

Maschinelles und Tiefes Lernen

Der Motor für „KI made in Germany“

WHITEPAPER

Kristian Kersting
Volker Tresp
AG Technologische
Wegbereiter
und Data Science

Inhalt

1. Eine Zukunft mit Künstlicher Intelligenz gestalten	3
2. Maschinelles Lernen und Tiefes Lernen: Motor für aktuelle KI-Durchbrüche.....	4
3. KI-Expertise für „KI made in Germany“	6
4. Langfristige Perspektive: AI is harder than you think!.....	9
5. Technologische Souveränität und europäische Dimension	14
6. Instrumente, um „KI made in Germany“ zu erreichen	15
7. Fazit	16
Über dieses Whitepaper.....	17
Literatur.....	18

1. Eine Zukunft mit Künstlicher Intelligenz gestalten

Wir leben im goldenen Zeitalter der Künstlichen Intelligenz¹ (KI). Nachhaltige algorithmische Fortschritte insbesondere beim Maschinellen Lernen² (ML) und beim Tiefen Lernen (Deep Learning, DL) in Verbindung mit der Verfügbarkeit massiver Datensätze und Fortschritten beim schnellen, parallelen Rechnen haben Durchbrüche in ganz verschiedenen Anwendungsfeldern ermöglicht. Anwendungen, die noch vor wenigen Jahren als Science-Fiction galten, sind heute schon in unserem Alltag angekommen oder stehen kurz davor: Wissen von unvorstellbarem Umfang und in erstaunlicher Tiefe wird mit einem Mausklick zugänglich, sprachgesteuerte Assistenzsysteme unterstützen unser Leben in vielen Bereichen, Bilderkennungssysteme haben menschenähnliche Leistungsfähigkeit erreicht, autonome Fahrzeuge werden zunehmend Realität, Geschäftsmodelle verändern sich rapide und personalisierte Medizin ermöglicht eine optimale und individualisierte Behandlung.

Künstliche Intelligenz kann in vielfältiger Art und Weise dazu beitragen, unsere Lebensbedingungen zu verbessern. Die Herausforderung für die Gesellschaft ist es, eine Zukunft mit Künstlicher Intelligenz zu gestalten. Dabei gilt es, gleichermaßen Chancen zu nutzen, aber auch Risiken zu analysieren und Lösungswege anzubieten. Die unterschiedlichen gesellschaftlichen Akteure müssen eine Zukunft mit Künstlicher Intelligenz gemeinsam gestalten. Im Folgenden stehen primär die technischen Herausforderungen und der Aufbau von Fähigkeiten im Mittelpunkt: Zu welchen Themen muss national KI-Kompetenz aufgebaut werden und in welche Forschungsthemen sollte heute und morgen investiert werden?

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).

2. Maschinelles Lernen und Tiefes Lernen: Motor für aktuelle KI-Durchbrüche


Smarte Lösungen werden heute vornehmlich manuell programmiert. Ein Smartphone beispielsweise beinhaltet mehr als zehn Millionen Codezeilen. Die aktuellen Entwicklungen auf dem Gebiet der Künstlichen Intelligenz markieren einen Paradigmenwechsel: Statt Verarbeitungsschritte manuell zu kodieren, wird die Fähigkeit zu lernen programmiert. Mithilfe des Maschinellen Lernens können Agenten aus sehr vielen Beispielsituationen Muster erlernen und auf neue, ähnliche Situationen übertragen. Die größten KI-Erfolge basieren derzeit auf tiefen neuronalen Netzen (Tiefes Lernen bzw. Deep Learning), bei denen eine große Zahl an künstlichen Neuronen Eingangsinformation in mehreren Schichten verarbeiten und am Ausgang das Ergebnis bereitstellen.

Auch beim Maschinellen Lernen muss weiterhin der Mensch programmieren. Allerdings programmiert er nicht mehr fertige Lösungen. Stattdessen entwickelt er Programme, die aufgrund von Trainingsdaten die Lösung erlernen. Durch Tiefes Lernen oder Deep Learning, einer Teildisziplin des Maschinellen Lernens, konnten jüngst in vielen Bereichen bemerkenswerte Durchbrüche erzielt werden. Diese Fortschritte sind die Basis für die meisten Erfolge in den erwähnten Anwendungsfeldern. So sind beispielsweise moderne Übersetzungs- und Bilderkennungssysteme ohne Tiefes Lernen nicht denkbar. Neuronale Netzwerke besitzen eine hohe Expressivität, 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 mit wenig Aufwand auf eine neue Aufgabenstellung anzupassen.

Das Verständnis der theoretischen Grundlagen des Tiefen Lernens ist – im Gegensatz zu früheren Ansätzen wie den Support Vector Machines – teilweise noch lückenhaft: Optimale Lösungen entstehen in einem Trial and Error-Verfahren, das auf Erfahrungswissen und Heuristiken basiert. Die Erarbeitung der theoretischen Grundlagen des Tiefen Lernens ist ein wichtiger gegenwärtiger Forschungsschwerpunkt.

Die Begriffe Künstliche Intelligenz, Maschinelles Lernen und Tiefes Lernen bzw. Deep Learning werden häufig nicht trennscharf verwendet. Künstliche Intelligenz definiert Herausforderungen, die es zu lösen gilt, und entwickelt Lösungsansätze. Beim Maschinellen Lernen steht das Erlernen der Lösungen im Vordergrund. Das Tiefe Lernen wiederum stellt derzeit einige der leistungsfähigsten Ansätze des Maschinellen Lernens bereit (siehe Abbildung 1).

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



3. KI-Expertise für „KI made in Germany“

Ohne Tiefes Lernen bzw. Deep Learning sind die spektakulären und heute viel diskutierten Durchbrüche in der Künstlichen Intelligenz nicht denkbar. Für eine erfolgreiche „KI made in Germany“ ist es unabdingbar, die Expertise für Maschinelles Lernen und Tiefes Lernen in Deutschland zu stärken: Denn unabhängig davon, ob Daten als das „Öl des 21. Jahrhunderts“ in großem oder kleinem Umfang gesammelt werden, ohne hochleistungsfähige „Raffinerien“ – also Methoden wie das Maschinelle Lernen oder das Tiefe Lernen – bleiben Daten, was sie sind: Rohöl, das keinen (Wirtschafts-)Motor antreiben kann.

Deutschland ist in vielen Forschungs- und Anwendungsbereichen sehr stark. Die Bundesregierung möchte diese Stärke ausbauen und stellt deshalb zur Umsetzung ihrer Strategie Künstliche Intelligenz bis 2025 weitere drei Milliarden Euro bereit (Bundesregierung 2018: 6). Um die Wettbewerbsfähigkeit der KI-Forschung in Deutschland zu sichern und mit der internationalen Entwicklung Schritt zu halten, sind weitere Investitionen in die KI-Spitzenforschung nötig – vor allem in den Bereichen Maschinelles und Tiefes Lernen. Andernfalls besteht die Gefahr, dass Deutschland den Anschluss verliert. Zudem muss die Spitzenforschung auf ein breiteres Fundament gestellt werden. Letztendlich gilt es, den Weg zur industriellen Umsetzung zu erleichtern und die Expertise in den Unternehmen zu stärken.

Im Folgenden werden Kompetenzen benannt, die für eine Umsetzung von „KI made in Germany“ zentral sind und an den Hochschulen, in Forschungsprogrammen und Kompetenzzentren adressiert werden sollten. Darüber hinaus werden Infrastrukturbedarfe benannt, die im Dialog zwischen Wissenschaft, Wirtschaft und Politik bearbeitet werden sollten. Die Reihenfolge entspricht dabei ihrer derzeitigen Bedeutung für die Technologieentwicklung.

■ **Expertise bei den Grundlagen und Verfahren des Maschinellen Lernens**

stärken. 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 und andere Verfahren. Zudem gehören zu den Grundlagen 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 Evaluation im Allgemeinen.

- **Expertise im Bereich Tiefes Lernen bzw. Deep Learning stärken**, insbesondere in den Teilgebieten neuronale Netzwerke, Convolutional Neural Networks, rekurrente neuronale Netze, Autoencoder, Neural Variational Inference, Generative Adversarial Networks, Self-Supervised Deep Networks, tiefe Wahrscheinlichkeitsmodelle, differenzierbare Programmierung, stochastische Optimierung und Visualisierung bzw. Erklärbarkeit von tiefen Modellen.
- **KI-Infrastruktur auf- und ausbauen**, insbesondere von Clustern, die das Maschinelle Lernen und das Tiefe Lernen beispielsweise mittels speziellen KI-Beschleunigern wie GPUs, TPUs u. a. unterstützen. Expertinnen und Experten für Künstliche Intelligenz und Maschinelles Lernen und die Politik sollten in einem kurzfristigen und intensiven Dialog erarbeiten, wie eine solche Infrastruktur ausgestaltet und umgesetzt werden kann. 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.
- **Forschung zu neuartigen Rechenplattformen stärken**. Heutige KI-Infrastrukturen basieren auf CPU- und GPU-Clustern. Zukünftige KI-Infrastrukturen werden sich voraussichtlich stark davon unterscheiden. Neue Rechenplattformen zu erforschen und Kompetenzen dazu aufzubauen, kann zu einem Wettbewerbsvorteil werden, insbesondere bei grundlegenden Umbrüchen auf dem Hardwaresektor. Deutschland sollte daher nicht nur auf bereits ausgereifte Technologien setzen, sondern gezielt künftige Basistechnologien für Künstliche Intelligenz erforschen.
- **System- und Integrationsexpertise stärken**. Dies umfasst die Kombination und Trade-off-Analyse von KI-Verfahren mit klassischen Verfahren ebenso wie Künstliche Intelligenz mit einem Energieverbrauch im Milliwatt-Bereich, sichere und garantierte KI-Anwendungen und Künstliche Intelligenz auf kostengünstigen Plattformen. Ein Schwerpunkt sollte auf die Architektur dieser Systeme mit KI-Komponenten gelegt werden. Denn die effiziente Bereitstellung der Daten an den Rechenknoten stellt derzeit die wesentliche Herausforderung dar – weniger die effiziente Gestaltung der Knoten selbst.
- **Expertise in weiteren relevanten KI-Methoden stärken**, beispielsweise Schlussfolgern, effiziente Suche (z. B. Monte Carlo Tree Search), Constraint Programming, Wissensrepräsentation, Planungsalgorithmen oder statistisch-relationale Ansätze.
- **Expertise in weiteren Bereichen der Datenwissenschaften stärken**, die nicht schon durch Maschinelles Lernen und Künstliche Intelligenz abgedeckt sind, etwa Datenerhebung, Datenmanagement verteiltes Rechnen oder insbesondere Hardware-basierte KI-Beschleunigung.

- **Expertise zur Anwendung von KI-Methoden und zur Untersuchung gesellschaftlicher, sozioökonomischer und politischer Effekte stärken**, die durch den vermehrten Einsatz Lernender Systeme und automatischer Entscheidungen ausgelöst werden: Interpretierbarkeit von KI-Modellen, KI-Qualitätssicherung, Diskriminierung durch und Bias von KI-Systemen sowie Wahrung der Menschenrechte bei der Anwendung von KI-Systemen u. a.
- **Statistik-Expertise und andere Kompetenzen für Künstliche Intelligenz und Maschinelles Lernen bereits in der Schule fördern**, so dass beispielsweise der Umgang mit Unwägbarkeiten und das Operieren in ungenau bestimmten Umgebungen frühzeitig erlernt wird. Das Verstehen und Interpretieren sowie der Umgang mit statistischen Aussagen sind wichtige Lerninhalte.

4. Langfristige Perspektive: AI is harder than you think!

Moderne KI-Anwendungen sind beeindruckend. Allerdings sind sie in der Entwicklung auch sehr kostenintensiv. Jedes aktuelle KI-Produkt – wie etwa Apple Siri, Amazon Alexa oder Tesla Autopilot – erfordert große und kostspielige Teams von Domain- und KI-Fachleuten, Datenwissenschaftlerinnen und -wissenschaftlern und Softwareentwicklerinnen und -entwicklern. Selbst in Unternehmen, die bereits erfolgreich KI-Technologien einsetzen, bleibt Künstliche Intelligenz ein seltenes und teures Gut, das oftmals einem kleinen Kreis von Nutzern vorbehalten bleibt. Darüber hinaus erfordern viele KI-Ansätze – wie das Tiefe Lernen – meist gelabelte Trainingsdaten, deren Beschaffung schwierig, wenn nicht gar unmöglich ist. Es ist ein wichtiges Ziel der Forschung, diese Entwicklungsprozesse zu vereinfachen.

Viele Expertinnen und Experten stimmen überein, dass Maschinelles Lernen der Schlüssel zur Künstlichen Intelligenz ist und es auch in Zukunft sein wird. So wie es keine Künstliche Intelligenz ohne Maschinelles Lernen gibt, so gibt es jedoch auch keine Künstliche Intelligenz, die ausschließlich auf Maschinellern Lernen basiert. In Zukunft sind zunehmend synergetische Lösungen zu erwarten, die unterschiedliche Paradigmen der KI-Forschung verknüpfen. **Das technologische Fundament der Künstlichen Intelligenz der Zukunft ist Maschinelles Lernen in Verbindung mit anderen leistungsstarken KI-Methoden und einem tiefen Verständnis der statistisch-probabilistischen Grundlagen.**

Einer der viel gefeierten KI-Durchbrüche ist AlphaGo: Das Computerprogramm besiegte 2016 den südkoreanischen Meister Lee Sedol im komplexen Brettspiel Go (Silver et al. 2016: 484-489). Sowohl AlphaGo als auch sein Nachfolger AlphaGo Zero kombinieren Tiefes Lernen bzw. Deep Learning mit klassischen KI-Algorithmen. AlphaGo Zero nutzt beispielsweise die stochastische Baumsuche (Silver et al. 2018: 1140-1144). Basierend auf diesem Zusammenwirken kann das Programm viele weitere Brettspiele erlernen. Ein ähnliches Bild zeigte sich 2017 auf der „Allen AI Science Challenge“. Die Aufgabe bestand darin, einen Text, der ein wissenschaftliches Problem auf Mittelstufen-Niveau beschreibt, zu verstehen und Multiple-Choice-Fragen zu beantworten. Alle Siegermodelle setzten Maschinelles Lernen ein. Jedoch gelang es keinem, den Test mit der gleichen Qualität wie ein kompetenter Mittelstufenschüler zu bestehen. Alle Gewinner argumentierten, dass dazu ein „tieferes“ Denken und Schlussfolgern nötig sei (Schoenick et al. 2017: 60-64).

Bei der Umsetzung von KI-Technologien sind sowohl der Energieverbrauch als auch die Entwicklungskosten beträchtlich: AlphaGo verbrauchte etwa ein Megawatt Energie und kostete – nach Expertenschätzungen – etwa eine Million Euro in der Entwicklung. Der Energieverbrauch und die Entwicklungskosten sind erheblich höher als in Edge Devices oder bei Cyber-Physical Systems (in diesem Bereich werden Milliwatt veranschlagt).

Ebenso werden unterschiedliche Teile einer heute oft noch segmentierten KI-Forschung – wie etwa Computer Vision, natürliche Sprachverarbeitung (im Besonderen NLP und Dialogbasierte Sprachsysteme), Robotik und Kognition – zunehmend zusammenwachsen und weitere Themen erschließen bzw. neue Durchbrüche ermöglichen. In den zukünftigen KI-Technologien liegen enorme Innovationspotenziale, die weit über den Nutzen großer Datenmengen hinausgehen. Künstliche Intelligenz könnte etwa in der Lage sein, Entwicklungs- und Produktionsprozesse, ganze Bauvorhaben und Verkehrsinfrastrukturen ganzheitlich und hocheffizient, autonom, ressourcensparend und sicher zu gestalten.

Breites Methodenwissen für die zukünftige Künstliche Intelligenz

Der Aufbau von KI-Systemen erfordert ein fundiertes Fachwissen im Bereich Künstliche Intelligenz, umfangreiche Programmierkenntnisse, Anwendungswissen sowie ein tiefes Verständnis der statistisch-probabilistischen Grundlagen. Konventionelle Programmiersprachen und Software-Engineering-Paradigmen werden den Herausforderungen der KI-Praktikerinnen und -Praktiker oftmals nicht gerecht. Die Integration von Maschinellen Lernen in (bestehende) Sensoren und verteilte, sehr stark beschränkte Geräte (z. B. ultra-low power microcontrollers) verschränkt neue ML-Algorithmen mit Hardware-Design. Aber selbst, wenn Produkte und Services gezielt gemeinsam als KI-Systeme entwickelt wurden, sind ein erheblicher Aufwand und viel Wissen erforderlich, um sichere KI-Anwendungen bereitzustellen, zu betreiben und zu warten – ganz besonders in kritischen Geschäftsprozessen. Nicht zuletzt muss die Künstliche Intelligenz auf einem fundierten Wissen im Umgang mit Unsicherheiten, das heißt den statistisch-probabilistischen Grundlagen der Künstlichen Intelligenz, aufbauen. Es ist also nicht übertrieben, wenn die Wissenschaftler Gary Marcus und Ernest Davis argumentieren: „AI is harder than you think“ (Marcus & Davis 2018).

Künstliche Intelligenz braucht also eine breite Expertise. Insbesondere, wenn Tiefes Lernen weniger „daten-hungrig“ sein soll und man die Künstliche Intelligenz innerhalb der ethischen, rechtlichen und gesellschaftlichen Rahmenbedingungen Deutschlands und Europas realisieren will. Eine starke Forschung mit unbefristeten und langfristigen Perspektiven an den deutschen Hochschulen ist dafür notwendig. **Durch zusätzliche Professuren in den Bereichen Künstliche Intelligenz, Maschinelles Lernen und Tiefes Lernen können die notwendigen Multiplikatoren ausgebildet werden. Sie können KI-Expertise weitervermitteln sowie in die Anwendung und Praxis tragen (auch zusammen mit anderen Disziplinen).** Wichtig ist es, diese Professuren nicht

nur durch temporäre Anschubfinanzierungen, sondern durchgängig zu fördern. Zudem ist es ratsam, eine größere Anzahl an Professuren nicht zum gleichen Zeitpunkt zu schaffen. Um Künstliche Intelligenz in Deutschland nachhaltig und dauerhaft zu stärken, sollten Professuren vielmehr kontinuierlich, zeitversetzt und kompetitiv besetzt werden. Die Gründung einer Stiftung könnte dazu beitragen; weitere Instrumente sollten entwickelt werden.

Starke Informatik und KI-Forschung: AI made easy

Für die nächste Generation der Künstlichen Intelligenz müssen die Grundlagen und Systeme geschaffen werden, die einen flexiblen Aufbau und eine sichere Nutzung von Künstlicher Intelligenz vereinfachen. An den heutigen KI-Erfolgen arbeiten große und kostspielige Teams von Statistikerinnen und Statistikern, Informatikerinnen und Informatikern und Software-Ingenieurinnen und -Ingenieuren. In Zukunft dagegen können Domänenexpertinnen und -experten, die über das nötige Wissen und die notwendigen Instrumente verfügen, dies allein leisten. Kleine Teams von KI-Laien werden Künstliche Intelligenz auf ihre Probleme anwenden, verstehen und qualitativ hochwertige Ergebnisse erzielen können. **Dazu müssen Künstliche Intelligenz und andere Disziplinen der Informatik zusammenarbeiten:** etwa in den Bereichen der Datenbanksysteme, Cybersicherheit, Software-Engineering, Cloud- und Edge-Programming oder verteilten und eingebetteten Systemen. Ebenso wichtig ist die enge Zusammenarbeit mit **anderen Anwendungsdisziplinen** wie beispielsweise im Bereich der (digitalen) Signalverarbeitung, der Regelungstechnik, der Sensorik, der Modellierung in der Physik und dem Maschinenbau, der Optimierung, der Statistik und Wahrscheinlichkeitslehre.

Menschenzentrierte KI – Die Zwillinge Künstliche Intelligenz und Cognitive Science

Für viele KI-Anwendungen in Wirtschaft und Gesellschaft ist es essentiell, dass Vorhersagen und Entscheidungen nachvollziehbar und zuverlässig sind, damit wir ihnen vertrauen können und sie selbst unter ungünstigen Bedingungen funktionieren. Natürlich sind Erklärungen nicht in allen Fällen und jederzeit erforderlich. Tiefe Netzwerke sollen gerade in großen, hochdimensionalen Datenmengen Muster finden, die kein Mensch jemals entdecken könnte. Aus ethischen, juristischen und sozialen Gründen gibt es aber bestimmte Domänen (etwa in der Medizin) und Aufgaben (beispielsweise bei Therapieempfehlungen), in denen eine nachvollziehbare Erklärung und ein zuverlässiges Verhalten unbedingt notwendig sind. Es ist also entscheidend, Blackbox-Modelle³

³ Whitebox-Modelle kennen die kausale Struktur der zu lernenden Problemstellung möglichst genau. Eine Blackbox berücksichtigt diese Struktur hingegen nicht. Greybox bezeichnet Kombinationen zwischen beiden.

der Künstlichen Intelligenz zu nachvollziehbaren und zuverlässigen Whitebox-Modellen zu machen. Auf unterschiedlichen Ebenen der Forschung, von der Grundlagenforschung bis zur Anwendungsforschung, zeigen sich aufschlussreiche Wechselwirkungen und eine Befruchtung zwischen Künstlicher Intelligenz und Kognitiven Systemen: Die Künstliche Intelligenz kann an diesem Punkt von den Kognitionswissenschaften lernen und vice versa.

Cyber-physische KI-Systeme – Künstliche Intelligenz für den digitalen Zwilling und unter Ressourcenbeschränkung

Die Leistungsfähigkeit der deutschen Volkswirtschaft ist stark vom Maschinen- und Anlagenbau und der Elektrotechnik geprägt, die insbesondere für die Schwerpunkte Automobil, Industrie und Automatisierung eine wichtige Rolle spielen. Für zukünftige KI-Systeme bedeutet dies eine Vielzahl von Anforderungen: Sie müssen eingebettet auf energie- und kostenbeschränkten Plattformen ausführbar sein und die notwendigen Sicherheitsanforderungen („Safety“ und „Security“) einhalten. Funktionieren müssen sie auf Datenströmen von Sensorsignalen, die zum Teil vorverarbeitet werden müssen. Gleichzeitig sollen sie Steuerungssignale für Starkstrom- und Hochspannungsanlagen liefern können. Des Weiteren ist die Sammlung von ausreichenden Lerndaten in vielen Fällen sehr aufwendig, wenn dies mit physikalischen Experimenten verbunden ist. Aus diesem Grund werden Lerndaten in Zukunft zunehmend mit Hilfe von Simulationen und (Whitebox-)Modellen erzeugt. Diese Koppelung von Künstlicher Intelligenz und Abbildungen entsprechender physikalischer Systeme im virtuellen Raum – dem digitalen Zwilling – erschließt einen zukunftsweisenden Ansatz für die deutsche Industrie mit ihrem starken Mittelstand (Bundesministerium für Wirtschaft und Energie 2018).

Öffentlich-private Partnerschaften für den Wissenstransfer, Förderung von Innovation und Gründungen

Weil Künstliche Intelligenz Lösungen für viele Herausforderungen verspricht, muss der Wissenstransfer im KI-Bereich – neben klassischen Arten der Fort- und Weiterbildung – insbesondere dazu genutzt werden, in den Unternehmen selbst KI-Expertise aufzubauen. Dies bildet die Voraussetzung dafür, dass die Betriebe neue Technologien einsetzen und entwickeln können. Nur so bleiben Unternehmen selbstständig innovativ. Die Keimzelle des KI-Wissenstransfers ist der personelle Transfer von gut ausgebildeten, ständig lernenden Domänen- und KI-Fachleuten, die in der Industrie kontinuierlich neue Lösungen entwickeln und mit den weltweiten Innovationen Schritt halten können. **Der Wissenstransfer muss also neben klassischen Ansätzen der Fort- und Weiterbildung insbesondere über „KI-Köpfe“ erfolgen, um Innovation und Ausgründungen im Bereich Künstliche Intelligenz zu befeuern.**

Viele Entscheidungsträgerinnen und Entscheidungsträger in Wissenschaft, Wirtschaft und Gesellschaft haben das große Potenzial der Künstlichen Intelligenz erkannt, allerdings bestehen oft Vorbehalte. Um das Potenzial 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.

Die KI-Kompetenzzentren, einschlägige KI- und Data-Science-Studiengänge und die Forschung an den Hochschulen bilden eine ausgezeichnete Basis für eine **Synergie zwischen Forschung, Lehre und Weiterbildung**. Sie können helfen, **die so dringend benötigten KI-Fachleute für den Wirtschaftsstandort Deutschland auszubilden**. Dazu sollte auch über **öffentlich-private Partnerschaften zur Sicherung der deutschen Wettbewerbsfähigkeit in der Künstlichen Intelligenz nachgedacht werden**. Durch die hohe Forschungs- und Industrierelevanz dieser Themen ist eine substantielle Finanzierung durch Drittmittel aus gezielten Förderprogrammen und Mitteln von Einrichtungen wie der Deutschen Forschungsgemeinschaft (DFG) oder der Europäischen Union (EU) notwendig. Gleichzeitig ist aber insbesondere auch die Industrie in der Pflicht – etwa durch Kooperationen mit Hochschulen und Forschungsinstitutionen.

Entwicklung der Algorithmen und „Köpfe“ für Innovation

Der technologische Fortschritt im Bereich Künstliche Intelligenz ist rasant, so 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. Die 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.

Neue duale Programme für Doktorandinnen und Doktoranden (in Analogie zur dualen Ausbildung) und insbesondere die Förderung von Gründungen und Start-ups sind vielversprechende Instrumente, um eine dynamische Ideenwirtschaft aufzubauen. **Zusammen mit bewährten Ansätzen der Weiter- und Fortbildung sowie Onlineangeboten können so alle Beteiligten gemeinsam einen Wissenstransfer in der Künstlichen Intelligenz realisieren**. Die Hochschulen können diese Aufgabe kurzfristig allein nicht leisten; im Zusammenwirken mit den Unternehmen hingegen kann der Transfer von Knowhow substantiell verstärkt werden.

5. Technologische Souveränität und europäische Dimension

Heutige KI-Forschung und KI-Anwendungen setzen in breiter Masse auf die „Open Source“ bereitgestellten Software-Pakete von US-amerikanischen Internetfirmen auf, allen voran den Produkten von Google. Auf der einen Seite ist dies ein Vorteil, da grundlegende Implementierungen wie logistische Regressionen, neuronale Netze oder Support Vector Machines nicht mehr durchgeführt werden müssen. Auf der anderen Seite ist nicht transparent, welche Algorithmen freigegeben und welche der Öffentlichkeit vorenthalten werden. Dadurch können unkalkulierbare Abhängigkeiten entstehen und auf die Marktpositionen von Unternehmen wirken. Hochschulen, Forschungsinstitute und Firmen sollten in die Lage versetzt werden, eine gewisse Autonomie bei der Nutzung von KI-Infrastrukturen, in denen Rechenleistung, Speicher und Werkzeuge bereitgestellt werden, zu erreichen. Diese Aufgabe kann – ähnlich wie die oben angesprochenen technisch-wissenschaftlichen Herausforderungen – nicht von Deutschland allein bewältigt werden. Das Netzwerk der deutschen KI-Forschung muss deshalb eng mit der europäischen Spitzenforschung im Bereich Künstliche Intelligenz verwoben werden. Ein kooperativer Wettstreit um die besten Ideen und Lösungen muss Europa auf dem Gebiet der Künstlichen Intelligenz voranbringen.

6. Instrumente, um „KI made in Germany“ zu erreichen

Ideale Voraussetzungen für Forscherinnen und Forscher sowie Studierende in den Bereichen Künstliche Intelligenz, Maschinelles Lernen und Tiefes Lernen beinhalten folgende Elemente:

- **Weitere Stärkung der KI-Forschung und -Lehre** durch unbefristete Professuren in den Bereichen Künstliche Intelligenz, Maschinelles Lernen und Tiefes Lernen, die zeitversetzt und kompetitiv besetzt werden und mit einem adäquaten akademischen Mittelbau und entsprechenden Mitteln hinterlegt sind.
- **Bereitstellung und Zugang zu entsprechenden Ressourcen und Infrastrukturen** wie etwa GPU/CPU-Clustern, aber auch Maßnahmen zur Erforschung weiterer technischer Plattformen und Beschleuniger.
- **Förderung der interdisziplinären Vernetzung mit anderen Wissenschaften** wie etwa der Statistik, der Elektrotechnik bzw. technischen Informatik (in USA: EECS Departments), dem Maschinenbau, den Wirtschaftswissenschaften, den Kognitionswissenschaften, der Medizin, der Physik oder der Chemie.
- **Vernetzung der KI-Forschung (national und international)**, etwa durch (überregionale) Graduiertenprogramme, unbürokratische Besucherprogramme und ausreichende Reisemittel.
- **Co-Innovationsprogramme zum Transfer von Knowhow in die Industrie**, Nutzung der KI-Kompetenzzentren und anderer KI-Hubs für den Transfer in Unternehmen und fokussierte Innovation für kleinere und mittlere Unternehmen (KMU).
- **Schaffung und Förderung von Ökosystemen der Talente**, in denen KI-Wissen informell geteilt und weiterentwickelt wird. Unternehmen, Hochschulen, Forschungseinrichtungen und Start-ups müssen in geographischer Nähe versammelt werden, so dass die Talente unkompliziert zusammenarbeiten und Ideen austauschen können.
- **Stärkung und Ausbau der Start-up-Infrastruktur**, z. B. durch die Bereitstellung von Mitteln für ein „Start-up-Add-on-Programm“ an Hochschulen, um Bachelor-/Master-Absolventinnen und Absolventen und Doktorandinnen und Doktoranden Zeit für die Konzeption, ein Prototyping oder sogar die Entwicklung marktfähiger KI-Produkte innerhalb einer starken KI-Infrastruktur zu geben.

Durch interdisziplinäre Zusammenarbeit entlang der Wertschöpfungsketten im europäischen Kontext kann eine Forschung zu Künstlicher Intelligenz, Maschinellem Lernen und Tiefem Lernen zum Nutzen aller in Deutschland weiterwachsen und „KI made in Germany“ zu einem global sichtbaren Qualitätsmerkmal entwickelt werden.

7. Fazit

Maschinelles Lernen und Tiefes Lernen bzw. Deep Learning sind wichtige Technologien, durch die entscheidende Durchbrüche in der Künstlichen Intelligenz erzielt wurden. Sie werden auch künftige Innovationen ermöglichen. Daher müssen Maschinelles Lernen und Tiefes Lernen bzw. Deep Learning in Deutschland gestärkt werden: Ziel muss es sein, KI-Talente anzuziehen und an den Standort zu binden, die Innovationskraft von Forschung und Wirtschaft zu erhalten und auszubauen. Eine wichtige Voraussetzung dafür ist eine im internationalen Vergleich gut ausgestattete und gut unterstützte Forschung in diesen Bereichen. Langfristig wird sich in der KI-Forschung ein breiter Methoden- und Expertisenkatalog entwickeln. Dabei ist der Transfer der neuesten Technologien von der Forschung in die Unternehmen von zentraler Bedeutung – etwa durch Transfer über die besten „Köpfe“, neue Instrumente der Aus- und Weiterbildung oder die Stärkung von Gründungen und Start-ups.

Über dieses Whitepaper

Das vorliegende Papier wurde von **Kristian Kersting** und **Volker Tresp** federführend erstellt. Es stützt sich auf Gespräche mit **Katharina Morik** (Technische Universität Dortmund), **Ulf Brefeld** (Leuphana Universität Lüneburg), **Stefan Kramer** (Johannes-Gutenberg-Universität Mainz), **Alexander Löser** (Beuth Hochschule Berlin), **Philipp Schlunder** (RapidMiner) und **Marc Toussaint** (Universität Stuttgart).

Die Autoren und ihre Gesprächspartner sind Mitglieder der Arbeitsgruppe Technologische Wegbereiter und Data Science der Plattform Lernende Systeme. Als eine von insgesamt sieben Arbeitsgruppen befasst sie sich mit den technologischen Grundlagen und Enablern von Künstlicher Intelligenz. Dabei geht es beispielsweise um die Anforderungen an die Forschung, die Ausbildung von KI-Fachleuten oder den Transfer von Forschungsergebnissen in erfolgreiche Anwendungen.

Autoren des Whitepapers:

Prof. Dr. Kristian Kersting, Technische Universität Darmstadt

Prof. Dr. Volker Tresp, Siemens AG, Ludwig-Maximilians-Universität München

Die Arbeitsgruppe wird geleitet von:

Prof. Dr. Katharina Morik, Technische Universität Dortmund

Prof. Dr. Volker Markl, Technische Universität Berlin

Redaktion

Dr. Andreas Heindl, Geschäftsstelle der Plattform Lernende Systeme

Johannes Melzer, Geschäftsstelle der Plattform Lernende Systeme

Die Plattform Lernende Systeme

Lernende Systeme im Sinne der Gesellschaft zu gestalten – mit diesem Anspruch wurde die Plattform Lernende Systeme im Jahr 2017 vom Bundesministerium für Bildung und Forschung (BMBF) auf Anregung des Fachforums Autonome Systeme des Hightech-Forums und acatech – Deutsche Akademie der Technikwissenschaften initiiert. Die Plattform bündelt die vorhandene Expertise im Bereich Künstliche Intelligenz und unterstützt den weiteren Weg Deutschlands zu einem international führenden Technologieanbieter. Die rund 200 Mitglieder der Plattform sind in Arbeitsgruppen und einem Lenkungskreis organisiert. Sie zeigen den persönlichen, gesellschaftlichen und wirtschaftlichen Nutzen von Lernenden Systemen auf, benennen aber auch Herausforderungen und Gestaltungsoptionen.

Literatur

Bundesministerium für Wirtschaft und Energie 2018: Wirtschaftsmotor Mittelstand Zahlen und Fakten zu den deutschen KMU. https://www.bmwi.de/Redaktion/DE/Publikationen/Mittelstand/wirtschaftsmotor-mittelstand-zahlen-und-fakten-zu-den-deutschen-kmu.pdf?__blob=publicationFile&v=32 (abgerufen am 15. März 2019).

Bundesregierung (2018): Strategie Künstliche Intelligenz der Bundesregierung. 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.

Glossar

Autoencoder – Künstliches neuronales Netz. Lernziel des Autoencoders ist es, einen Datensatz mit allen relevanten Merkmalen komprimiert repräsentieren zu können (Encoding). Anschließend soll er aus diesen wieder weitestgehend den ursprünglichen Datensatz rekonstruieren. Der Autoencoder wird beispielsweise zur Dimensionsreduktion genutzt, wobei Daten mit vielen Merkmalen (Repräsentation mit vielen Dimensionen) in Daten mit weniger, jedoch wesentlichen Merkmalen umgewandelt werden (Repräsentation mit weniger Dimensionen). Eine verbreitete Anwendung ist die zweidimensionale Repräsentation von Daten, die eine bessere Visualisierung und ein besseres Verständnis von Bildern erlaubt.

Black-Box-Modell – Black-Box-Modelle des maschinellen Lernens sind Modelle rein statistischer Art. White-Box-Modelle dagegen bezeichnen interpretierbare Modelle. Sie ermöglichen beispielsweise eine analytische oder physikalische Beschreibung der Funktionen eines trainierten Modells. Bei Grey-Box-Modellen kombiniert man beide Ansätze, um die jeweiligen Vorteile zu vereinen.⁴

Boosting – Klassifizierungsalgorithmen, die zu den Ensemble-Methoden gehören und mehrere kleine bzw. schwache Klassifikatoren zu einem leistungsfähigen Klassifikator zusammenfügen. Die Kernidee des Boosting ist es, auf einem Datensatz mehrere schwache Klassifikationsmodelle aufeinander folgend und abhängig derart zu trainieren, dass sie zusammengefügt ihre jeweiligen Schwachstellen ausgleichen.

Cloud-Programmierung (englisch: Cloud Computing) – Bei der Cloud-Programmierung wird die Rechenleistung (CPU, GPU, RAM, Netzwerkgeschwindigkeit, Storage OS-Software) eines Dienstes über ein Netzwerk bereitgestellt (normalerweise das Internet), anstatt die Rechenressourcen physisch vor Ort zu haben. Vorteile für Unternehmen sind Kosteneinsparungen, da sie diese Dienste rein nach Bedarf nutzen können und nur die tatsächliche Dienstleistung bezahlen. Außerdem übernimmt der Cloud-Provider die Sicherung vor Cyber-Angriffen.

Cognitive Science (deutsch: Kognitionswissenschaft) – Gegenstand der Kognitions-wissenschaft ist das Erforschen kognitiver Fähigkeiten, wie Wahrnehmung, Denken, Lernen, Motorik und Sprache. Ihr Ziel ist es, die geistigen Leistungen des Menschen und anderer Organismen zu begreifen und in technischen Systemen nachzubilden.⁵

4 Fraunhofer Gesellschaft (2018): Maschinelles Lernen: Kompetenzen, Forschung, Anwendung. https://www.bigdata.fraunhofer.de/content/dam/bigdata/de/documents/Publikationen/Fraunhofer_Studie_ML_201809.pdf (abgerufen am 18.06.2019).

5 Käferbrock et al. (2007): Einführung in die Kognitionswissenschaften & die Künstliche Intelligenz. https://www.researchgate.net/publication/242215171_Einfuehrung_in_die_Kognitionswissenschaften_die_Kunstliche_Intelligenz (abgerufen am 17.06.2019).

Constraint Programming – Die Constraint-Programmierung ist eine Weiterführung aus der logischen Programmierung, also der Definition von Berechnungen als Regeln. In der Constraint-basierten Programmierung wird eine Antwort auf ein Problem gefunden, das durch Einschränkungen und Bedingungen (Constraints) manuell beschrieben wurde. Anwendungsbereiche sind etwa die Produktions- und Personalplanung, Transportoptimierung sowie Layout-Generierung.⁶

Convolutional Neural Networks (CNN, deutsch: faltendes neuronales Netzwerk) – Deep Learning-Architektur, die sich vor allem für Anwendungen mit großen Eingabedimensionen wie in der Bilderkennung eignet. CNN erlauben es beispielsweise, Objekte in Bildern unabhängig von der Position zu erkennen. Im Gegensatz zu klassischen neuronalen Netzen nutzen die Neuronen einer gefalteten Schicht in einem CNN gemeinsame Parameter. Sie benötigen deshalb einen geringeren Speicherplatz und eine verkürzte Trainingszeit.⁷

CPU (englisch: Central Processing Unit, deutsch: zentrale Prozessoreinheit) – Hauptprozessor eines Computers. Dieser ist für die Berechnung und Steuerung aller wichtigen Vorgänge, Anfragen und Ein- und Ausgaben des Computers zuständig.

Cyber Physical Systems – In Cyber-physischen Systemen sind mechanische Komponenten, Software und moderne Informationstechnik über Netzwerke wie beispielsweise dem Internet miteinander verbunden. Dies ermöglicht es, die Infrastrukturen zu steuern, zu regeln und zu kontrollieren und erlaubt einen Informationsaustausch in Echtzeit. Einsatzgebiete sind zum Beispiel die Produktfertigung und das autonome Fahren.⁸

Datenbereinigung – Verfahren zum Entfernen oder Korrigieren von Datenfehlern wie Dopplungen, Formatierungsfehlern oder fehlerhaften, unvollständigen Datensätzen in Datenbanken.

Deep Learning (deutsch: tiefes Lernen) – Methode des maschinellen Lernens bei der aufeinander aufbauende Schichten von Merkmalen automatisch gelernt werden. Realisiert wird sie meist mit künstlichen neuronalen Netzen. Diese umfassen mehrere Schichten – typischerweise eine Eingabe- und Ausgabeschicht sowie mehr als eine „versteckte“ dazwischenliegende Schicht. Die einzelnen Schichten bestehen aus einer Vielzahl künstlicher Neuronen, die miteinander verbunden sind und auf Eingaben von Neuronen aus der jeweils vorherigen Schicht reagieren. In der ersten Schicht wird etwa ein Muster erkannt, in der zweiten Schicht ein Muster von Mustern und so weiter. Je komplexer (tiefer) das Netz (gemessen an der Anzahl der Schichten von Neuronen, der Verbindungen zwischen Neuronen sowie der Neuronen pro Schicht), desto höher ist der mögliche Abstraktionsgrad – und desto komplexere Sachverhalte können verarbeitet

⁶ Universität Ulm (2019): Constraint-Programmierung. <https://www.uni-ulm.de/in/pm/lehre/ss2019/cp/> (abgerufen am 18.06.2019).

⁷ Luber und Litzel (2019): Was ist ein Convolutional Neural Network? <https://www.bigdata-insider.de/was-ist-ein-convolutional-neural-network-a-801246/> (abgerufen am 17.06.2019).

⁸ Luber und Litzel (2017): Was ist ein Cyber-physisches System (CPS)? <https://www.bigdata-insider.de/was-ist-ein-cyber-physisches-system-cps-a-668494/> (abgerufen am 18.06.2019).

werden. Angewendet wird Deep Learning bei der Bild-, Sprach- und Objekterkennung sowie dem verstärkenden Lernen.

Dichteschätzung – Verfahren, das es erlaubt, eine Wahrscheinlichkeitsdichte zu schätzen. Mit einem Dichteschätzer kann beispielsweise das normale Verhalten einer Anlage modelliert werden. Testdaten mit geringem Dichtewert sind ungewöhnlich und können unter Umständen auf ein abnormales Verhalten der Anlage hinweisen.

Edge Devices – Jede Hardware, die den Datenfluss an der Grenze zwischen zwei Kommunikationsnetzwerken steuert. Edge Devices dienen im Wesentlichen als Zugang zum Kernnetz eines Unternehmens oder eines Service Providers. Gängige Funktionen sind die Weiterleitung, Verarbeitung, Überwachung, Filterung, Übersetzung und Speicherung von Daten, die zwischen Netzwerken übertragen werden.

Edge-Programmierung (englisch: Edge Computing) – Dezentrale Datenverarbeitung in einem verteilten System. Daten werden am Rand (edge) eines Kommunikationsnetzwerks verarbeitet, typischerweise also dort, wo sie entstanden sind. Dies kann etwa als Endgerät ein Smartphone oder beim autonomen Fahren ein einzelnes Auto sein. Im Unterschied zur Cloud-Programmierung müssen die Daten nicht erst zur Verarbeitung an ein zentrales Rechensystem zurückgeschickt werden. Dadurch wird eine Datenverarbeitung in Echtzeit möglich. Besonders sinnvoll eingesetzt werden kann diese IT-Architektur, wenn eine Echtzeitdatenverarbeitung notwendig ist, etwa beim autonomen Fahren.

Effiziente Suche – Da KI oft einen großen Raum möglicher Lösungen durchsuchen muss, ist die effiziente Gestaltung von Suchalgorithmen ein wichtiger Bestandteil von KI. Beispiele für effiziente Suchalgorithmen sind beispielsweise A* oder die Monte-Carlo-Baumsuche, die etwa beim verstärkenden Lernen eingesetzt werden kann.

Eingebettetes System (englisch: Embedded System) – Ein Computersystem, das in komplexe mikroelektronische bzw. mechatronische Systeme (Geräte, Anlagen und Maschinen etc.) eingebettet ist. Meist führt es eine einzelne Aufgabe aus, wie etwa die interaktive Steuerung bzw. Regelung des Systems. Eingebettete Systeme werden vielseitig eingesetzt, unter anderem in Haushaltsgeräten oder in der Automatisierungstechnik (Prozessregelung, Robotik, Bluetooth etc.).

Ensemble-Methoden – Methoden, die in der Statistik und für das maschinelle Lernen eingesetzt werden. Individuell geschulte Klassifikatoren werden bei der Vorhersage von neuen Ereignissen kombiniert. Das Resultat dieser Methode ist in der Regel deutlich genauer als die jedes einzelnen Klassifikators. Diese Methoden werden bei Visualisierungen, der Bild-, Sprach-, und Textverarbeitung eingesetzt.⁹

⁹ Optitz & Maclin (1999): „Popular Ensemble Methods: An Empirical Study“ in Journal of Artificial Intelligence Research 11 <https://jair.org/index.php/jair/article/view/10239/24370> (abgerufen am 18.06.2019).

Generative Adversarial Networks (GAN) – Neuronale Netzarchitektur, die aus zwei Netzwerken (Diskriminator, Generator) besteht und zum unüberwachten Lernen gehört. Ziel ist es zu erreichen, dass der Generator aus Trainingsdaten neue Daten erstellt, die vom Diskriminator nicht von den Trainingsdaten zu unterscheiden sind. Diese Architektur wird im Deep Learning beispielsweise angewendet, wenn eine hohe Anzahl an Trainingsdaten benötigt wird. In der Anwendung kann diese Architektur beispielsweise eigene Bilder aus einer Textbeschreibung erzeugen oder 3D-Modelle erstellen.¹⁰

GPU (englisch: Graphics Processing Unit; deutsch: Grafikprozessor) – Prozessor, der auf die Berechnung von Grafiken und Bilddaten spezialisiert und optimiert ist. Er wird in Computern, Servern, Smartphones, Spielekonsolen und Tablets eingesetzt. Grafikprozessoren finden häufig Anwendung bei Deep Learning, weil ihre Architektur die Beschleunigung dieser Lernverfahren erlaubt.

Max-Margin-Modelle (deutsch: Maximal-Rand) – Ein Bestandteil sogenannter Klassifizierungsmodelle des überwachten Lernens. Bei Klassifizierungsmethoden wie etwa Support-Vector-Maschinen werden Datensätze in Klassen (Kategorien) zusammengefasst, indem Muster und Zusammenhänge erkannt werden. Max-Margin-Modelle stellen sicher, dass unterschiedliche Klassen sich nicht überlappen. Sie sind effizient berechenbar und führen zu leistungsfähigen Klassifikatoren.

Merkmalsauswahl (englisch: Feature Selection) – Prozess, bei dem automatisch oder manuell die wichtigsten Merkmale ausgewählt werden. Irrelevante Merkmale in den Daten können die Genauigkeit der Modelle verringern und dazu führen, dass Modelle sich auf irrelevante Merkmale fokussieren.

Monte Carlo Tree Search (deutsch: Monte-Carlo-Baumsuche) – Suchalgorithmus, der versucht mit geringem Rechenaufwand und kurzer Laufzeit Lösungen zu finden. Bei der Monte-Carlo-Methode wird versucht, sich mit vielen zufälligen Verzweigungen in der Suche der Lösung eines Problems anzunähern. Je höher die Anzahl der zufälligen Verzweigungen ist, desto präziser ist auch das Ergebnis. Diese Methode kann Anwendung finden, wenn eine genaue Berechnung einer Lösung unmöglich oder sehr aufwendig ist.

Neural Variational Inference – Variational Inference (VI) ist eine deterministische Methode zur approximativen Inferenz in probabilistischen Modellen. Eine einfach zu berechnende Verteilung wird so optimiert, dass sie sich gut an die schwierig zu berechnende Verteilung anpasst und damit zur Inferenz herangezogen werden kann. Bei der neuronalen VI werden neuronale Netzwerke zur Darstellung der „einfachen“ Verteilung benutzt.

NLP (englisch: Natural Language Processing; deutsch: Verarbeitung natürlicher Sprache) – Teilgebiet der Informatik, Informationstechnik und Künstlichen Intelligenz,

¹⁰ Wiegand (2017): Eine Einführung in Generative Adversarial Network(GAN)
https://cogsys.uni-bamberg.de/teaching/ws1718/sem_m2/GAN-AndreasWiegand.pdf (abgerufen am 18.06.2019).

das sich mit der maschinellen Verarbeitung menschlicher Sprache befasst. Wichtige Themenfelder sind unter anderem das Erkennen, Verstehen und Generieren von natürlicher Sprache.

Online- und Datenstrom-Lernverfahren – Ein traditionelles Lernverfahren erstellt ein Modell aus statischen Eingabedateien. Bei neuen Trainingsdaten muss der Trainingsprozess des Modells von Grund auf neu gestartet werden. Es ist nicht in der Lage, sich in Echtzeit auf Verhaltensänderungen anzupassen. Demgegenüber kann ein Online-Lernverfahren ein Modell durch neue Trainingsdaten laufend anpassen, ohne den Trainingsprozess von Grund auf neu zu beginnen. Dies ist für viele Szenarien relevant, etwa bei sehr sensiblen oder personenbezogenen Trainingsdaten, die nicht offline verarbeitet werden dürfen (Gesundheitswerte) oder bei Datenströmen – ein im Voraus nicht absehbarer kontinuierlicher Datenstrom (z.B. Sensorgenerierte Daten wie Temperaturmessungen) –, die aufgrund ihrer Größe nicht gespeichert werden können.

Reinforcement Learning (deutsch: Verstärkendes Lernen) – Prozess, bei dem ein Lernendes System Entscheidungen trifft, auf deren Basis es anschließend handelt. Dabei lernt der Algorithmus, die Erfolgsaussichten der einzelnen Aktionen in den verschiedenen Situationen zunehmend besser einzuschätzen, indem er für die gewählten Aktionen positives oder negatives Feedback erhält. Ziel des Systems ist es, möglichst viel positives Feedback zu erhalten. Verstärkendes Lernen wird manchmal als biologisch plausibler eingeschätzt, im Vergleich zum überwachten Lernen. Beim Deep Reinforcement Learning kommen auch tiefe künstliche neuronale Netze zum Einsatz, womit bisher insbesondere in der Anwendung auf Gesellschaftsspiele bedeutende Erfolge erzielt wurden (z.B. Go, Poker, Atari).

Rekurrente Neuronale Netze – Oberbegriff für eine Gruppe von Netzwerkarchitekturen für zeitlich geordnete Daten. Solche Netzwerke haben eine Gedächtnisfunktion. Diese Funktion wird umgesetzt, indem Neuronen einer Schicht, die Aktivierung dieser Neuronen zu einem vorangegangenen Zeitpunkt berücksichtigen. Dadurch ist es möglich, Informationen bzw. Daten aus zeitlich weit auseinanderliegenden Beobachtungen im Training mit zu berücksichtigen. Die Architekturform eignet sich primär für die Analyse sequentieller Daten, wie etwa Sprache, Text oder Zeitreihendaten.

(Statistisches) Relationales Lernen – Relationales Lernen ist ein Unterbereich des maschinellen Lernens. Es findet Anwendung, wenn die Beziehungen zwischen Entitäten im Fokus stehen. Ein Beispiel ist die Modellierung eines sozialen Netzwerks. Eine besondere Bedeutung erhält das relationale Lernen durch die weite Verbreitung relationaler Datenbanken wie etwa in der Industrie. Eine moderne Repräsentation relationaler Daten sind Wissensgraphen (knowledge graphs). Relationales Lernen kommt zur Anwendung in der Textverarbeitung, Medizin, Robotik und Analyse von sozialen Netzwerken.

Self-Supervised Deep Networks – Self Supervised Learning beruht auf dem Lernprozess des überwachten Lernens und auf der gleichen Architektur wie tiefe, künstliche neuronale

Netze. Während beim überwachten Lernen jedoch die Kennzeichnung von Trainingsdaten (data label) manuell vorgegeben werden, werden diese beim Self Supervised Learning automatisch von der Anwendung generiert. Ein Beispiel eines solchen künstlichen neuronalen Netzes ist der Autoencoder¹¹, ein weiteres Beispiel ist die Zeitreihenvorhersage.

Tiefe Wahrscheinlichkeitsmodelle – Modelle aus der mathematischen Wahrscheinlichkeitstheorie, die mit dem Verfahren des tiefen Lernens trainiert werden und beispielsweise Unsicherheiten mit Wahrscheinlichkeitsverteilungen beschreiben können. Dies ist etwa in die Abschätzung der Vorhersagegüte, der Entscheidungsfindung, der Datenkompression oder dem Lernen mit fehlenden, begrenzten oder verrauschten Daten wichtig.¹²

TPU (englisch: Tensor Processing Unit) – Spezieller Chip, der von Google zur Optimierung von maschinellem Lernen und KI entwickelt wurde. Mit TPU kann das Training von neuronalen Netzwerken wesentlich beschleunigt werden. Die Chips werden etwa für die Google-Suche oder für Übersetzungen mit Google Translate angewendet.

Überwachtes Lernen – In diesem Lernverfahren werden dem Lernalgorithmen im Trainingsprozess sowohl der Input als auch der gewünschte Output vorgegeben. Soll der Algorithmus beispielsweise lernen, einen Hund von einem Wolf zu unterscheiden, erhält er Beispielbilder von Hunden und Wölfen. Im Lernprozess optimiert das System kontinuierlich das Modell, um Zuordnungen oder Vorhersagen zu verbessern. Im Einsatz werden die gelernten Modelle auf neue Daten angewendet. Überwachtes Lernen ist gegenwärtig die Grundlage der Mehrzahl erfolgreicher Anwendungen maschinellen Lernens.

Ultra-low power micro controller – Ein-Chip-Computersystem mit sehr geringem Stromverbrauch.

Unüberwachtes Lernen – Wenn im Training eines Modells die Zielgrößen (z.B. Klassifikationslabels) nicht zur Verfügung stehen, spricht man von unüberwachtem Lernen. Ziel kann es sein, in einem großen, unstrukturierten Datensatz interessante und relevante Muster zu erkennen oder die Daten kompakter zu repräsentieren. So können beispielsweise Kundendaten nach Zielgruppen segmentiert werden, die man auf ähnliche Weise adressieren möchte.

Verteiltes Rechnen / Verteiltes System – Netzwerk von mehreren physikalischen Recheneinheiten, die jedoch als ein einzelnes System ausgeführt werden. Im Gegensatz zu zentralisierten Systemen bieten verteilte Systeme den Vorteil der Skalierbarkeit, da weitere Recheneinheiten zu dem Netzwerk hinzugefügt werden können.

White-Box-Modell – Siehe Black-Box-Modell.

11 Pröve (2018): The Blurry Lines of Supervised and Unsupervised Learning
<https://towardsdatascience.com/the-blurry-lines-of-supervised-and-unsupervised-learning-b8a2aa04c8b0>
(abgerufen am 18.06.2019).

12 Ghahramani (2017): Probabilistic machine learning and AI
<https://www.microsoft.com/en-us/research/wp-content/uploads/2017/03/Ghahramani.pdf> (abgerufen am 18.06.2019).

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung



Impressum

Herausgeber

Lernende Systeme –
Die Plattform für Künstliche Intelligenz
Geschäftsstelle | c/o acatech
Karolinenplatz 4 | 80333 München
www.plattform-lernende-systeme.de

Gestaltung

PRpetuum GmbH, München

Stand

Juni 2019

Bildnachweis

Lia Koltyrina / Shutterstock | Titelbild

Bei Fragen oder Anmerkungen zu dieser
Publikation kontaktieren Sie bitte Johannes Winter
(Leiter der Geschäftsstelle):
kontakt@plattform-lernende-systeme.de

Folgen sie uns auf Twitter: @LernendeSysteme

Empfohlene Zitierweise

Kristian Kersting/Volker Tresp: Maschinelles und Tiefes
Lernen – Whitepaper aus der Plattform Lernende
Systeme, München 2019.

Dieses Werk ist urheberrechtlich geschützt.
Die dadurch begründeten Rechte, insbesondere die
der Übersetzung, des Nachdrucks, der Entnahme von
Abbildungen, der Wiedergabe auf fotomechanischem
oder ähnlichem Wege und der Speicherung in Daten-
verarbeitungsanlagen, bleiben – auch bei nur auszugs-
weiser Verwendung – vorbehalten.