der Fernseher gibt Programmempfehlungen abhängig von der Stimmung des Zuschauers. Die Arbeitsstätte passt sich dem mentalen Zustand der Mitarbeiter an. Diese Ebene emotionaler intelligenter Produkte und Services birgt das Potential eines Game Changer für ganze Industrien zu sein, da es eine völlig neue Dimension zur Verbesserung der Arbeitszufriedenheit, der Arbeitssicherheit und der Individualisierung von Anwendungen ermöglicht.

Level 2 wird von TAWNY bereits in unterschiedlichsten Anwendungsfällen in die Realität umgesetzt. Als Beispiel hierfür ist der Leistungssport zu nennen. In der Schweizer Biathlon Arena Lenzerheide führte TAWNY gemeinsam mit dem Schweizer Profinachwuchs im Biathlon und der Innovationsabteilung von Red Bull Media House erste Tests durch, wie zukünftig die Trefferwahrscheinlichkeit der Athleten auf Basis biometrischer Muster vorhergesagt werden könnte. Klicke auf <https://youtu.be/tiQwXrbwOQc>, um TAWNY auf der Loipe zu sehen.

Level 3 wird noch innerhalb der nächsten 20 Jahre erreicht sein. Durch den multimodalen Input von kamerabasierter Mimik-Erkennung, Sprachanalyseverfahren, textbasierter Sentiment-Analyse und Vitaldaten wird man ein 24/7 Emotionsprofil zusammensetzen, um die Umgebung jedes Menschen an seine Emotions- und Stimmungswelten sowie mentalen Allgemeinzustand anzupassen. Vor dem Hintergrund, dass Menschen eben nicht die Rationalitätsannahme des homo oeconomicus erfüllen, wäre eine Messbarkeit und Prognose gefühlsgetriebener

Handlungen ein Meilenstein in der Konsumentenforschung.

Ob es Ziel sein sollte, Level 4 der emotionalen Intelligenz zu erreichen, wird kontrovers diskutiert. Hier geht man davon aus, dass Roboter eigene Gefühle entwickeln können und nicht nur die von Menschen erkennen können, um diesen besser zu dienen. Viele Länder und Organisationen beschäftigen sich gerade damit wie man AI regulieren kann oder soll. Die Diskussion wird befeuert von prominenten Personen wie Elon Musk, Stephen Hawking oder Bill Gates. Auf der einen Seite steht das Bild einer Technologie Apokalypse verursacht durch die unethische und selbstbestimmte Verbreitung der KI, auf der anderen Seite stehen die immensen wirtschaftlichen Potenziale durch autonome Systeme und damit die Möglichkeit den Wachstumshunger einer globalisierten Welt zu stillen.

Dr. Michael Bartl, Regina Burgmayr

## 1.5 USE CASES

### Instrumente der Zukunft: Software-Roboter gesteuerte Prozessautomatisierung (RPA) und Künstliche Intelligenz (KI) als wichtige Wettbewerbsfaktoren

Software-Roboter gesteuerte Prozessautomatisierung (engl. Robotic Process Automation, RPA) ist eine aus der klassischen Prozessautomatisierung hervorgehende Technologie. Das Spektrum reicht dabei von einfachen, händisch eingerichteten Workarounds bis hin zu komplexer Software auf einer virtuellen Maschine. Dank RPA können Unternehmen ihre Pro-

zesse autonom ablaufen lassen und gleichzeitig ihre Systemsicherheit erhöhen. Software-Roboter ahmen Industrieroboter nach. Sie automatisieren Abläufe, die von den Applikationen selbst nur unzureichend abgebildet werden. Hierdurch gewinnen Mitarbeiter wertvolle Zeit, um sich auf andere, wichtigere Aufgaben zu konzentrieren. Dazu zählt etwa der Kundendienst.

Bei RPA geht es also nicht nur um Kosteneinsparungen, sondern auch um die Steigerung und Vereinheitlichung des Qualitätsniveaus. Die Erbringung von Dienstleistungen ist in hohem Maße von Prozessen abhängig, die ein bestimmtes Urteilsvermögen voraussetzen. Unternehmen, die neben software-roboter gesteuerten Prozessautomatisierung auch künstliche Intelligenz (KI) und maschinelles Lernen einsetzen, können Ressourcen, Zeit und Geld weitaus sinnvoller einsetzen.

Zum Beispiel können Backoffice-Funktionen durch Software Robotik effizienter gestaltet werden, indem die produktiveren Roboter ihre menschlichen Vorgänger ersetzen. Software Roboter können im Bedarfsfall rund um die Uhr arbeiten, nehmen keinen Urlaub und werden nicht krank. Hierdurch vervielfachen sich die verfügbaren Arbeitsstunden pro Jahr im Vergleich zu einer durchschnittlichen menschlichen Arbeitskraft und Aufgaben können zehn bis zwölf Mal schneller erledigt werden. Dies kann die Produktivität eines Unternehmens um das 50- oder 60-Fache erhöhen.

#### Die zwei Arten von RPA-Robotern

- 1) Bedient oder beaufsichtigt: Menschliche Nutzer steuern den Prozess und bestimmen, wann Transaktionen durchgeführt werden.
- 2) Unbedient oder unbeaufsichtigt: Der Software Roboter kann Transaktionen durchgehend und ohne menschliche Beteiligung durchführen. Menschen greifen nur im Ausnahmefall ein.

Die „Intelligenz“ eines Software Roboters hängt davon ab, wie viel er beim Ausführen seiner Prozesse lernen kann. Einfache RPA-Roboter, die unbediente oder bediente Prozesse ausführen, müssen trainiert werden: Ihnen fehlt Intelligenz oder selbständige Lernfähigkeit und sie sind von regelmäßigen Softwareaktualisierungen abhängig. Je nach Komplexität der Logik, mit der der Roboter ausgestattet wurde, können solche Anwendungen ganz einfach automatisiert werden.

Sogenannte kognitive Technologien, die auf künstlicher Intelligenz (KI) und maschinellem Lernen basieren, erweitern die Fähigkeiten von Software Robotern erheblich. Maschinelles Lernen bezieht sich auf Software, die Muster (engl. Patterns) erkennen und analysieren sowie das künftige Verhalten der Software entsprechend anpassen kann. Solche Systeme können beeindruckend komplex

sein und durch den Einsatz umfangreicher Logik zur Analyse von Mustern „intelligent“ erscheinen. Im Fall „richtiger“ KI dagegen können Software-Systeme über ihre ursprüngliche Umgebung hinaus lernen und sich anpassen. KI-Systeme können sich ohne menschliches Eingreifen weiterentwickeln und ihr Verhalten ändern. Fast jedes zweite Unternehmen in der Telekommunikationsbranche setzt daher bereits auf Künstliche Intelligenz.

#### Die zwei Typen von RPA-Anwendungen

- 1) „Beaufsichtigte“ Anwendungen werden offline vorbereitet und programmiert und anschließend in die Live-Umgebung eingebettet. Diese Art von KI wird mithilfe großer Datensätze trainiert, um Klassifizierungsfunktionen zu entwickeln, die beispielsweise für folgende Anwendungen genutzt werden:
  - Informationserfassung: visuelle Informationen wie Fotos oder andere zur Gesichtserkennung verwendete Bilder
  - Audioanalyse: Transkription von gesprochener Sprache, Sprachdialogsysteme (IVR) oder Voice UI/UX
  - Datenextraktion: aus unstrukturierten Dokumenten oder für automatisierte Online-Assistenten und Chatbots
- 2) „Unbeaufsichtigte“ Anwendungen erfahren ein ähnliches Training wie die einfacheren Versionen, sind jedoch in der Lage, ihre Umgebungen zu studieren und von ihnen zu lernen. Dadurch können sie sich anpassen und neue Verhaltensweisen annehmen. Das erhöht ihre Fähigkeit zur Entscheidungsfindung und lässt ihr Denkmuster dem menschlichen ähnlicher werden.
  - Diese Art von KI wird zur Datenanalyse genutzt, zum Beispiel zur Erkennung von Mustern in Kundendaten.
  - Anbieter wie Google und Facebook nutzen diese Art von Anwendung, um das Verhalten ihrer Nutzer zu analysieren und ihnen maßgeschneiderte Suchergebnisse, Newsfeeds und Werbung bereitzustellen.

Ergänzt wird KI durch Optionen wie natürliche Sprachverarbeitung (beispielsweise das Verständnis unstrukturierter Dokumente wie E-Mails oder Briefe), Schlussfolgerungen (Handlungen auf Basis der verfügbaren Daten) und Antizipation (z. B. die Einschätzung des Kaufverhaltens anhand früherer Käufe). So werden Daten in nützliche Informationen umgewandelt.

Trotz ihrer Ähnlichkeiten und Überschneidungen gibt es große Unterschiede zwischen RPA und KI. Wie bereits erwähnt, führen RPA Software-Roboter Tätigkeiten, die ihnen beigebracht wurden, präzise aus – ideal für regelbasierte Prozesse, in denen



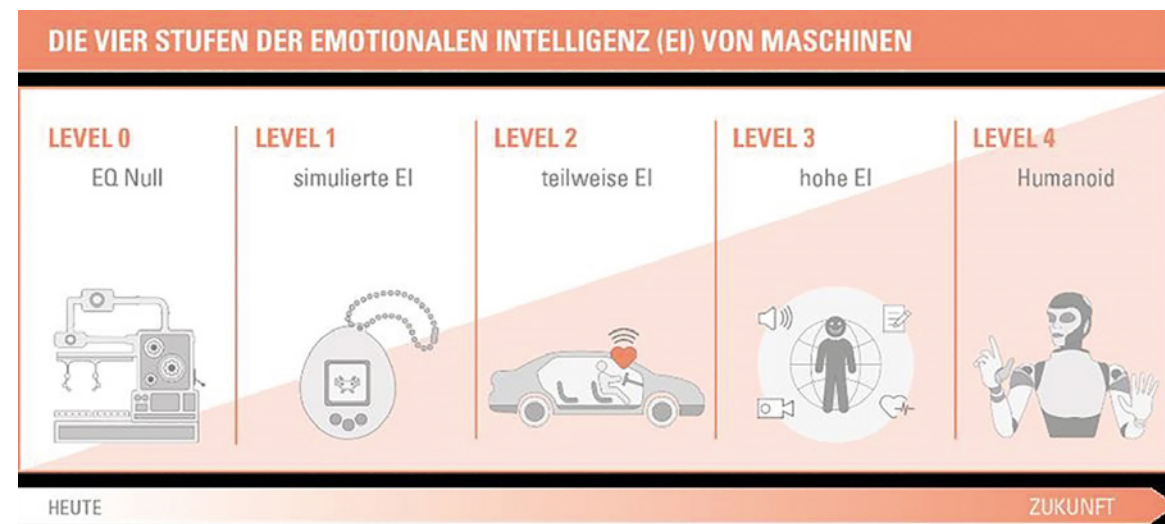
Dr. Michael Bartl,  
Vorstand,  
HYVE Unternehmensgruppe für  
Innovation



Regina Burgmayr,  
Projekt- und Communitymanager,  
TAWNY GmbH



Markus Mayer,  
Senior Director  
Customer Services  
Germany,  
Axway



Die vier Stufen der emotionalen Intelligenz von Maschinen. Hyve Sciences Labs 2017

Compliance und Genauigkeit entscheidend sind. Bei mehrdeutigen Inputs oder Daten (zum Beispiel unstrukturierten E-Mails) bzw. einer großen Datenmenge eignen sich jedoch maschinelles Lernen und KI besser, da diese nicht nur eine Mehrdeutigkeit besser handhaben, sondern im Laufe der Zeit auch dazulernen und ihre Fähigkeiten optimieren.

#### RPA allein reicht nicht aus

Zwar haben Mitarbeiter dank RPA-Instrumenten mehr Zeit für wichtigere Aufgaben, die Urteilsvermögen und Erfahrung voraussetzen. Doch mit RPA allein kann das volle Potenzial für Kosteneinsparungen und Effizienzsteigerungen nicht ausgeschöpft werden. Um umfassend von RPA und kognitiven Technologien zu profitieren, müssen Unternehmen zusätzliche Tools zur Analysierung der enormen Menge an Betriebs- und Kundendaten einsetzen, die von den Robotern in jedem Arbeitsprozess gesammelt und erzeugt wird (Stichwort: Big Data).

Software-Roboter-gesteuerte Instrumente allein sind nur bedingt in der Lage, durchgehende Prozessintelligenz zu entwickeln. Bei individuellen, kleinteiligen Arbeitsschritten innerhalb eines Prozesses sammeln die Roboter kontinuierlich eine bestimmte Menge an Daten und überwachen ihre eigenen lokalen Aktivitäten. Allerdings bieten robotergesteuerte Instrumente nicht die erforderliche Sichtbarkeit des Gesamtprozessstatus, um beispielsweise die Auswirkungen der Automatisierung auf die Service-Ebene zu bewerten, und liefern nicht die nötigen Erkenntnisse über Optimierungsmöglichkeiten des Prozesses.

#### Was ist Operational Intelligence?

Operational Intelligence (OI) ist die neueste Form von Datenanalyse, die Unternehmen zur Optimierung ihrer Geschäftsabläufe einsetzen. OI stellt eine Verbesserung gegenüber früheren Analyseverfahren dar, die schlicht vergangene Ereignisse gemeldet haben. OI-Systeme untersuchen aktuelle Ereignisse, liefern Empfehlungen und benachrichtigen in Echtzeit über das Erreichen vorab definierter Schwellenwerte.

Mithilfe von OI-Plattformen können Unternehmen schnell auf veränderte Geschäftsbedingungen reagieren und auf Grundlage von Trends, die durch einen Basisdatensatz innerhalb der Unternehmensdaten ermittelt werden, Prozessverläufe und -ergebnisse vorhersagen.

Geeignete OI-Tools umfassen folgende Funktionen:

- Kundenanalyse zur Auswertung von Daten und Aktivitäten von Kunden, um ihr Verhalten zu verstehen, den Kundennutzen und die Kundenbindung zu verbessern sowie Verkaufszahlen zu steigern
- Betriebliche Analyse zur Messung und Sicherstellung der Qualität, Gewährleistung der Compliance und Minderung von Risiken, Nachfragesteuerung

sowie Optimierung von Geschäftsprozessen auf Basis der Effizienz der Transaktionsprozesse

- Anwendung von geeigneten Methoden, Wissen und Erfahrung zur Identifizierung der richtigen Parameter

Es ist jedoch wichtig, dass das Unternehmen und die Geschäftsführung diese Informationen auch als Aufruf zum Handeln verstehen und die Geschäftsprozesse entsprechend optimieren, unabhängig davon, ob sie von Menschen, Software Robotern oder beiden ausgeführt werden.

#### Warum Operational Intelligence für RPA unerlässlich ist

Mit OI-Instrumenten können Nutzer schnellere, klügere Entscheidungen treffen. Sie ermöglichen es Unternehmen, Daten aus robotergesteuerten, transaktionalen, analytischen und Workflow- sowie Datenbank-basierten Systemen zu kombinieren, um eine einzige anpassbare Übersicht der wichtigsten Kennzahlen und Leistungsindikatoren des Unternehmens und seiner Prozesse zu entwickeln. Dies befähigt die Unternehmen wiederum zur optimalen Nutzung ihrer betrieblichen Daten. Die gewonnenen Erkenntnisse können sie für ihre Entscheidungsfindung einsetzen und ihre Prozesse gegebenenfalls ändern oder neu aufsetzen sowie neue Produkte und Dienstleistungen schneller und wirksamer entwickeln und anbieten.

Für die erfolgreiche Implementierung eines OI-Tools zur Unterstützung der RPA ist die Integration ins transaktionale RPA-System erforderlich. Außerdem müssen die Ergebnisse und Analysen des Systems von den Personen aufgegriffen werden, die die betrieblichen Prozesse durchführen, damit eine Kultur der kontinuierlichen Optimierung möglich wird.

Axway Decision Insight ist ein gutes Beispiel für ein OI-Tool, das separat und ergänzend zu einem Software RPA-Programm implementiert werden kann. Es erlaubt Unternehmen, stärker von vorhandenen Lösungen zu profitieren oder ihr Potenzial von Anfang an voll auszuschöpfen. Die Kombination aus Axway Decision Insight und RPA bietet einem Unternehmen wertvolle Einsichten in seine Prozesse. Dazu zählen die Identifizierung von Engpässen und Unterbrechungen normaler Datenflüsse sowie die Verbesserung von Auslastung, Produktivität und Kundennutzen. Unternehmen, die Axway Decision Insight mit RPA verknüpfen und die gewonnenen Erkenntnisse und Informationen praktisch umsetzen, können von den fortschrittlichen Analysefähigkeiten von Axway Decision Insight profitieren. Markus Mayer

## So profitieren Unternehmen von KI-Chatbots

Wie viele andere intelligente Technologien wurden auch Chatbots seit ihrem ersten Erscheinen neugierig und zugleich besorgt beobachtet. Es stellte sich die Frage, welchen Einfluss diese Technologie hat und wie sie sich auf Unternehmen und ihre Geschäftsprozesse auswirken könnte.

Inzwischen ist der Einsatz von künstlicher Intelligenz und Chatbots zu einem wichtigen und wertvollen Bestandteil vieler Unternehmen geworden und erleichtert in einigen Bereichen erheblich den Arbeitsalltag. Ob im Kundensupport oder bei wiederkehrenden Geschäftsprozessen – für viele Unternehmen sind KI-Chatbots kaum noch wegzudenken.

#### Warum KI-Chatbots?

Unternehmen, die nicht auf aktuelle Trends und technische Fortschritte setzen, laufen Gefahr, hinter der Konkurrenz zurückzubleiben. Da Chatbots Unternehmen in vielen Bereichen unterstützen und sowohl das Markenimage als auch die Beziehung zum Kunden stärken, ist es wichtig, dass die intelligenten Technologien so schnell wie möglich evaluiert und für eigene Zwecke genutzt werden.

#### Chatbots für eine bessere Customer Experience

Beim gegenwärtigen Konkurrenzdruck ist es notwendig herauszustecken. Durch digitale und intelligente Technologien ergeben sich viele neue Möglichkeiten für eine neue und verbesserte Art der Customer Journey. Potenzielle Kunden können rund um die Uhr auf Informationen zugreifen, die von Chatbots auf verschiedenen Kontaktpunkten zur Verfügung gestellt werden. Die Bedienung von Chatbots ist unkompliziert und selbsterklärend, wodurch die Interaktion zu einem angenehmen Erlebnis wird. Neben der Customer Experience wird dadurch auch das Markenimage des Unternehmens gefördert.

Chatbots erleichtern es zudem, den Dialog zum Kunden aufrechtzuerhalten, Vertrauen aufzubauen und Konsumenten so an das Unternehmen zu binden. Zusätzlich sind die intelligenten Helfer ein Aushängeschild für das Unternehmen als solches. Technisch versierte Kunden und IT-Experten lassen sich durch die raffinierten Technologien der KI-Chatbots begeistern.

#### Gesteigerte Nutzerinteraktion

Chatbots erlauben es Nutzern, unkompliziert mit dem Unternehmen zu kommunizieren und zu interagieren. Bots initiieren ein Gespräch, halten den Dialog aufrecht und zeigen spezifische Informationen zum richtigen Zeitpunkt an. Um einen guten Kommunikationsverlauf zu gewährleisten, wird die Interaktion durch benutzerspezifische Ein- und

Ausgaben erweitert, wodurch eine Beziehung zum Nutzer aufgebaut und Vertrauen geschaffen wird. Daher sind Chatbots das beste Mittel, um Kunden länger auf der Unternehmensplattform zu halten.

#### KI als Kundenbetreuer und Sachbearbeiter

Künstliche Intelligenz und Machine Learning sind die perfekten Kundenbetreuer. Sie sind kaum fehleranfällig und können häufig gestellte Fragen vermerken und routiniert beantworten. Dadurch müssen Kunden nicht erst den Internetauftritt des Unternehmens durchsuchen oder möglicherweise am Telefon auf einen freien Ansprechpartner warten, sondern können ihre Fragen und Anmerkungen unkompliziert zu jeder Tages- und Nachtzeit absetzen. Chatbots liefern ohne Verzögerung Antworten und steigern dadurch das Kundenerlebnis. Durch diese intelligenten Technologien werden zudem Personalkosten in der Kundenbetreuung gespart.

#### Aufwand und Kosten reduzieren

KI beschleunigt entscheidend Geschäftsprozesse: Bots können Mails und andere Nachrichten analysieren, ordnen und entsprechende Antwortentwürfe vorformulieren. Einzelne Informationen können im Hintergrund verarbeitet werden sowie direkt und automatisch an entsprechende Plattformen und Personen übermittelt werden. Durch diese Hilfestellungen werden Aufwand und Kosten reduziert und die Effizienz gesteigert.

Außerdem entlasten künstliche Intelligenzen die Mitarbeiter eines Unternehmens. Chatbots zeigen keine menschlichen Eigenschaften wie Erschöpfung und lassen sich nicht von inneren Stimmungen leiten. Somit können sie beispielsweise rund um die Uhr für den Kundenservice eingesetzt werden, um Fragen zu beantworten oder Hilfestellungen bei Routineaufgaben zu bieten. Dadurch werden Kosten in der Kundenbetreuung gespart und Sacharbeiter entlastet, die sich dadurch intensiver anderen Aufgabenbereichen widmen können.

#### Wer nutzt die KI?

Bedenken über die Nutzung von KI-Chatbots werden immer unbegründeter. Die Technologie ermöglicht eine schnelle und einfache Kommunikation mit dem Unternehmen und wird daher zunehmend wertgeschätzt. Außerdem sind immer mehr Verbraucher bereit, die intelligenten Technologien zu nutzen.

#### Überschaubare Implementierungskosten

Ein weiterer großer Vorteil von KI-Chatbots: Sie sind unkompliziert und kostengünstig im Unternehmen zu verankern und erfordern wenig Aufwand in der Entwicklung. Zudem bieten einige IT-Dienstleister Hilfestellung bei der Implementierung.

In den nächsten Jahren wird die Kommunikation



**Holger Hornik,**  
Leiter Artificial des  
Teams Intelligence &  
Data Analytics,  
msg systems AG

via Chatbots immer stärker in die Arbeitswelt einziehen und sich im Alltag der Gesellschaft verankern. Für Unternehmen ist es ratsam, früh auf diesen Zug aufzuspringen und die neuen Möglichkeiten für sich zu nutzen.

Holger Hornik

### Vorausschauende Produktion. Kosten reduzieren, Ausfälle verhindern und Produkte nachhaltig verbessern

Mit maschinellen Lernverfahren lassen sich Produktion und Wartung in der Industrie revolutionieren. Selbstlernende Algorithmen sind in der Lage, Maschinenausfälle vorauszuberechnen. Statt sich von Störungen überraschen zu lassen, erkennen Fabriken die Ursachen weit im Voraus und planen Wartungsarbeiten in die Fertigung ein. Ersatzteile und Techniker lassen sich immer bedarfsgerecht bereithalten. Das reduziert nicht nur Service- und Betriebskosten, sondern steigert zugleich die Produktionsqualität, wenn Daten aus der Maintenance in das Engineering zurückfließen.

Produktivität erhöhen, Umsätze steigern, gleichzeitig Kosten senken und flexibler produzieren – zentrale Motive, die Unternehmen übergreifend mit Industrie 4.0 verfolgen [1]. Auf ihrer Suche nach Wegen, diese Ziele zu erreichen, visiert die Industrie insbesondere Wartung und Instandhaltung an. Denn: Gerechnet auf die gesamte Abschreibungsdauer von Investitionsgütern, wie Förder- oder Produktionsanlagen, entfallen nur 20 Prozent aller Kosten auf die Anschaffung – aber 80 Prozent auf Betrieb und Service („Total Cost of Ownership“) [2]. Heißt konkret: Wer Reparatur- und Stillstandzeiten verkürzt, spart Service- und Betriebskosten und steigert zugleich Umsätze, indem er die Verfügbarkeit und Auslastung seines Produktionsequipments erhöht.

### Industrielle Instandhaltung

Je nach Branche machen Ausgaben für die Instandhaltung rund 2 bis 6 Prozent der Gesamtkosten eines Industrieunternehmens aus [3]. Unternehmen setzen zunehmend auf die vorausschauende Instandhaltung, um ihre Anlagen verfügbar zu halten – durch drei Methoden zur Prävention:

- **Periodisch vorbeugende Wartung**  
Bei der periodisch vorbeugenden Wartung tauschen Fabriken Verschleißteile oder Betriebsmittel nach definierten Zeitintervallen aus. Erst an der Maschine sieht der Wartungstechniker, ob ein Austausch auch wirklich erforderlich ist. Das macht die Arbeit ineffizient.
- **Zustandsorientierte Instandhaltung**  
Die zustandsorientierte Instandhaltung setzt darauf, punktuell einzelne Maschinenparameter wie Temperatur, Druck oder Geschwindigkeit über Sensoren zu kontrollieren, auf dieser Basis Regeln oder Wenn-Dann-Beziehungen abzuleiten und so Servicearbeiten zu koordinieren. Branchen wie die Luftfahrtindustrie, leben diesen Ansatz der Condition-based Maintenance schon seit Jahren.
- **Instandhaltung mit Predictive Analytics**  
Neue Möglichkeiten für eine ganzheitlichere Instandhaltung bieten sich über Datenanalysen. Statt einzelne Maschinenparameter punktuell zu betrachten, lassen sich diese mit Big Data-Lösungen in der Gesamtschau aller unterschiedlichen Parameter auswerten. Unternehmen, die Daten aus dem laufenden Betrieb auswerten, sichern sich Effizienzvorteile und damit einen ökonomischen Wettbewerbsvorteil. Insofern gewinnen Big Data-Lösungen zunehmend an Bedeutung – nicht nur, um Aufträge, Absätze oder Bestände zu analysieren, sondern auch im laufenden Fertigungsbetrieb [4].

Die Möglichkeit, große Mengen von Sensordaten in der Cloud schnell und kostengünstig zu verarbeiten, eröffnet neue Auswertungs- und Nutzenpotentiale. Maschinendaten aus dem laufenden Produktionsbetrieb lassen sich mit Methoden des maschinellen Lernens über Software analysieren. Das heißt: Selbstlernende Algorithmen werten Datenströme der Produktionsanlagen kontinuierlich aus, erkennen Verhaltensmuster der Maschinen und sagen mit hoher Wahrscheinlichkeit voraus, zu welcher Zeit ein Bauteil ausfällt. Auf diese Weise sind Störungen mehrere Tage im Voraus erkennbar. Proaktiv planen die Anwender notwendige Wartungsarbeiten mit Vorlauf ein, bevor ein Ausfall überhaupt eintritt.

### Prognosen durch den Einsatz künstlicher Intelligenz

Gemeinsam mit dem Unternehmen IS Predict hat T-Systems eine Lösung entwickelt, die das Verhalten von komplexen Produktionsprozessen über künstliche Intelligenz prognostiziert. In vielschichtigen Verfahren, in denen sich die Einflüsse laufend ändern oder die Nutzungsprozesse variieren, reichen Regeln nicht aus, um Geräte und Anlagen optimal zu betreiben. Industrielle Zusammenhänge sind nur über entsprechend ausgeprägte mathematische Modelle beschreibbar, die alle möglichen Einflussfaktoren berücksichtigen können: Selbstlernende, kognitive Algorithmen sind in der Lage, versteckte und komplexe Datenmuster aufzudecken und die verwobenen Wirkzusammenhänge zu erkennen.

Selbstlernende Algorithmen, die auch „Kognitive RPA-BOTs“ genannt werden – also kognitive Roboter zur Robotic Process Automation (RPA) – werden zukünftig in der Industrie eine deutlich größere Rolle einnehmen. Auf Basis von historischen Daten werden sie vor ihrem Einsatz im laufenden Fertigungsbetrieb trainiert. So erkennen die RPA-BOTs dann in komplexen und dynamischen Echtzeit-Umfeldern nicht „nur“ den Gesundheitszustand einzelner

Maschinen und stoßen Serviceprozesse an, bevor der Schaden entsteht. Die selbstlernenden Algorithmen stellen etwa auch in der stückorientierten Fertigung sicher, dass kleinste Fehler an Karosserien frühzeitig aufgedeckt werden oder sie kalibrieren Maschinen in der Prozessindustrie vorausschauend. Der Vorteil: Mangelware (schlechte Qualität) verliert zunehmend an Relevanz.

Damit sind selbstlernende Algorithmen regelbasierten oder statistischen Verfahren überlegen: Wie in Abbildung 1 dargestellt lassen sich Indikationen, die zu Störungen führen, frühzeitig erkennen und der Gesundheitszustand von Anlagen als „Anomalie-KPI“ ausdrücken. Weder Regeln mit Grenzwerten noch statistische Verfahren ermöglichen die Vorhersage des Maschinenausfalls (links, rote Markierung). Komplexe Datenmuster decken den Gesundheitszustand von Maschinen auf: Der Anomalie-KPI (rechts, blaue Linie) steigt vor der Störung rapide an. Ausfälle lassen sich Tage oder sogar Wochen im Voraus prognostizieren. Die Kennzahl ermitteln die Algorithmen auf Basis unzähliger Datenpunkte, in denen sie subtile Muster frühzeitig aufdecken, die sich bei einem nahenden Störfall dann verstärken.

### Selbstlernende Algorithmen

Selbstlernende Algorithmen bestimmen den Charakter von RPA-BOTs. Diese Fähigkeiten zeichnen sie aus:

- **Komplexität:** Kognitive Algorithmen erkennen selbst die komplexesten Datenmuster, sodass sich auch vielschichtige und dynamische Prozessstrukturen beherrschen lassen.
- **Transparenz über Störfaktoren:** Kognitive RPA-BOTs erklären Zusammenhänge, indem sie beispielsweise aus allen Datenpunkten einer Maschine genau die Parameter identifizieren, die für Motorschäden – auch nur in bestimmten Konstellationen – verantwortlich sind.



Britta Hilt, Geschäftsführerin, IS Predict GmbH



Georg Rätker, Geschäftsführer, T-Systems on site services GmbH



Karlheinz Blank, IT-Experte und leitender Berater, T-Systems International GmbH

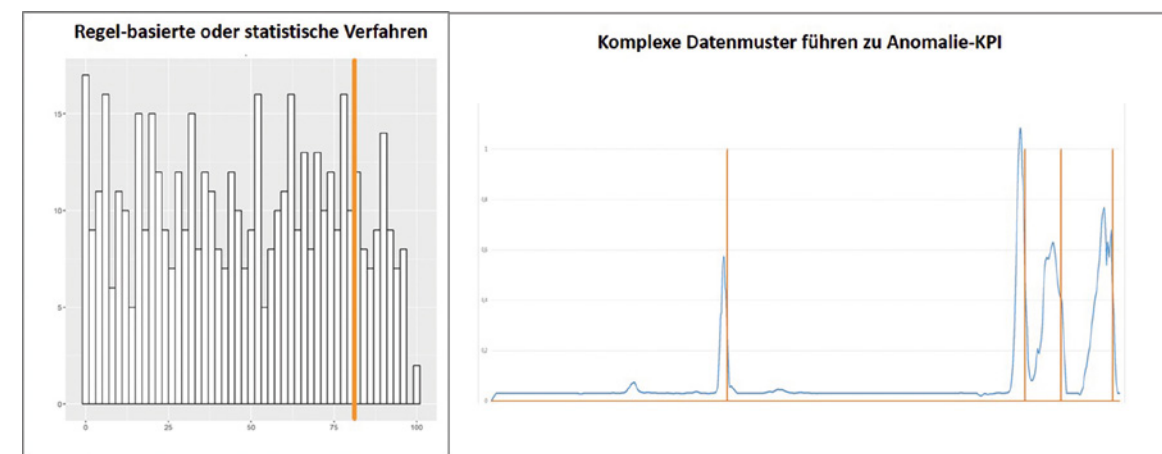
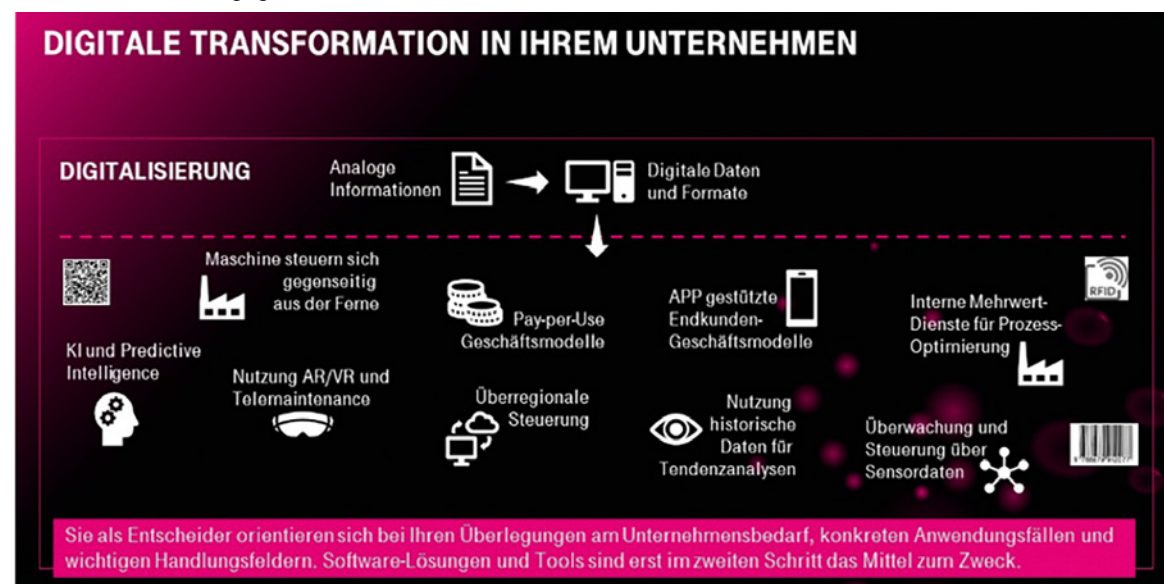


Abbildung 1: Regel-basierte, statistische Verfahren im Vergleich mit Anomalie-KPIs.

- Veränderungen automatisch verstehen: Die Algorithmen lernen, ohne dass ein Mensch (Data Scientist) sie anpassen muss, wenn sich Bedingungen ändern.
- Skalierbarkeit: Mit seiner selbstlernenden Algorithmen passt sich der kognitive RPA-BOT auch dann an, wenn eine Lösung um Instanzen ergänzt wird (beispielsweise, wenn weitere Baureihen oder Produktionsmaschinen in ein System kommen).
- Automatisierung des Data Scientists: Die – kreative – Arbeit des Data Scientists wird zum Teil von den kognitiven RPA-BOTs ersetzt. So lassen sich mehr Lösungen in weniger Zeit realisieren.

### Ergebnisse der Anwendungen

Ein großes, internationales Logistikunternehmen transportiert die Güter seiner Kunden mit gut 4.000 Lokomotiven in ganz Europa. Hier helfen künstliche Intelligenz-Analysen, Motorschäden zu vermeiden. Denn: Bleibt beispielsweise ein Frachtzug wegen eines Defekts liegen, drohen hohe Verluste im Geschäft mit Transportgütern. Für die Analyse der Maschinendaten zapft IS Predict bis zu 900 Datenpunkte der Lokomotiven an. Davon haben die RPA-BOTs acht Parameter identifiziert, die ein charakteristisches, wenn auch dynamisches, Muster entwickeln, wenn sich Störungen am Motor ankündigen. Heute ist das Logistikunternehmen in der Lage, Ausfälle bis zu drei Wochen im Voraus zu erkennen und betroffene Lokomotiven immer rechtzeitig zu warten. Einfache Probleme, die bei Eintritt einen kompletten Motortausch nach sich gezogen hätten, lassen sich proaktiv abstellen: Pro Motorwechsel entstehen sonst Kosten in Höhe von rund 200.000 Euro;

dank selbstlernender Künstlicher Intelligenz reduzieren sich die Kosten um 90 % auf 20.000 Euro.

Gemeinsam mit T-Systems hat IS Predict das Verfahren in der Automobilproduktion zum Einsatz gebracht, um die Wartung von Schweißrobotern zu optimieren. Fällt ein Roboter ungeplant aus, steht die komplette Fertigungslinie still. Jede Minute Stillstand kostet die Automobilindustrie bis zu 22.000 US-Dollar, zeigt eine Umfrage der Marktforscher von Nielsen. Dank RPA-BOTs ist das Automobilunternehmen jetzt in der Lage, nicht nur ausfallende Schweißroboter bis zu 6 Tage im Voraus zu identifizieren, sondern auch die Ursachen für den Defekt zu erkennen. Reparaturen an den Schweißrobotern plant das Automobilunternehmen mit Vorlauf so ein, dass die Produktion stets ungehindert weiterläuft.

### „Next Generation Maintenance“

Die von T-Systems entwickelte Lösung „Next Generation Maintenance“ geht noch über die reine Prädiktion von Maschinenausfällen hinaus. So fungiert das System als integrierte 360-Grad-Businesslösung, die Maschinendaten aus der Wartung in das Engineering zurückkoppelt, wie Abbildung 2 zeigt. Das heißt: Die bei der Wartung festgestellten Schwachstellen von Produktionsanlagen lassen sich im Designprozess nutzen. Eine Analyse der Wartungshistorie liefert so auch wichtige Rückschlüsse für die Produktentwicklung. Mit den gewonnenen Erkenntnissen ist es möglich, sowohl die Qualität der Erzeugnisse zu optimieren, als auch die Lebensdauer einer Produktionsanlage zu verlängern. Effekte, die unmittelbar dazu beitragen, die TCO-Kosten zu senken.

## CLOSING THE LOOP VON DER INSTANDHALTUNG ZUM VERBESSERTEN PRODUKT

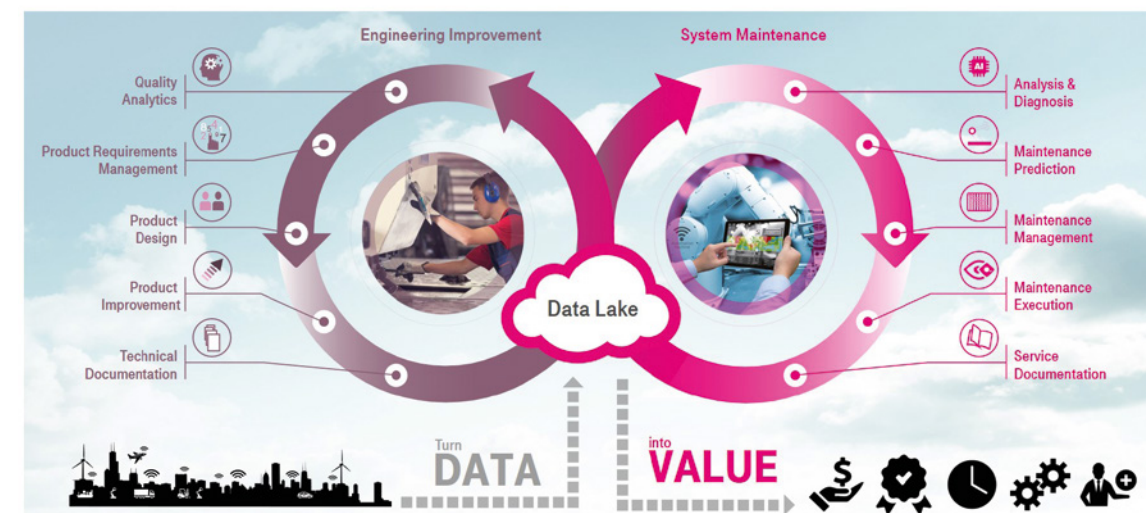


Abbildung 2: Next Generation Maintenance koppelt den Wartungszyklus (System Maintenance Cycle) mit dem Engineeringzyklus (System Improvement Cycle): So lassen sich Maschinenausfälle Tage im Voraus erkennen und Wartungsdaten nutzen, um das Produktdesign nachhaltig zu verbessern.

### Ausblick & Fazit

Die vorausschauende Wartung ist für Hersteller und Betreiber von Anlagen eine Industrie- 4.0-Schlüsseltechnologie. Laut Studie „Industrie 4.0“ von PricewaterhouseCoopers (PwC) und Strategy werden Industrieunternehmen in den nächsten fünf Jahren durchschnittliche 3,3 Prozent ihres Jahresumsatzes in Industrie-4.0-Lösungen investieren. Das entspricht etwa 50 Prozent der geplanten neuen Ausrüstungsinvestitionen und – bezogen auf die gesamte deutsche Industrie – einer Investitionssumme von rund 40 Milliarden Euro [5]. „Predictive Maintenance“ sticht dabei als das Industrie 4.0-Konzept mit dem größten Wachstumspotential heraus: Setzen aktuell nur 28 Prozent der Industrieunternehmen Predictive Maintenance-Lösungen ein, sollen es innerhalb der nächsten fünf Jahren 66 Prozent werden, sagt PwC [6].

Fabriken müssen ihre Maschinen verfügbar halten, um jederzeit eine reibungslose Fertigung zu gewährleisten. Der Wartung von Produktionsanlagen kommt daher große Bedeutung zu. Mit maschinellen Lernverfahren lassen sich Ausfälle an Produktionssystemen jetzt erstmals vorausberechnen: Ursachen lassen sich mehrere Tage vorher erkennen. Statt sich von einem Ausfall überraschen zu lassen, planen die Fabriken Wartungsarbeiten ein – und zwar immer genau dann, wenn sie nötig sind und immer genau so, dass die Produktion ungestört weiterlaufen kann.

Britta Hilt, Georg Rätker, Karlheinz Blank

[1] Bundesministerium für Wirtschaft und Energie (BMWi): Volks- und betriebswirtschaftliche Faktoren für den Standort Deutschland – Eine Studie im Rahmen der Begleitforschung zum Technologieprogramm AUTONOMIK für Industrie 4.0. Berlin, 2015. S. 7f. [2] Helen, Jiang: Key Findings on Airplane Economic Life. [http://www.boeing.com/assets/pdf/commercial/aircraft\\_economic\\_life\\_whitepaper.pdf](http://www.boeing.com/assets/pdf/commercial/aircraft_economic_life_whitepaper.pdf). 09.10.2017 [3] Biedermann, Hubert: Wertschöpfendes Instandhaltungs- und Produktionsmanagement. Erfolgreich durch Innovationen in Management und Technologie; 21. Instandhaltungsforum, TÜV Media. Köln, 2007. S. 19ff. [4] Beutnagel, Werner: Big Data erobert den Mittelstand. <http://www.automotiveit.eu/big-data-erobertden-mittelstand/management/id-0051062>. 09.10.2017 [5] PricewaterhouseCoopers und Strategy&: Industrie 4.0. Chancen und Herausforderungen der vierten industriellen Revolution. München, 2014. S. 12. [6] PricewaterhouseCoopers: Digital Factories 2020. Shaping the Future of Manufacturing. München, 2017. S. 26 [7] PricewaterhouseCoopers: Digital Factories 2020. Shaping the Future of Manufacturing. München, 2017. S. 26

## Machine Learning & Healthcare: Wie Algorithmen Krankenkassenbeiträge fairer gestalten können

Machine Learning Algorithmen (zu deutsch: Algorithmen für maschinelles Lernen) helfen Organisationen, große Datenmengen zu analysieren, um die Entscheidungsfindung bei den Krankenkassenbeiträgen zu verbessern. Diese Tools werden in Krankenhäusern zunehmend dazu verwendet, Behandlungsentscheidungen zu treffen und die Effizienz zu verbessern. Die Algorithmen „lernen“, indem sie Muster in über viele Jahre gesammelten Daten identifizieren.

Was passiert also, wenn die analysierten Daten

die historische Tendenz gegenüber gefährdeten Bevölkerungsgruppen widerspiegeln? Experten arbeiten daran, in allen Bereichen des Gesundheitssystems Gerechtigkeit sicherzustellen, einschließlich der Datenanalyse. Sie arbeiten seit mehreren Jahrzehnten an der Prüfung und Entwicklung von Lösungen für gesundheitliche Ungleichheiten.

### Die Idee hinter den Algorithmen

Gesundheitssysteme stehen weltweit vor vielfältigen Herausforderungen: zunehmende Krankheitslast, Multimorbidität und Behinderung, die auf Alterung und epidemiologischen Wandel zurückzuführen sind, höhere Nachfrage nach Gesundheitsdienstleistungen, höhere gesellschaftliche Erwartungen und steigende Gesundheitsausgaben, so die Experten vom Online-Gesundheitsmagazin Medmeister.

Eine weitere Herausforderung betrifft die Ineffizienz mit schlechter Produktivität. Diese Herausforderungen des Gesundheitssystems bestehen vor dem Hintergrund des fiskalischen Konservatismus und einer fehlgeleiteten Sparpolitik, die die Investitionen in die Gesundheitssysteme einschränkt. Eine grundlegende Umgestaltung der Gesundheitssysteme ist von entscheidender Bedeutung, um diese Herausforderungen zu bewältigen und eine umfassende Gesundheitsversorgung für die Zukunft zu erreichen.

Machine Learning, die greifbarste Manifestation künstlicher Intelligenz - und das neueste Wachstumsfeld der digitalen Technologie - verspricht mit weniger mehr zu erreichen und könnte der Katalysator für eine solche Umwandlung sein.

### Vorteile für den Gesundheitssektor

Die ständig wachsende Weltbevölkerung hat den Gesundheitssektor enorm unter Druck gesetzt, qualitativ hochwertige Behandlungs- und Gesundheitsleistungen anzubieten. Mehr denn je verlangen die Menschen nach intelligenten Gesundheitsdienstleistungen und Anwendungen, die ihnen helfen, ein besseres Leben zu führen und ihre Lebensdauer zu verlängern. Dieses Bedürfnis nach einem „besseren“ Gesundheitsdienst schafft immer mehr Möglichkeiten für Anwendungen der künstlichen Intelligenz und des maschinellen Lernens, um in die Gesundheits- und Pharmawelt einzusteigen. Da es im Gesundheitswesen keinen Datenmangel gibt, ist die Zeit reif, um das Potenzial dieser Daten mit KI- und ML-Anwendungen zu nutzen.

### Wie verbreitet sind diese Algorithmen heute im Gesundheitswesen?

Dies variiert je nach Einstellung, sie werden jedoch zunehmend für die klinische Behandlung verwendet, beispielsweise das Lesen von Röntgenstrahlen und Bildern zur Diagnose von Erkrankungen wie Augenerkrankungen oder Hautkrebs. Sie werden auch aus



betriebswirtschaftlicher Sicht zur Analyse von Krankenakten und Versicherungsansprüchen verwendet, um die Effizienz der Organisation zu steigern und die Kosten zu senken.

An der University of Chicago Medicine gibt es eine Datenanalyse-Gruppe. Sie erstellen Algorithmen zur Analyse von Daten in elektronischen Patientenakten. Eines der Projekte, an denen sie arbeiten, besteht darin, die Aufenthaltsdauer für Patienten zu verkürzen, da es im besten Interesse ist, dass Patienten nach Hause gehen, sobald sie bereit sind. Der Gedanke war: Wenn Patienten identifiziert werden können, bei denen die Wahrscheinlichkeit einer frühzeitigen Entlassung besteht, kann ein Fallmanager beauftragt werden, um sicherzustellen, dass keine weiteren Blockaden oder Barrieren vorhanden sind, die das rechtzeitige Verlassen des Krankenhauses verhindern könnten.

#### Probleme bei der Verwendung

Die Datenanalysegruppe entwickelte zunächst die Algorithmen auf der Grundlage klinischer Daten und stellte dann fest, dass das Hinzufügen der Postleitzahl, in der der Patient lebt, die Genauigkeit des Modells verbessert und die Personen mit kürzeren Aufenthaltszeiten identifiziert. Das Problem war jedoch, dass wenn man eine Postleitzahl hinzufügen würde, wenn der Patient in einem armen Viertel wohnt, erhält man eher die längere Aufenthaltsdauer.

Der Algorithmus hätte also zu dem paradoxen Ergebnis geführt, dass das Krankenhaus zusätzliche Fallmanagementressourcen einer bereits wohlhabenden Bevölkerung zur Verfügung stellt, um sie früher aus dem Krankenhaus zu bringen, anstatt einer sozial stärker gefährdeten Bevölkerung, die diejenigen sein sollten, die mehr Hilfe erhalten. Mittlerweile arbeiten Datenanalyse-Teams nun daran sicherzustellen, dass diese Gerechtigkeitsprobleme explizit berücksichtigt werden, wenn Algorithmen entwickelt werden, und erforschen, wie sie das maschinelle Lernen proaktiv eingesetzt werden kann, um Gerechtigkeit zu verbessern.

#### Wie wird verhindert, dass diese unfairen Ergebnisse auftreten?

Der erste Schritt wäre zu untersuchen, wie die Modelle tatsächlich entwickelt werden. Hier gibt es technische Möglichkeiten, die Algorithmen so zu gestalten, dass sie bestimmte Prinzipien der ethischen Gerechtigkeit fördern. Man kann Algorithmen erstellen, die gleiche Ergebnisse für zwei Bevölkerungsgruppen gewährleisten, und so sicherstellen, dass die technische Leistung des Modells angemessen ist. Wenn es also ein Problem gibt, bei dem Algorithmen für die Diagnose von bestimmten Personengruppen unter bestimmten Umständen diagnostiziert werden, können die Parameter der Formeln geändert werden,

um sie genauer zu machen.

Eine andere Möglichkeit zur Förderung der Gerechtigkeit besteht darin, Formeln so anzupassen, dass eine gleichmäßige Verteilung der Ressourcen gewährleistet ist. Das vorige Beispiel für die Zuweisung von Fallmanagern, damit die Menschen früher aus dem Krankenhaus nach Hause gehen können, ist ein gutes Beispiel. Sie können die Schwellenwerte für die Qualifizierung dieser Formeln ändern, um die Zuordnung der tatsächlichen Ressourcen zu verschiedenen Gruppen auszugleichen.

#### Wie lässt sich der Erfolg der Algorithmen überprüfen?

Trotz der Entwicklung einer guten Formel, muss man dennoch überwachen, was im wirklichen Leben passiert. Dazu gehört das Überwachen der Daten auf Ungleichheiten sowie das Gespräch mit den Leistungserbringern, den Patienten und den Administratoren, um festzustellen, ob sie Fairnessprobleme sehen.

#### Der genaue Ablauf bei Verwendung des maschinellen Lernens

Ein wirksames Management von Gesundheitssystemen, wie die Bereitstellung von öffentlicher Gesundheitsfürsorge, ist im Wesentlichen ein Netzwerk von Informationsverarbeitungsaufgaben. Die politischen Entscheidungsträger ändern die Gesundheitssystemfunktionen von Organisation, Finanzierung und Ressourcenmanagement, um die Ergebnisse des Gesundheitssystems (Gesundheitsdienste und öffentliche Gesundheit) und die Systemziele zu erreichen.

Die Gesundheitsfürsorge selbst umfasst zwei Hauptaufgaben der Informationsverarbeitung: Erstens das Screening und die Diagnose, d. h. die Klassifizierung von Fällen anhand von Anamnese und Untersuchungen und die zweite Behandlung und Überwachung, die die Planung, Implementierung und Überwachung eines mehrstufigen Verfahrens umfasst, um ein zukünftiges Ergebnis zu liefern.

Die wesentliche Form dieser Prozesse in allen Bereichen des Gesundheitssystemmanagements und der Versorgung umfasst die Generierung von Hypothesen, das Testen von Hypothesen und das Handeln. Maschinelles Lernen hat das Potenzial, Hypothesengenerierungs- und Hypothesentestaufgaben innerhalb eines Gesundheitssystems zu verbessern, indem zuvor verborgene Trends in Daten aufgedeckt werden, und hat daher das Potenzial, sowohl auf der Ebene des einzelnen Patienten als auch auf Systemebene erhebliche Auswirkungen zu haben.

#### Fazit

Maschinelles Lernen erweitert bestehende statistische Techniken, indem es Methoden verwendet, die nicht auf vorherige Annahmen über die Verteilung der Daten basieren, und kann Muster in den Daten finden,

die wiederum zur Formulierung von Hypothesen und Hypothesentests verwendet werden können. Während maschinelle Lernmodelle schwieriger zu interpretieren sind, können sie jedoch viel mehr Variablen enthalten und sind für eine viel breitere Palette von Datentypen verallgemeinerbar und können in komplexeren Situationen zudem zu Ergebnissen führen.

Diese Methoden wurden im Forschungskontext für das Screening und die Diagnose und Vorhersage zukünftiger Ereignisse eingesetzt. Diese Einsätze finden in unterschiedlichen Bereichen statt, in der Regel im Krankenhaus und nicht in der Gemeinde. In den allermeisten Fällen basieren die Daten auf Daten einzelner Zentren, was sich auf die Reproduzierbarkeit und die Generalisierbarkeit auswirkt. Das rasante Tempo der Entwicklung des maschinellen Lernens setzt sich jedoch sowohl im Gesundheitswesen als auch bei allen Aufgaben der Informationsverarbeitung in der Gesellschaft fort.

Alexander Eser

## Herausforderungen für Machine Learning in der Abschlussprüfung

Voraussetzungen und Chancen von Künstlicher Intelligenz in der Abschlussprüfung und über die zukünftige Rolle des Menschen und der Maschine in der Abschlussprüfung.

Kaum ein Bereich wird so stark mit Zahlen und Mathematik in Verbindung gebracht wie die Abschlussprüfung. Darum liegt der Schluss nahe, dass sich dieser Bereich wie kaum ein anderer dafür eignet, von intelligenten Algorithmen und Machine-Learning-Methoden transformiert zu werden. Ein genauere Blick zeigt aber, dass der Arbeitsalltag von Wirtschaftsprüfern nur wenig mit dem eines rechnenden Wissenschaftlers zu tun hat. Sehr viel mehr sind bei der Abschlussprüfung menschliche Urteilskraft und Fragen des Ermessens gefragt. Dennoch stellt sich angesichts der Erfolge von Machine Learning die Frage, inwiefern auch Aufgaben im Rahmen der Abschlussprüfung transformiert, ersetzt oder erweitert werden.

#### Das Potential von Machine Learning in der Abschlussprüfung

Machine Learning ist eine Kategorie innerhalb des großen Themenkomplexes der Künstlichen Intelligenz. Aber auch Machine Learning ist nicht immer gleich Machine Learning. Beispielsweise lassen sich die grundlegend verschiedenen Methoden von Supervised-Machine-Learning und Unsupervised-Machine-Learning unterscheiden. Die im Moment am weitesten verbreitete Methode ist das Supervised Learning, bei dem ein intelligenter Algorithmus während einer Lern- bzw. Trainingsphase ein Feedback

bekommt, ob das errechnete Ergebnis richtig oder falsch war. Das wirft die Frage auf, was im Bereich Abschlussprüfung ein richtiges oder falsches Ergebnis sein könnte. Ein vergleichbar eindeutiges Erfolgskriterium wie „richtig“ oder „falsch“ gibt es im Bereich der Prüfung aber nur in den wenigsten Fällen.

#### Herausforderungen bei der Abschlussprüfung

In der Bilanzierung gibt es zwar klare Regelungen wie beispielsweise die internationalen Bilanzierungsstandards IFRS. Diese erlauben aber Ermessen durch den Anwender und sind darum auslegungsbedürftig. Die IFRS enthalten neben einigen wenigen Bilanzierungsvorschriften ansonsten ganz bewusst nur Rechnungslegungsprinzipien. Es werden bewusst nicht alle möglichen Sachverhaltsvarianten geregelt, sondern der Einzelfall ist anhand der Prinzipien abzuleiten. Ansonsten müssten immer detailliertere Regelungen geschaffen werden, um alle Bilanzierungssachverhalte abzubilden („standard overload“).

Seit 2018 sind beispielsweise die neuen Regelungen zur Umsatzrealisierung (IFRS 15) anzuwenden. Betrachtet man nun die monatliche Grundgebühr eines Energieversorgers, so geht aus dem Standard nicht klar hervor, ob diese als Preiskomponente für den gelieferten Strom zu sehen ist und entsprechend auf die gelieferten kWh umzulegen ist oder als Vergütung für die ständige Bereitschaft Strom an den Kunden auf dessen Wunsch zu liefern, die monatlich in gleicher Höhe als Umsatz zu erfassen ist. Letztere Meinung hat sich derzeit im Schrifttum durchgesetzt.

Die sachgemäße Interpretation der Rechnungslegungsvorschriften liegt somit in der Verantwortung des Bilanzierenden und des würdigenden Abschlussprüfers. Zu einer endgültigen und rechtsverbindlichen Entscheidung über die Angemessenheit dieser Interpretation kommt es jedoch nur in den seltensten Fällen und dann auch nur bezogen auf den spezifischen Sachverhalt. Darüber hinaus kann sich Ermessen und Auslegung über den Zeitverlauf verändern, ohne dass es zu einer erkennbaren Regeländerung für die KI kommt. Für die Frage nach der Anwendbarkeit von Machine Learning in der Abschlussprüfung bedeutet dies, dass sich der Regelkatalog immer wieder verändern kann und die Algorithmen immer wieder neu angelernt werden müssten.

#### Die Digitalisierung von Experten-Know-how

Die Verantwortung für das finale Urteil wird also in Zukunft ebenso wie heute bei der Wirtschaftsprüfungsgesellschaft und beim einzelnen Prüfer liegen. Der Abschlussprüfer unterzeichnet den Bestätigungsvermerk mit seinem Namen und steht damit persönlich für das eigene Urteil ein. Vertrauen in einem so hochsensiblen Bereich lässt sich nicht digitalisieren. Das bedeutet aber nicht, dass sich der Wirtschaftsprüfer nicht die Technologie zunutze



Alexander Eser,  
Co-Founder &  
Managing Director,  
Kaufberater.io

machen sollte. Das Wissen und die Erfahrung von Wirtschaftsprüfern lässt sich nämlich schon digitalisieren, nur eben nicht die Verantwortung dieses auf den Bilanzierungssachverhalt anzuwenden. Der Erfolg von Machine Learning im Bereich Abschlussprüfung hängt damit davon ab, wie diese Know-how auf Standardprobleme anwenden kann und wie Wirtschaftsprüfer lernen mit KI und den immanenten Grenzen zusammenzuarbeiten.

### Machine Learning befähigt Maschinen, aus Erfahrung zu lernen

Alle großen Prüfungsgesellschaften haben beispielsweise Fachabteilungen, die Fachwissen bereitstellen und bei denen sich Prüfungsteams bei komplexen Fragestellungen rückversichern können. Durch Machine Learning haben wir nun eine Technologie, bei der Maschinen aus Erfahrung lernen können. Eine Digitalisierung von Wissen in diesem Bereich kann entsprechend als Lernprozess in mehreren Stufen erfolgen. Zunächst unterstützt eine auf Machine Learning basierende KI eine Person in der Fachabteilung, indem sie beispielsweise automatisch der Anfrage entsprechende Literaturstellen und vergleichbare Anwendungsfälle recherchiert. Die Mitarbeiter können der KI das Feedback geben, ob die Recherche richtig war oder ob es weitere relevante Stellen gibt.

In einem zweiten Schritt könnte eine KI bereits konkrete Lösungen vorschlagen, die in der Fachabteilung verifiziert werden, bevor diese an das Prüfungsteam weitergegeben werden. In einem dritten Schritt agiert die KI dann direkt mit den Prüfungsteams. Die Fachabteilung übernimmt nun mehr die Aufgabe, die KI wie dargestellt auf dem neuesten Stand zu halten. Nur bei Fragen, die noch in Diskussion sind oder wo die KI nicht sicher ist, wird der Fall an einen Menschen weitergeleitet. Hier hört die KI dann wieder mit und lernt weiter. Andere Anwendungsbeispiele, die nach einem vergleichbaren Muster verlaufen, sind bei der Auswertung von Verträgen denkbar. Schon heute können Verträge maschinell ausgewertet werden und einfache Bilanzierungsentscheidungen werden den Beratern von KPMG von einer KI wie IBMs Watson vorgeschlagen.

### Maschinen werden zu Artificial Co-Workern

In der konkreten Anwendung bedeutet das, dass sich Wirtschaftsprüfer in Zukunft Artificial Co-Workern als Unterstützung holen können. Über intelligente Chatbots lässt sich Machine Learning in den Prüfalltag einbinden. Neben den menschlichen Kollegen tauchen bei Skype oder Slack die Artificial Co-Worker auf, denen schriftlich oder auch mündlich Fragen gestellt werden können. Sind diese einmal trainiert, könnten diese automatisch Gesetzesstellen, Kommentarmeinungen, Fachartikel oder passende Referenzfälle recherchieren und vorschlagen. Auf

diese Weise nutzt Machine Learning dem Menschen, um Entscheidungsprozesse zu beschleunigen und zu erleichtern sowie dazu, die Entscheidungsqualität zu erhöhen. Auch hier ist die Rolle des Menschen aber nicht einfach ersetzbar. Vielmehr ist er dafür zuständig, das richtige Tool auszuwählen und die richtige Frage an die Maschine zu stellen.

Bereits diese Unterstützung des Menschen würde zu einer deutlichen Qualitätsverbesserung führen, da das Wissen skalierbar und ohne Grenzkosten verfügbar wäre und die Wahrscheinlichkeit erhöht wird, dass relevante Sachverhalte erkannt werden. Zudem kann so gewährleistet werden, dass das gesamte fachliche Wissen einer Prüfungsgesellschaft jedem Mitarbeiter zu jeder Zeit leicht zugänglich ist. Gleichzeitig entstehen aber auch neue Cyber-Risiken, wie beispielsweise der mögliche Verlust von geschütztem Wissen durch Cyber-Angriffe oder Reputationsrisiken durch ungewollte Veröffentlichungen von Insider-Wissen.

### Status-quo: Machine Learning in der Abschlussprüfung heute

Machine Learning ist längst in der Abschlussprüfung angekommen. Tools, die beispielsweise selbstlernend Verträge auswerten wie IBMs Watson oder der intelligente Chatbot CLARA werden bereits aktiv genutzt. Allerdings gibt es bislang noch keine bekannten Tools, die Machine Learning in dem hier ausgeführten Umfang einsetzen. Der nächste, notwendige Schritt für Wirtschaftsprüfungsgesellschaften muss darum die Digitalisierung ihres Know-hows sein. Dies ist die Grundvoraussetzung, um die Anschlussfähigkeit für Machine Learning her- und sicherzustellen. Insbesondere angesichts des War for Talents sind Maßnahmen wie diese ein zunehmend wichtiger Erfolgsfaktor.

### Und wenn es doch anders kommt...

Der beschriebene „standard overload“, in dem jeder Einzelsachverhalt abschließend geregelt wird, führt für den Menschen zu einer unübersichtlich und letzten Endes nicht mehr nachvollziehbaren Vorgabe. Für eine Maschine wäre diese Situation aber beherrschbar. Warum also nicht vollständig auf die Maschine umstellen? Diese Entwicklung würde einer echten kulturellen Revolution in der Rechnungslegung und dann auch der Abschlussprüfung gleichkommen. Die im Abschluss anzuwendenden Standards würden in Zukunft nicht mehr von Menschen aufgestellt, sondern zwischen intelligenten Maschinen vereinbart. Eine bilanzierende KI hätte kein Problem, anhand von bestimmten Kriterien die jeweils richtige Vorgabe zu identifizieren und auf den jeweiligen Sachverhalt anzuwenden. Wenn es einen neuen Fall gibt, könnte eine standardsetzende KI diesen in Sekundenbruchteilen entscheiden und wieder

einheitlich vorgeben. In dieser Welt gäbe es keine Ermessensspielräume mehr und alle Abschlüsse wären vollständig miteinander vergleichbar.

Aus heutiger Sicht erscheint eine solche vollständige Übertragung auf die Maschine unvorstellbar. Vor allem müsste eine Umstellung zeitgleich für alle bilanzierenden Unternehmen erfolgen. Ob es hierzu jemals kommen wird ist unklar. Solange sollte Machine Learning in der Abschlussprüfung aber genutzt werden um die Qualität zu erhöhen, indem diese insbesondere bei aufwendigen Analysen und Recherchen unterstützt und einfache Tätigkeiten übernimmt.

Matthias Koeplin

## (K)IQ-Test für Banken: Technologie für Kundenbindung

In der Regel gelten Banken und Finanzdienstleister oft als traditionelle Einrichtungen, die sich primär mit den Investitionen ihrer Kunden beschäftigen. Doch gerade im Trendthema Künstliche Intelligenz (KI) sehen Finanzinstitute eine große Chance und sind teilweise Vorreiter: Das Marktforschungsinstitut IDC schätzt die Ausgaben des Finanzsektors im Bereich KI auf rund drei Milliarden Dollar – im Jahr 2018 allein. Die möglichen Anwendungsbereiche sind in einer derart datengetriebenen Branche vielfältig: automatisierte Sicherheitsmaßnahmen, die selbstständig verdächtige Transaktionen und Betrugsversuche erkennen, personalisierter Echtzeit-Kundenservice und sogar Anlagenhandel auf Basis von Algorithmen.

Gerade für etablierte Banken sind KI-Lösungen die Chance, auf die agilen und individuellen Geschäftsmodelle der zahlreichen Fintechs zu reagieren. Denn die gehobene Erwartungshaltung des digitalen Kunden schließt auch ihre Branche ein. Und genau wie im Einzelhandel gilt es, mit neuer Technologie die Erwartungen der Kunden besser zu verstehen und zu erfüllen – und im Idealfall vorherzusehen.

### Datenbasierte Geschäftsmodelle

Finanzinstitute sind in fast jeden Bezahl-Bereich des täglichen Lebens eingebunden und können aus den entstehenden Transaktionsdaten eine Vielzahl von Rückschlüssen auf das Verhalten ihrer Kunden ziehen: Wo geben sie ihr Geld aus? In welchem Lebensabschnitt befinden sie sich? Welche Services oder Zahlungsmittel des Portfolios nutzen sie und wie häufig? Zusammen mit Informationen aus der Kundenberatung oder sozialen Plattformen ergibt sich ein sehr aufschlussreiches Kundenbild. Allerdings kann es Instituten schwerfallen, dieses Bild aus den vielen einzelnen Konto- und Serviceinformationen zusammenzusetzen. Vor allem, wenn diese Daten über mehrere Abteilungen und deren Daten-

silos verteilt sind. Deshalb ist es wichtig, dass sie mit einem effizienten und übergreifenden Datenmanagement die Voraussetzungen für einen effektiven Einsatz von KI schaffen. Beispielsweise machen es Datenplattformen mit Single Customer View (SCV) einfacher, die Daten einzelner Kunden gezielt und sicher aus großen Datensätzen herauszufiltern. Bei der Planung der eigenen IT-Infrastruktur sollte für Banken die Verfügbarkeit ihrer Daten immer höchste Priorität haben.

Dann kann künstliche Intelligenz schon im ersten Analyseschritt enorm weiterhelfen. Sie ist prädestiniert dafür, aus einer großen Menge unstrukturierter Daten Muster abzuleiten und darauf basierende Handlungsempfehlungen zu geben. Selbstlernende Algorithmen „wissen“ dann anhand der Kundendaten, welche Angebote den Nutzer gerade vermutlich am meisten interessieren. Ein Sparbuch bei Nachwuchs, Baufinanzierung für den Hausbau oder ein Kredit für ein neues Auto sind nur einige Beispiele. Mit KI können Banken ihren Daten eine menschliche Dimension verleihen und persönlicher auf ihre Kunden eingehen. Nur dann sind das Ergebnis personalisierte Angebote und Services für den Kunden und eine höhere Zufriedenheit und Kundenbindung auf Unternehmensseite. Ersetzen kann KI die menschlichen Berater zwar noch lange nicht, aber sie gibt deren Beratung ein Datenfundament für passgenaue und proaktive Geschäftsmodelle.

### Nutzer erwarten „Always on“

Mit omnipräsenten Smartphones und Webapplikationen schrumpft außerdem die Distanz zwischen Kunde und Finanzdienstleister. Öffnungszeiten, Landesgrenzen und selbst Servicegebühren durch reine Online Banken scheinen größtenteils Vergangenheit. Stattdessen erwarten Nutzer im Austausch für ihre Daten sofortiges, persönliches Feedback rund um die Uhr, denn auch sie wissen, dass ihre Daten etwas wert sind. Anbieter, die den Erwartungen der „Always on“-Mentalität nicht gerecht werden, tun sich schwer am Markt. Es gilt also, die internen Reaktionszeiten zu verkürzen und Support- und Serviceprozesse möglichst effizient zu gestalten. KI bietet hier mehrere Ansatzpunkte: Viele moderne Webpräsenzen greifen bereits auf automatisierte Chatbots als erste Anlaufstelle zurück. Unabhängig von den menschlichen Kundenbetreuern können diese KI-Bots Anfragen aufnehmen, filtern und dafür sorgen, dass der Ratsuchende mit dem richtigen Ansprechpartner verbunden wird. Dank fortschrittlicher Sprachtechnologie kann KI auch in Callcentern bereits ähnliche Screening-Aufgaben übernehmen. So zeigt beispielsweise Google, dass die Tage passiver Bandansagen dank KI gezählt sind. Denn mit der Duplex-Technologie können intelligente Bots das Gespräch innerhalb ihrer Kapazitäten unabhängig



Matthias Koeplin,  
Partner,  
KPMG AG  
Wirtschaftsprüfungsgesellschaft

führen und entweder Routineabfragen wie Kontostände selbst beantworten oder im Falle komplexerer Anfragen an zuständige Mitarbeiter durchstellen. Capital One dagegen hat bereits den Amazon-Sprachassistenten Alexa für solche Anfragen eingespannt.

Auch für Applikationen und Website-Präsenzen ist Benutzerfreundlichkeit oberstes Gebot. Gerade Suchfunktionalitäten lassen sich mit KI intuitiver und individueller gestalten. Die Macquarie Bank verwendet in ihrer App eine Kontextsuche, die auch Anfragen wie „Wieviel habe ich für das Golfen ausgegeben?“ versteht und innerhalb der eigenen Transaktionen die relevanten Umsätze identifizieren kann. Ganze Sätze im Suchfeld, Sprachsteuerung – diese kleinen Schritte sind wertvoll für eine eingängige Bedienung und die damit einhergehende Zufriedenheit der Kunden mit den Apps und Services.

#### Sicherer dank Daten

Banken und Finanzdienstleister müssen sich aber vor der Implementierung vergegenwärtigen, dass diese Lösungen nicht in einem Vakuum funktionieren: Datenmanagement ist der Erfolgsfaktor Nummer Eins in der Digitalisierung und komplexe KI-Lösungen sind von einem steten Strom von Informationen und Updates abhängig. Alles im Bereich Machine Learning, Analytics, Streaming oder Bots ist extrem „datenhungrig“. Gleichzeitig wächst auch das Volumen der produzierten und zu verarbeitenden Rohdaten weiter exponentiell an. Auch der Aufbau der IT wird komplexer: statt „on premises only“ greifen Banken und Fintechs gleichermaßen häufig auf die Services verschiedener Cloud-Dienstleister zurück, sei es für Backups, Storage oder zusätzliche Rechenpower. Die entstehenden Multi-Cloud-Ökosysteme sind eine zusätzliche Herausforderung für das eigene Datenmanagement. Mit zentralisierten Datenplattformen, wie beispielsweise DataStax Enterprise, können Unternehmen gewährleisten, dass ihre Daten immer rechtzeitig bereitgestellt werden und dabei auch die gängigen Sicherheits- und Compliance-Richtlinien erfüllen. Und umgekehrt erlauben KI-basierte Sicherheitsmaßnahmen es Banken, das eigene Sicherheitsniveau anzuheben: Automatisierte Betrugserkennung war einer der ersten Bereiche für KI im Finanzsektor. Und auch weiterhin entfällt ein Großteil der Ausgaben für KI in diesem Sektor auf die Erkennung, Prävention und Untersuchung möglicher krimineller Transaktionen.

#### Ausblick

KI wird sich bei Banken und Finanzdienstleistern aber auch in weiteren Anwendungsbereichen etablieren. Gezielter Einsatz von Automatisierung ist unumgänglich in einer derart weitreichenden Branche mit immer höheren Erwartungen der Kunden. Nach dem derzeitigen Stand der Technik ist KI hier allerdings

ein Helfer und kein Ersatz: Auch wenn die Software mögliche Betrugsversuche oder ein anderes verdächtiges Muster identifiziert, obliegt die schlussendliche Handlungsentscheidung doch immer noch einem menschlichen Mitarbeiter.

Mit weiterem technologischem Fortschritt im Bereich künstliche Intelligenz kann sich dieses Kräfteverhältnis natürlich in Zukunft verschieben. Deshalb ist es wichtig, dass Finanzinstitute frühzeitig für sie geeignete KI-Technologie identifizieren und in dem Bereich praktische Erfahrungen sammeln, um später diese Kompetenzen an ihre Teams weitergeben zu können. Denn mit neuer Technik allein ist es nicht getan. Für einen nachhaltigen Erfolg am digitalen Markt müssen sich KI-Lösungen und Datenmanagement auch in der Unternehmenskultur und den Köpfen sowie im Know-how der Mitarbeiter etablieren.

Xavier Guerin



Xavier Guerin,  
Vice President  
Western Europe,  
DataStax

## Wie China an allen vorbeizieht



Eigentlich sollte es nur unser 35-jähriges Abifest werden. Hände schütteln, sich wiedersehen, gemeinsam essen und hören, wie es dem einen oder anderen ergangen ist. Doch dann tauchte überraschend mein Jugendfreund auf, den das Schicksal nach China verschlagen hat. Er bot seinen alten Schulkameraden an, mit einer Präsentation aus seinem heutigen Leben zu berichten.

Er startete mit Fotos seiner chinesischen Familie und seines Alltags. Gemeinsam leben sie in Shanghai in einem schicken Reihenhaushaus - in einer „guarded area“ mit Sicherheitsdienst. Seine Frau trägt weiter ihren eigenen Vor- und Nachnamen, denn chinesische Frauen nehmen nicht den Namen ihres Mannes an. Und seine Kinder tragen deutsche Namen, sehen aber komplett asiatisch aus. Zusätzlich haben alle Familienmitglieder einen chinesischen Namen, der immer eine inhaltliche Bedeutung hat.

Er spricht über die großartige Vielfalt von sowohl Essensangebot als auch -bräuchen. Dass man in chinesischen Restaurants neben vielfältigsten Gemüsesorten auch Huhn, Rind, Schlange, Ratte und Hund verzehren kann. Reis wird nur nach dem Essen angeboten, falls man nicht satt geworden ist. Normal ist die No-Carb-Ernährung.

Er hat kein Bargeld mehr in der Tasche, sondern bezahlt alles mit dem Handy. Entweder über „Alibaba“ oder über „WeChat“, dem chinesischen Pendant zu Whatsapp. Danach stellt mein Freund sein Unternehmen vor, seine Arbeit und seine Mitarbeiter. Alle sehen jung und hochmotiviert aus. Wir sollen das Alter der Chinesen schätzen und liegen immer daneben. Asiaten haben jugendliche Gene.

Sein Unternehmen macht mit nur wenigen hundert Mitarbeitern mehrere 100 Millionen Umsatz im Maschinenbau. Ihre hochmoderne Fabrik steht in einer sehr ländlichen Gegend. Die Löhne der Führungskräfte wie auch seine Miete seien gleich hoch wie in Deutschland. Wir kommen aus dem Staunen nicht mehr heraus. Er räumt mit unseren Vorurteilen auf. Das Ausbildungslevel der Menschen sei extrem hoch, sie lernen viel mehr, länger und intensiver als wir.

Er erzählt, wie in Shanghai in nur acht Monaten eine Brücke gebaut wird. Wir benötigen für solche Projekte mehrere Jahre für Planung und Genehmigungen. Auch zeigt er uns die siebenstöckigen Autobahnkreuze, die entstehen, weil Shanghai einfach unfassbar schnell wächst. Mittlerweile leben dort 25 Millionen Menschen.

Immer wieder kommt die Rede auf die Sozialkontrolle der Bürger, die auch in deutschen Medien oft Thema ist. Er meint, dass sie absolut existiert und nach dem Testlauf in drei Regionen jetzt auf alle Städte und das ganze Land ausgedehnt wird. Jeder Bürger erhält 1000 Punkte als Basishöhe. Wenn er aufgrund unsozialen Verhaltens auf 500 Punkte sinkt, darf er keine Flüge und Bahntickets mehr buchen.

Jeder Bürger wird überall beobachtet, überwacht und ausgewertet. So werden z.B. dem Chinesen, der einem alten Mann über die Straße hilft, plötzlich Punkte gutgeschrieben. Diese Bürgerüberwachung wird nun auch auf die Unternehmen und die Mitarbeiter ausgeweitet. Gesicht und Mimik der Bürger werden so analysiert, dass man weiß, ob sie grimmig oder wütend sind. Wenn ja, wird reagiert.

In Schulen werden Kinder bei ihrem Lern- und Essensverhalten via künstlicher Intelligenz kontrolliert. Diese schlägt ihnen auch optimierte Verhaltensweisen vor.

China ist der Anwärter auf den Thron der führenden Weltmacht geworden, ohne dass es im Alltag des Westens jemand wirklich bemerkt hätte. Dazu beigetragen hat vor allem der neo-leninistische Ansatz und das gehobene Potenzial von KI. Die Schaffung des „perfekten Staats“, in dem der Mensch untergeordnet ist, ist mehr als auf dem Weg.

Moralisch und regulatorisch wird chinesisches Denken nicht durch die abendländische Kultur gebremst. Mein Schulfreund sagt, er denkt und agiert jetzt zunehmend wie ein Chinese. Es sei für ihn nicht mehr nachvollziehbar, wie bei uns gehandelt wird. Das sei so langsam und auf Prinzipien basierend, die die Chinesen in dem Maß gar nicht hätten. Sie würden viel pragmatischer, effizienter, egoistischer und langfristiger denken und handeln als wir.

Bleibt die Frage, was das für Deutschland bedeutet. Können wir noch zu China aufschließen? Und mit unserem Habitus schnellere Innovationszyklen und angstfreie Begegnungen mit KI initiieren? Können die Werte, die die führende wirtschaftliche Rolle Deutschlands einmal ausgemacht haben, noch Grundlage für die heute notwendige Agilität und Schnelligkeit sein?

Uwe Walter ist Storytelling- und Change-Experte für Medien- und Industrieunternehmen. Er berät so unterschiedliche Kunden wie YouTube-Stars, Start-ups, Blogger, Verlage, Radio- und Fernsehsender sowie Filmproduktionen. Seine Expertise: Wie generiere ich Reichweite durch zukunftsicheres Erzählen?

Beim PlanQK-Workshop im Sheraton Hotel im Arabellapark kamen über 80 Interessierte, um das Thema Quantengestützte Künstliche Intelligenz zu diskutieren.



Auch zwischen den Panels des PlanQK-Workshops und DigiTalks tauschten sich Experten der Wissenschaft mit Vertretern der Industrie aus.

Zu Beginn begrüßte Prof. Claudia Linnhoff-Popien (Vorstandsvorsitzende Digitale Stadt München e.V.) die neuen Mitglieder des Vereins und präsentierte die aktuellen Mitgliederzahlen.



Welchen Einfluss die Unternehmenskultur auf die Innovationsfähigkeit hat, erläuterte Stefan Rauch (iteratec GmbH) im zweiten Vortrag des Abends.



**MÜNCHEN**

**Digitale Stadt München e. V.**

**DigiTalk - PlanQK: Plattform und Ökosystem für Quantenunterstützte Künstliche Intelligenz**

Am Donnerstagabend, den 23. Mai 2019, versammelten sich 84 Gäste im Sheraton Arabellapark Hotel zum DigiTalk. Im Zusammenhang mit einem vorangegangenen Industrie-Workshop des BMWi-geförderten Projektes „PlanQK“ (<https://planqk.de/>) war das Thema des Abends die Schnittstelle zwischen Künstlicher Intelligenz (KI) und Quantencomputing (QC). Mit diversen Impulsvorträgen und einer anschließenden Podiumsdiskussion wurde erörtert, inwiefern die Kombination beider Technologien einen Nutzen für die Wirtschaft generiert.



Darf bei keinem DigiTalk fehlen: Für ein tolles Buffet war für die Gäste des PlanQK-DigiTalks gesorgt.



Prof. Dr. Dr. Frank Leymann, Universität Stuttgart, berichtete von QC-Lehre an seinem Lehrstuhl und dem BMWi-geförderten Projekt „PlanQK“, das unter anderem zusammen mit der LMU München durchgeführt wird.



Im ersten Vortrag zeigte Dr. Michael Gebhard (Vorstandsmitglied der neu gegründeten iteratec nordemteam eG) auf, welche Chancen aber auch Herausforderungen darin liegen, ein Inhaber-geführtes Unternehmen in eine Genossenschaft zu überführen.

Die vielen Fragen der Gäste wurden zum Teil noch bis spät in den Abend mit den Vortragenden diskutiert.



Der Abend fand sein kulinarisches Highlight in dem mühevoll bereiteten Grill-Buffet, das mit vielen Spezialitäten begeisterte ...

**MÜNCHEN**

**Digitale Stadt München e. V.**

**DigiTalk Iteratec**

Gemeinsam mit der iteratec GmbH veranstaltete die Digitale Stadt München am 04. Juli 2019 einen sommerlichen DigiTalk. Die spannende Agenda zog mehr als 60 Gäste in die neuen Räumlichkeiten der iteratec in der St. Martin-Straße.

... und das auch bei den Gästen sehr gut ankam!





# OPENMUNICH 2019

\*Christmas Edition

LMU Munich, Accenture and Red Hat are inviting you to the FOURTH conference on New IT within the Open Source ecosystem **all day** on the **13.12.2019**.

Throughout the day, you can expect:

- an exciting keynote,
- interesting presentations,
- technical workshops,
- exhibition booths with prizes to win & personal contacts

OpenMunich 2019 has **NO REGISTRATION FEE**

**13.12.2019**  
Save the Date

FIND MORE INFORMATION AT:  
**openmunich.eu**

## FACHBEIRAT



**Patric Fedlmeier**  
CIO Provinzial Rheinland



**Norbert Gaus**  
Executive VP SIEMENS



**Sandro Gaycken**  
Direktor ESMT



**Michaela Harlander**  
Vorstand Harlander-Stiftung



**Markus Heyn**  
GF BOSCH



**Martin Hofmann**  
CIO Volkswagen



**Manfred Klaus**  
Sprecher der GF Plan.Net



**Andrea Martin**  
CTO IBM



**Niko Mohr**  
Partner McKinsey



**Christian Plenge**  
BL Messe Düsseldorf



**Frank Rosenberger**  
Group Director TUI



**Ralf Schneider**  
CIO Allianz Group



**Stephan Schneider**  
Manager Vodafone



**Marc Schröder**  
GL MG RTL Deutschland



**Uwe Walter**  
Waltermedia



**Michael Zaddach**  
CIO Flughafen München

## DIGITALE WELT IM ABO

**DIGITALE WELT** im Abo: Die **DIGITALE WELT** kommt ganz bequem und portofrei nach Hause. Sichern Sie sich jetzt das Jahresabo für 78 €.

Haben Sie Interesse? Das eMagazin- oder Print-Abo gibt es unter [www.digitaleweltmagazin.de/abo](http://www.digitaleweltmagazin.de/abo) oder beim Abo-Service:  
Email: [abodigitalewelt@vogel.de](mailto:abodigitalewelt@vogel.de), Tel.: +49 931 4170-435

## IMPRESSUM

### VERLAG

Vogel Communications Group GmbH & Co. KG,  
Max-Planck-Str. 7/9, 97064 Würzburg, [www.vogel.de](http://www.vogel.de)

### Geschäftsführer

Matthias Bauer, Florian Fischer, Günter Schürger

### REDAKTION

**Chefredaktion** Claudia Linnhoff-Popien (V. i. S. d. P.)

**Chef vom Dienst** Robert Müller

**Fachbeirat** Patric Fedlmeier, Norbert Gaus, Sandro Gaycken, Michaela Harlander, Markus Heyn, Martin Hofmann, Manfred Klaus, Andrea Martin, Niko Mohr, Christian Plenge, Frank Rosenberger, Ralf Schneider, Stephan Schneider, Marc Schröder, Uwe Walter, Michael Zaddach

**Redaktion** Hannes Mittermaier, Florentina Hofbauer

**Blog** Steffen Illium, Tanja Zecca, Tamara Tomasevic

**Redaktionsassistentz** Katja Grenner

**Mitarbeiter dieser Ausgabe** Thomy Phan, Kyrill Schmid

**Schlussredaktion** Barbara Haber

### ANFRAGEN AN DIE REDAKTION

[redaktion@digitaleweltmagazin.de](mailto:redaktion@digitaleweltmagazin.de)

### GRAFIK

**Layout** Stefan Stockinger, [www.stefanstockinger.com](http://www.stefanstockinger.com)

### ANZEIGEN

**Ansprechpartner** Tanja Zecca, Tel. +49 89 2180-9171,  
E-Mail: [anzeigen@digitaleweltmagazin.de](mailto:anzeigen@digitaleweltmagazin.de)

Es gilt die gültige Preisliste, Informationen hierzu unter [www.digitaleweltmagazin.de/mediadaten](http://www.digitaleweltmagazin.de/mediadaten)

### HERSTELLUNG

ColorDruck Solutions GmbH,  
Gutenbergstraße 4, 69181 Leimen

### ABO-SERVICE

DataM-Services GmbH, Aboservice Digitale Welt,  
Franz-Horn-Str. 2, 97082 Würzburg,

Tel. +49 931 4170-435

E-Mail: [abodigitalewelt@vogel.de](mailto:abodigitalewelt@vogel.de)

Digitale Welt erscheint einmal pro Quartal

### ABONNEMENT-PREISE

Jahres-Abo inklusive Versandkosten: Inland 78,00 €, Ausland 87,60 €; ermäßigtes Abo für Schüler, Studenten, Auszubildende: Inland 39,00 €  
Der Bezug der Zeitschrift Digitale Welt ist im Mitglieds-Beitrag des Verbandes VOICE - Bundesverband der IT-Anwender e.V., Digitale Stadt München e.V. und Hannover IT e.V. enthalten.

### HERAUSGEBER

Prof. Dr. Claudia Linnhoff-Popien, Institut für Informatik, Ludwig-Maximilians-Universität München, Oettingenstr. 67, 80538 München,  
Tel. +49 89 2180-9153, [www.digitaleweltmagazin.de](http://www.digitaleweltmagazin.de)

### RECHTE

Dieses Magazin und alle in ihm enthaltenen Beiträge, Abbildungen, Entwürfe und Pläne sowie Darstellungen von Ideen sind urheberrechtlich geschützt. Mit Ausnahme der gesetzlich zugelassenen Fälle ist eine Verwertung einschließlich Nachdrucks ohne schriftliche Einwilligung des Herausgebers strafbar. Für unverlangt eingesandte Manuskripte und Bildmaterial übernehmen Redaktion und Verlag keine Haftung.

# CALL FOR CONTRIBUTION

für den DIGITALE-WELT-Blog



Die nächste DIGITALE WELT erscheint am 04.12.2019

Werden Sie Teil unserer hochkarätigen Autorenschaft und platzieren Sie Ihre Digitalthemen von morgen auf der Plattform von heute mit bislang **700.000\*** Klicks.

UNSERE AKTUELLEN BLOG-RUBRIKEN:

- ✓ Machine Learning
- ✓ Quantum Computing
- ✓ Internet of Things
- ✓ Blockchain
- ✓ Cyber Security
- ✓ Human Resource

**INTERESSE GEWECKT?**

Dann melden Sie sich bei der **DIGITALE WELT**-Redaktion per E-Mail: [blog@digitaleweltmagazin.de](mailto:blog@digitaleweltmagazin.de) oder telefonisch unter der +49 89 2180 9171.

\*Unsere Beiträge wurden online unter [www.digitaleweltmagazin.de/blog](http://www.digitaleweltmagazin.de/blog) veröffentlicht und erzielten dabei die oben genannte Klickanzahl im Zeitraum 01. August 2017 – 29. Juli 2019.

## Leitfaden zur Veröffentlichung von Fachbeiträgen

### FÜR IHRE EINREICHUNG SIND FOLGENDE DINGE ZU BEACHTEN:

1. Ihr Fachbeitrag erfüllt folgende Anforderungen:
  - Inhaltliche Orientierung an den Blog-Rubriken der DIGITALEN WELT
  - Titel mit max. 60 Zeichen inkl. Leerzeichen
  - Umfang: 7.000-15.000 Zeichen inkl. Leerzeichen
  - Exklusiv für DIGITALE WELT verfasst
  - Alle Grafiken und Bilder sind rechtfrei
  - Enthält keinerlei Werbung
2. CV und Bild des Autors:
 

Um Sie als Autor vorzustellen, benötigen wir:

  - Ihren vollständigen Namen
  - eventuelle akademische Titel
  - Position im Unternehmen (max. 40 Zeichen)
  - Name Ihres Unternehmens (max. 25 Zeichen)
  - Portraitbild mit min. 300 DPI Auflösung
  - CV mit max. 300 Zeichen inkl. Leerzeichen
3. Consent to Publish:
 

Für die Publikation in Print- & Online-Medien benötigen wir die vollständig ausgefüllte und unterzeichnete Einverständniserklärung. Diese finden Sie unter [digitaleweltmagazin.de/erklaerung](http://digitaleweltmagazin.de/erklaerung)

### DAFÜR KOMMEN SIE IN DEN GENUSS FOLGENDER LEISTUNGEN:

- Ihr qualitativ hochwertiger Beitrag wird in unserem Online-Blog des DIGITALE WELT Magazins veröffentlicht
  - Die besten Beiträge werden additiv im Print-Magazin abgedruckt
  - Unterstützung einer hohen Reichweite durch Verbreitung über Social-Media
  - Dieser Service ist für Sie selbstverständlich kostenlos
- Schicken Sie uns Ihre vollständigen Unterlagen an [blog@digitaleweltmagazin.de](mailto:blog@digitaleweltmagazin.de) oder nutzen Sie unser Online-Tool unter [digitaleweltmagazin.de/fachbeitrag-einreichen](http://digitaleweltmagazin.de/fachbeitrag-einreichen)
- Eine Auflistung unserer aktuellen und vergangenen „Call-For-Contributions“ finden Sie unter [digitaleweltmagazin.de/calls](http://digitaleweltmagazin.de/calls)

**Wir freuen uns auf Ihren Fachbeitrag mit Ihrem Expertenwissen.**

Ihr **DIGITALE WELT** Team

## Future Processing

# Liefere Sie Ihre IT-Projekte

reibungslos + rechtzeitig + schnell + agil

Kunden nutzen die Vorteile unserer 19-jährigen Erfahrung.

Heute **800 Mitarbeiter**

**777** BSc-, MSc-Absolventen und Doktoranden

**Kunden** in 10 Ländern



**Mehr als 150** globale Kunden in unserem Portfolio.

**65%** unserer Umsätze stammen von Kunden, die schon seit mehr als 3 Jahren mit uns zusammenarbeiten

**Microsoft Partner** seit 12 Jahren

**ISO 27001:2013** zertifiziert

**2019** GSA Best Nearshore Team 2019

### Unsere Schwerpunkte

- Maßgeschneiderte Softwareentwicklung (.NET & Java)
- Cloud Service
- Anforderungsanalyse
- Künstliche Intelligenz und Maschinelles Lernen
- Software-Architektur
- Große Datenmengen - Big Data
- Produktdesign
- Blockchain-Entwicklung
- IT Sicherheit

**Digitale Stadt München e.V.**

**Digitale Stadt Düsseldorf**



### Kontakt



Adam Mirowski  
Business Development Manager DACH  
[amirowski@future-processing.com](mailto:amirowski@future-processing.com)  
Mob: +48 605 446 665

Future Processing  
ul. Bojkowska 37A  
44-100 Gliwice, Polen

[www.future-processing.de](http://www.future-processing.de)

MACHINE LEARNING BEGREIFEN:

# Artificial Intelligence for one day.

UNIBRAND

## AI zum Anfassen! Lernen Sie in unserem Hands-on-Workshop, wie Sie Machine Learning für Ihr Unternehmen nutzen.

Artificial Intelligence bzw. Machine Learning ist längst keine Spielerei mehr. In vielen produktiven Anwendungen werden selbstlernende Systeme eingesetzt oder Unternehmensdaten mit Machine-Learning-Methoden analysiert. Mit unserer Machine-Learning-Erfahrung machen wir das Thema für Sie greifbar und befähigen Sie, Ihre eigenen Ideen zu definieren und umzusetzen. Im Workshop werden Sie grundsätzliche Machine-Learning-Methoden anschaulich mit Stift und Papier durchspielen, um die Mechanik hinter der Mathematik zu verstehen. Dies gibt Ihnen die Basis, um ein Gefühl für die Einsatzmöglichkeiten selbstlernender Methoden zu entwickeln.

Gerne unterstützen wir Sie bei der Ideenfindung für den Einsatz von Machine Learning in Ihrem Unternehmen.

Jetzt gleich informieren unter [www.iteratec.de/machine-learning](http://www.iteratec.de/machine-learning)



iteratec

KOMPETENZ,  
DIE ENTLASTET

Softwareentwicklung  
IT-Projekte  
Architekturberatung  
Technologieberatung