

Materialien

Prof. Dr. Wolfram Burgard

Künstliche Intelligenz

Expertise für das WBGU-Hauptgutachten
„Unsere gemeinsame digitale Zukunft“

Berlin 2018

Künstliche Intelligenz

Wolfram Burgard

8. Januar 2018

Inhaltsverzeichnis

1	Einleitung	1
2	Maschinelles Lernen	4
2.1	Schlüsseltechnologie Big Data	5
2.2	Schlüsseltechnologie Deep Learning	6
3	Robotik	7
3.1	Schlüsseltechnologie Navigation	8
3.2	Schlüsseltechnologie Autonome Manipulation	9
4	Derzeitige und zukünftige Anwendungsfelder	10

1 Einleitung

Künstliche Intelligenz ist eine Disziplin innerhalb der Informatik, die sich mit der Generierung von Softwaresystemen befasst, welche Funktionen bereitstellen, deren Ausführung das erfordert, was typischerweise mit dem Wort Intelligenz bezeichnet wird. Dabei können diese Funktionen sowohl von reinen Software-Agenten als auch von physikalischen Systemen, beispielsweise Robotern oder auch selbstfahrende Autos ausgeführt werden.

Nachdem sich der Begriff Intelligenz nur sehr schwer definieren lässt, ist natürlich auch die Definition des Begriffs Künstliche Intelligenz entsprechend schwierig und es finden sich zahlreiche Definitionen in der Literatur [20, 17]. Es gibt einige Ansätze, die sich an menschlichem Verhalten oder Denken orientieren. Beispielsweise ist in diesem Kontext der von Alan Turing im Jahr 1950 eingeführte Turing-Test [25] anzusetzen, bei dem sich die vom System oder Roboter generierten Aktionen nicht von den von Menschen erzeugten unterscheiden

sollen. Ein solcher Turing-Test für Systeme, die mit dem Menschen interagieren, würde dann beispielsweise bedeuten, dass ein Mensch nicht mehr feststellen kann, ob der aktuelle Gesprächspartner am Telefon ein Mensch oder eine Software ist.

Die Mehrzahl aktueller KI-Systeme zielt jedoch darauf ab, rationales Denken oder rationales Handeln zu generieren. Zur Realisierung von Systemen, die rational denken, werden viele auf Logik basierende Repräsentationsformen und Schlussfolgerungssysteme eingesetzt. Die Grundannahme dabei ist, dass rationales Denken auch tatsächlich rationales Handeln nach sich zieht, wenn die verwendeten Schlussfolgerungsmechanismen korrekt sind. Eine weitere Gruppe von Definitionsansätzen befasst sich mit der direkten Generierung von rationalem Handeln. Dabei ist es nicht notwendig, dass die vom System verwendeten Repräsentationen vom Menschen lesbar oder durch den Menschen leicht verständlich sind. Vielmehr wird häufig eine Zielfunktion eingeführt, welche die Nützlichkeit von Zuständen beschreibt. Aufgabe des Systems ist es dann, diese Zielfunktion zu maximieren, d.h. den Zustand zu bestimmen, welcher die maximale Nützlichkeit hat. Wählt man beispielsweise bei einem Putzroboter die Sauberkeit der Arbeitsfläche minus der Kosten für die ausgeführten Aktionen als Zielfunktion, dann führt das im Idealfall dazu, dass der Roboter die optimalen Aktionen auswählt, um die Arbeitsfläche möglichst sauber zu halten. Hierin zeigt sich auch schon die Stärke des Ansatzes rationales Verhalten zu generieren gegenüber dem, menschliches Verhalten zu erzeugen. Ein nach rationalem Verhalten strebender Roboter kann einfach effektiver werden als einer, der lediglich menschliches Verhalten imitiert, denn Menschen zeigen leider nicht in allen Fällen das optimale Verhalten. Allerdings liegt darin natürlich auch ein Problem, denn die Interpretation der vom System gelernten Strukturen ist häufig nicht einfach, was eine Verifikation erschwert. Insbesondere bei sicherheitsrelevanten Systemen ist es aber häufig erforderlich, Nachweise über die Sicherheit beispielsweise der Steuerungssoftware zu führen. Dies kann allerdings sehr schwierig und im allgemeinen sogar nicht analytisch möglich sein, so dass man sich auf die Statistik berufen muss. Wahrscheinlich wird man beispielsweise bei selbstfahrenden Autos auf umfangreiche Feldtests zurückgreifen müssen, um die geforderte Sicherheit der Systeme nachweisen zu können.

Historisch geht der Begriff der Künstlichen Intelligenz auf das Jahr 1956 zurück, als sich auf einem Dartmouth Summer Research Project on Artificial Intelligence [14] genannten Sommerworkshop namhafte Wissenschaftler im US-Bundesstaat New Hampshire, USA, trafen, um über Künstliche Intelligenz zu diskutieren. Die grundlegende These war, dass jeder Aspekt von Lernen oder andere Eigenschaften der Intelligenz so präzise beschrieben werden können, dass man sie mit Hilfe von Maschinen simulieren kann. Darüber hinaus wollten die Teilnehmer darüber diskutieren, wie man Computer dazu bringen kann, Sprache zu verwenden, Konzepte zu abstrahieren oder einfach ihr eigenes Verhalten zu ver-

bessern. Dieses Treffen wird auch heute noch als äußerst erfolgreich eingestuft und hat zu einer großen Zahl von Aktivitäten im Bereich der Künstlichen Intelligenz geführt. Beispielsweise gab es in den achtziger Jahren des vergangenen Jahrhunderts einen beachtlichen Aufschwung in der KI. Dabei spielten Fragen der Wissensrepräsentation und Wissensverarbeitung eine wichtige Rolle. In diesem Kontext wurden beispielsweise die Expertensysteme populär [11]. Solche Systeme verwendeten einen großen Korpus von Wissen, beispielsweise in Form von Fakten und Regeln repräsentiert, um daraus Schlussfolgerungen zu ziehen und Problemlösungen anzubieten. Zwar gab es anfangs durchaus vielversprechende Erfolge mit den Expertensystemen, allerdings ließen die Erfolge dann doch recht stark nach, was zu einer so genannten Demystifizierung der Künstlichen Intelligenz geführt führte und den KI-Winter eingeleitete [6]. Erst als in den neunziger Jahren verstärkt mathematische und probabilistische Methoden Einzug hielten, konnte ein neuer Aufschwung verzeichnet werden. Ein prominenter Vertreter dieser Gruppe von Verfahren sind die Bayesian Networks [18]. Die aus dieser Technik resultierenden Systeme waren deutlich robuster als die auf symbolischen Techniken basierenden. In dieser Zeit startete auch der Einzug von Techniken des Maschinellen Lernens, die auf probabilistischen und mathematischen Konzepten basierten. Beispielsweise revolutionierten die Support-Vector-Machines [26] das maschinelle Lernen. Sie galten bis vor wenigen Jahren als einer der performantesten Ansätze für Klassifikationsprobleme. Dies strahlte auch auf andere Bereiche aus, beispielsweise die Mustererkennung und die Bildverarbeitung. Techniken der Gesichtserkennung und auch Spracherkennung hielten Einzug in Produkte, die wir im täglichen Leben verwenden, wie beispielsweise Kameras oder auch Mobiltelefone. Kameras können automatisch Gesichter erkennen und Mobiltelefone können per Sprache gesteuert werden. Auch im Automobil gibt es Anwendungen dieser Methoden, beispielsweise wenn Komponenten per Sprache gesteuert werden können. Allerdings gibt es auch grundlegende Resultate aus frühen Zeiten der Künstlichen Intelligenz, die einen grundlegenden Einfluss auf heutige Produkte haben. Hierzu gehört beispielsweise die Fähigkeit von Navigationssystemen, kürzeste Wege zu planen [10] und uns effektiv auf der Basis von gegebenen Karten zu unserem Zielpunkt zu navigieren. Dieselben Ansätze spielen übrigens auch in Computerspielen eine maßgebliche Rolle, vor allem dann, wenn es darum geht intelligente Systeme zu simulieren, die effektiv in der virtuellen Umgebung navigieren können. Gleichzeitig gab es auch in der Robotik einen Paradigmenwechsel. Die probabilistischen Methoden hatten insbesondere auf die Navigation von mobilen Robotern einen maßgeblichen Einfluss und heute ist es Dank dieser Entwicklung wohlverstanden, wie man mobile Systeme bauen kann, die sich autonom in ihrer Umgebung bewegen. Das hat auch aktuell einen wichtigen Einfluss auf verschiedene Bereiche, wie beispielsweise selbstfahrende Autos oder Transportsysteme in der Logistik, bei denen in den nächsten Jahren umfangreiche In-

novationen zu erwarten sind.

Seit wenigen Jahren gelten insbesondere die Bereiche Maschinelles Lernen und Robotik als besonders vielversprechend, was insbesondere auf den Schlüsselfeldern Big Data, Deep Learning und autonome Navigation und Manipulation beruht.

2 Maschinelles Lernen

Im Maschinellen Lernen geht es typischerweise darum, Algorithmen zu entwickeln, die die Performanz von Verfahren auf der Basis von Daten oder Beispielen und ohne explizite Programmierung verbessern [16]. Eines der typischen Beispiele des Maschinellen Lernens ist das der Klassifikation. Hierbei wird das System mit einer Menge von Beispielen und ihren entsprechenden Klassen konfrontiert. Das System muss nun eine Abbildung lernen, welche die Eigenschaften oder Attribute der Beispiele auf die entsprechenden Klassen abbildet mit dem Ziel, den Klassifikationsfehler zu minimieren. Nun könnte man sich natürlich einfach alle Beispiele merken, was den Klassifikationsfehler automatisch minimiert, allerdings würde ein solches Verfahren sehr viel Platz benötigen und darüber hinaus schlecht auf bis dahin nicht gesehene Beispiele generalisieren. Es kann im Prinzip lediglich raten. Ziel des Maschinellen Lernens ist es nun, eine kompakte Funktion zu lernen, die möglichst gut auf nicht gesehene Beispiele generalisiert. Im Kontext der Klassifikation sind beispielsweise Entscheidungsbäume (Decision Trees), Random Forests, eine Verallgemeinerung davon, Support Vector Machines oder Boosting. Diese Ansätze gelten als überwachtes Lernen, weil dem Lerner stets die Beispiele einschließlich ihrer Klassen gegeben werden. Ein weiteres, populäres Problem des überwachten Lernens ist die Regression. Dabei wird dem System eine Menge von Punkten einer Funktion gegeben mit der Aufgabe eine Funktion zu bestimmen, welche die gegebenen Messpunkte möglichst gut approximiert. Auch hier ist man wieder an möglichst kompakten Funktionen interessiert, die den Approximationsfehler minimieren. Darüber hinaus gibt es auch das unüberwachte Lernen, bei dem man eine Funktion sucht, welche die gegebenen Daten möglichst gut erklärt. Ein typisches unüberwachtes Lernproblem stellt das Clustering dar, bei dem man die für eine Menge von Punkten in der Ebene Zentren sucht derart, dass die summe der quadratischen Abstände aller Punkte von ihrem nächsten Zentrum minimiert wird. Überwachte Lernprobleme treten in der Praxis sehr häufig auf. Betrachten wir beispielsweise das Problem der Gesichtsklassifikation. Hier geht es darum für ein in einem Bild gefundenen Gesicht den Namen der Person zuzuordnen. Solche Daten stehen Unternehmen, welche soziale Netzwerke zur Verfügung stellen, wie beispielsweise Facebook massenhaft in großen Massen zur Verfügung. Benutzer können in Facebook nicht nur Gesichter markieren, son-

den diesen markierten Gesichtern auch noch den Namen ihrer Freunde zuordnen. Auf diese Weise entsteht eine riesige Datenmenge von Bildern in denen Gesichter markiert und auch mit Labeln versehen sind. Damit können jetzt überwachte Lernverfahren eingesetzt werden, um (a) Gesichter in Bildern zu identifizieren und (b) die gefundenen Gesichter Personen zuzuordnen. Dadurch, dass die Klassifikatoren gut generalisieren, können sie anschließend auch auf bisher noch nicht gesehene Gesichter angewendet werden und liefern heutzutage erstaunlich gute Ergebnisse.

Tatsächlich stellt die Akquisition von großen Korpora annotierter Daten eines der Hauptprobleme im Kontext des Big Data und Deep Learning dar. Die großen Internetfirmen unternehmen in großem Stil Anstrengungen, um massive Korpora an annotierten Daten zu erhalten. Ein Beispiel hierfür stellen so genannte CAPTCHAs (Completely Automated Public Turing test to tell Computers and Humans Apart) dar [2]. Solchen CAPTCHAs ist schon fast jeder einmal begegnet, der im Internet ein Benutzerkonto anlegen wollte. Typischerweise wollen die Diensteanbieter sicherstellen, dass die Benutzerkonten nicht massenhaft durch Computerprogramme registriert werden. Deswegen werden den Antragstellern Bilder von verzerrten Texten präsentiert, die mit Scannern und optischer Buchstabenkennung kaum erkannt werden können. Da die Bilder nun durch Programme schwer zu erkennen sind, sind sie ideal geeignet um Menschen von Computerprogrammen oder Bots zu unterscheiden. Haben die Menschen die Bilder annotiert, können wiederum Lernverfahren eingesetzt werden um auch diese harten Probleme zu lösen und optische Zeichenerkennung weiter zu verbessern. Gleichzeitig kann sichergestellt werden, dass die Computerprogramme stets die schwersten Probleme vorgesetzt bekommen, die selbst durch die besten Verfahren noch nicht zu lösen sind.

2.1 Schlüsseltechnologie Big Data

Weltweit wird die Gesamtzahl des zur Verfügung stehenden Speicherplatzes derzeit ca. 20 Zettabyte (1 Zettabyte = 10^{21} Byte = 10^9 Terabyte) geschätzt [21]. Andere Quellen schätzen den Datentransfer im Internet auf ca. 26 Terabyte pro Sekunde [4]. Vorhersagen sind natürlich immer mit großen Unsicherheiten behaftet. Schätzungen der International Data Corporation gehen davon aus, dass die Gesamtmenge bis 2025 auf 160 Zettabyte anwachsen und damit geschätzt zehnfachen wird. Andere Quellen sagen eine jährliche Verdoppelung vorher. Die Anzahl der durch Suchmaschinen indizierten Web-Seiten ist enorm. Google hatte vor fast 10 Jahren angekündigt, dass sie 10^{12} verschiedene URLs (Uniform Resource Locator, Referenz auf eine Ressource im World Wide Web) indiziert haben [9]. Auch wenn diese Zahlen teilweise auf Schätzungen beruhen und daher mit Vorsicht zu behandeln sind, insbesondere hinsichtlich der Vorhersagen für die

Zukunft, machen sie deutlich, dass im World Wide Web riesige Datenmengen zur Verfügung stehen. Dadurch entsteht ein enormes Potential an Daten, die nicht nur den Menschen, sondern auch Diensteanbietern, wie beispielsweise Apple, Facebook, Amazon, Google, und vielen anderen zur Verfügung stehen, um daraus mit entsprechenden Verfahren aus der Künstlichen Intelligenz Dienste anzubieten die in anderen Kontexten hilfreich für den Menschen sind. Ein Hauptproblem hierbei stellt allerdings die Bereitstellung der Daten dar. Daten sind nicht in allen Fällen hilfreich. Sie werden es in der Regel erst dadurch, dass Menschen sie annotieren und ihnen eine Bedeutung zuordnen. Durch den Einsatz von Lernverfahren können dann auch bisher noch nicht gesehene Bilder annotiert werden. Die entsprechenden Techniken hierfür werden in den folgenden Abschnitten vorgestellt. Wir werden auch diskutieren, mit welchen Methoden diese annotierten Daten generiert werden können.

2.2 Schlüsseltechnologie Deep Learning

Deep Learning [3, 13] ist eine vor wenigen Jahren entstandene Technik, die aus massiven Datenmengen lernen kann, um effektive Lösungen für eine Vielzahl von Problemen des Maschinellen Lernens zu bieten. Eine der populärsten Ansätze sind die so genannten tiefen neuronalen Netze. Sie basieren auf den neuronalen Netzen, deren Einführung auf Warren McCulloch and Walter Pitts im Jahr 1943 [15] zurückgeht. Damals hat man versucht, die Funktionsweise von Neuronen des Gehirns durch elektronische Schaltkreise nachzubauen, was zu den künstlichen neuronalen Netzen führte. Die Grundidee lag darin, ein Netzwerk bestehend aus miteinander verbundenen Schichten von Knoten aufzubauen. Dabei gilt die unterste Schicht als Eingabeschicht und die oberste Schicht als Ausgabeschicht. Jeder Knoten führt nun eine einfache Berechnungsvorschrift aus, beispielsweise eine einfache Schwellwert-Entscheidung. Die Ausgaben der einzelnen Knoten einer Schicht werden dann mittels gewichteter Summen an die Knoten der nächsten Schicht weitergereicht. Diese Netze waren bereits äußerst erfolgreich und brachten beeindruckende Erfolge beispielsweise im Bereich der optischen Buchstabenerkennung mit sich. Es gab allerdings auch damals bereits schon auch aus heutiger Sicht wegweisende Erfolge, beispielsweise im No Hands Across America Projekt [23], in dem ein Minivan zu großen Teilen autonom und mitunter von einem neuronalen Netzwerk gesteuert von der Westküste zur Ostküste der USA navigierte. Bis zur Mitte der 80 Jahre des vergangenen Jahrhunderts spielten die künstlichen, neuronalen Netze eine nicht unerhebliche Rolle im Machine Learning, bis sie dann schließlich durch probabilistische Methoden, zum Beispiel Bayes'sche Netzwerke [18], Support Vector Machines [26] oder Gaussian Processes [19], abgelöst wurden. Diese Techniken haben das Maschinelle Lernen für mehr als ein Jahrzehnt dominiert und auch zu zahlreichen Anwendungen

geführt, beispielsweise in der Bildverarbeitung, der Spracherkennung oder auch der Mensch-Maschine-Interaktion. Sie wurden allerdings kürzlich durch die so genannten tiefen neuronalen Netze abgelöst, die sich dadurch auszeichnen, dass sie eine massive Anzahl von Schichten haben, die effektiv auf moderner Hardware, beispielsweise Grafikkarten, trainiert werden können. Diese tiefen Netzwerke lernen auf den einzelnen Schichten Repräsentationen der Daten auf unterschiedlichen Abstraktionsleveln. Insbesondere in Verbindung mit großen Datenmengen (Big Data) können diese Netzwerke mit Hilfe effizienter Algorithmen wie Backpropagation die Parameter in einer einzelnen Schicht auf der Basis der vorangegangenen Schicht optimieren um Strukturen in Daten zu erkennen. Tiefe neuronale Netze haben zu enormen Erfolgen geführt, beispielsweise in der Bild-, Video oder Sprachverarbeitung. Aber auch in anderen Aufgaben wurden sie mit großem Erfolg eingesetzt, beispielsweise im Kontext der Objekterkennung oder der Interpretation von Tiefendaten. Die tiefen neuronalen Netze konnten ihre Fähigkeit eindrücklich unter Beweis stellen bei ihrer Anwendung innerhalb von AlphaGo, einem Computerprogramm, welches Lee Sidol, einen der besten Go-Spieler der Welt im Go besiegte [22]. Dies ist deswegen hervorzuheben, weil es bis vor wenigen Jahren als unwahrscheinlich galt, dass Go-Programme in absehbarer Zeit auf einem solchen Level spielen können.

3 Robotik

Die Robotik ist eine eigentlich eigenständige wissenschaftliche Disziplin, die sich mit der Konstruktion von physikalischen Agenten (Robotersystemen) befasst, die in der realen Welt Aufgaben ausführen. Anwendungsfelder der Robotik sind vielfältig. Neben klassischen Themen wie der Manipulation im industriellen Umfeld sind in der jüngeren Vergangenheit zunehmend weitere Anwendungsfelder in den Vordergrund gerückt, beispielsweise die Pfadplanung, die Positionsschätzung, die Kartierung oder die Navigation. Letztere sind insbesondere für Transportaufgaben relevant. Kombiniert man nun mobile Manipulatoren mit navigierenden Plattformen, so erhält man mobile Manipulationssysteme, die eine besondere Rolle im Kontext zukünftiger Produktionsprozesse spielen können. Produktionsprozesse können mit diesen flexibel rekonfiguriert werden und durch die Integration von Manipulation und Transport können effektivere Prozesse entstehen. Um dies zu erreichen sind verschiedene Schlüsselkompetenzen erforderlich, die teilweise bereits verfügbar sind oder sich auf einem Qualitätslevel befinden, welches für ein Produktionsumfeld ausreichend ist, was die Attraktivität dieser Technologie in den vergangenen Jahren deutlich erhöht hat.

3.1 Schlüsseltechnologie Navigation

Mobile Roboter müssen in ihren Umgebungen effektiv navigieren können um verschiedene Aufgaben effektiv erfüllen zu können. Betrachten wir beispielsweise einen Staubsaugerroboter oder einen robotischen Rasenmäher. Die meisten der heutigen Systeme erledigen ihre Arbeit, indem sie im Wesentlichen zufällig navigieren. Dadurch steigt mit fortschreitender Zeit die Wahrscheinlichkeit, dass der Roboter jeden Punkt in seinem Umfeld einmal angefahren hat, so dass die Aufgabe zwar nie garantiert aber doch mit großer Wahrscheinlichkeit erfüllt ist, wenn man nur hinreichend lange wartet. Offensichtlich ist ein solches Vorgehen nicht optimal im Kontext von Transportrobotern, die ein Objekt möglichst rasch von der Aufnahme-Position zum Ziel bringen sollen. Um eine solche Aufgabe effektiver zu gestalten, bedarf es mehrerer Komponenten. Zunächst muss der Roboter eine Pfadplanungskomponente besitzen, die es ihm erlaubt auf möglichst kurzem Weg von seiner aktuellen Position zum Zielpunkt zu gelangen. Verfahren hierzu stammen unter anderem auch aus der Künstlichen Intelligenz und basieren beispielsweise auf dem klassischen, dort entwickelten A^* -Algorithmus für die optimale Berechnung kürzester Wege [10]. Hierzu verwenden Robotersysteme typischerweise Karten. Eine Möglichkeit ist, in diesen Karten direkt das Wegenetz zu spezifizieren. Alternativ kann man die Karten auch so wählen, dass sie die Umgebung des Roboters in Freiraum und Hindernisse einteilt um daraus mögliche Wege zu berechnen. Allerdings kann der Roboter nur unter sehr starken Einschränkungen annehmen, dass der einmal geplante Weg tatsächlich auch frei von Hindernissen ist. Das gilt insbesondere dann, wenn der Roboter sich in einer dynamischen und von Menschen genutzten Umgebung befindet. Gerade in echten Umgebungen muss man davon ausgehen, dass Türen geschlossen sein können, sich Hindernisse auf dem geplanten Pfad befinden oder dass die Umgebung ggf. verändert und die Karte daher nicht mehr gültig ist. Hierzu gibt es jetzt verschiedene Lösungsansätze. Zunächst muss man den Roboter mit Sensoren ausstatten, die es ihm erlauben, den Abstand zu Hindernissen zu messen und so Hindernissen ausweichen zu können. Dies geschieht typischerweise mit einer weiteren Komponente, die Kollisionen vermeidet und dynamische Anpassungen an dem zuvor geplanten Pfad vornimmt. Um tatsächlich entlang eines geplanten Pfades navigieren zu können, muss der Roboter tatsächlich in der Lage sein, seine Position in der Karte und auf dem geplanten Pfad (oder den Abstand davon) präzise bestimmen zu können. Hierzu verwenden heutige Navigationssysteme für Roboter spezielle Algorithmen, denen probabilistische Prinzipien zu Grunde liegen [24], wie beispielsweise den Kalman-Filter [12] oder den Partikel-Filter-Algorithmus [7]. Beide Ansätze und ihre Varianten haben sich als äußerst robust herausgestellt um auf der Basis der Abstände zu Hindernissen, die mit dem Abstandssensor ermittelt werden, und der gegebenen Hinderniskarte eine Wahrscheinlichkeitsverteilung für die Position des

Fahrzeugs. Auf der Basis dieser Verteilung bestimmt man dann typischerweise die wahrscheinlichste Position des Roboters oder Fahrzeugs. Diese Verfahren liegen im Prinzip allen autonom fahrenden Fahrzeugen, die nicht durch Induktionsschleifen, optische Marker oder Linien geführt werden, zu Grunde. Eine Grundvoraussetzung für beide zuletzt besprochenen Komponenten ist die Existenz einer Karte. Aber wie kann ein Roboter an eine solche Hinderniskarte kommen? Im Prinzip gibt es hierfür zwei Lösungsmöglichkeiten. Zunächst kann der Benutzer die Umgebung ausmessen und daraus eine Karte mit den exakten Positionen aller Objekte im Arbeitsraum des Roboters erstellen. Diese Karte kann dann anschließend genutzt werden, um die Position des Vehikels zu berechnen oder Pfade in der Umgebung zu berechnen. Die Alternative ist der Einsatz eines so genannten SLAM-Verfahrens (Simultaneous Localization and Mapping) [24]. Dabei wird der Roboter durch seine Umgebung gesteuert und er berechnet die Karte aufgrund des gefahrenen Weges und der vom Sensor erhaltenen Abstandsdaten automatisch. Diese SLAM-Technik ist übrigens auch in der Photogrammetrie bekannt und wird auch dort für die Erzeugung von Karten auf der Basis von Messungen verwendet [1]. Diese vier Komponenten: Pfadplanung, Kollisionsvermeidung und Neuplanung, Lokalisierung und SLAM für die Kartenerstellung sind der Schlüssel für die heutigen Navigationsroboter und auch selbstfahrende Autos.

3.2 Schlüsseltechnologie Autonome Manipulation

Die Manipulation konnte in der Vergangenheit erfolgreich wurde in Produktionsprozessen eingesetzt werden. Allerdings hatten diese Roboter stets fest programmierte Aktionen und darüber hinaus einen Käfig um sich, um zu verhindern, dass Menschen in den Aktionsraum des Roboters eintreten. Letzteres war erforderlich, weil die Roboter nicht über Sensorik verfügten um ihren Arbeitsraum zu überwachen. Mit moderner Sensortechnik können die Arbeitsbereiche von Robotersysteme jedoch sicher überwacht werden. Betritt eine Person den Arbeitsbereich, wird der Roboter entweder ausgeschaltet oder so stark verlangsamt, dass keine Gefahr mehr von ihm ausgeht. Darüber hinaus gibt es heute bereits Robotersysteme, welche die zu manipulierenden Objekte mit Hilfe von Kameras oder Abstandsdaten erkennen und so flexibler agieren können. Der von der Firma Rethink Robotics vertriebene Roboter Baxter ist ein bereits auf dem Markt verfügbares System, das durch den Anwender flexibel programmiert werden kann, um einfache Manipulationsaufgaben auszuführen. Insbesondere die Entwicklung hin zu leichtgewichtigen Systemen mit einer Vielzahl von Endeffektoren wird zu einer deutlichen Flexibilisierung von robotischen Manipulationsprozessen führen.

4 Derzeitige und zukünftige Anwendungsfelder

Wie oben bereits angedeutet, hält die Künstliche Intelligenz derzeit in zunehmendem Maße Einzug in unserer tägliches Leben. Dies betrifft sowohl unser privates als auch unser berufliches Leben. Wichtige Transporteure der Künstlichen Intelligenz in unser Leben stellen die Smartphones dar. Zahlreiche Funktionen basieren auf Methoden der Künstlichen Intelligenz. Beispielsweise können wir sie bereits per Sprache steuern, sie erkennen Gesichter in Bildern, sie speichern wichtige Informationen für uns, beispielsweise, wo unser Fahrzeug geparkt ist, und sie spielen Musik, die uns gefällt, nachdem sie unsere Musikbibliothek analysiert haben oder aus unseren Bewertungen von Musikstücken lernen, was uns gefällt. Durch Analysen dieser Präferenzen in Verbindung mit denen anderer Nutzer werden die Vorhersagen von Stücken, die uns gefallen, immer besser. Das lässt sich natürlich auch auf andere Dinge übertragen, beispielsweise das Einkaufen, bei dem uns die Einkaufsplattformen mögliche Produkte vorschlagen, an denen wir interessiert sein könnten. Bekannt ist das natürlich schon lange von Suchmaschinen, die versuchen, uns die Antworten so zu präsentieren, dass sie möglichst dem von uns tatsächlich gesuchten Web-Seiten entsprechen. In der Robotik sind die aktuellen Schlüsselfelder die Logistik und die flexible Produktion (Industrie 4.0). Um wettbewerbsfähig zu bleiben, müssen die Unternehmen die Produktionsprozesse weiter optimieren. Hier werden mobile Roboter und flexible Manipulationssysteme, die mit dem Menschen kooperieren können, eine maßgeblich Rolle spielen. Dadurch ergeben sich deutlich flexiblere Produktionsprozesse, die für den Wirtschaftsstandort Deutschland von enormer Bedeutung sein können.

Bis 2030 wird die Künstliche Intelligenz in weitere Bereiche vordringen. Wir werden nicht nur erleben, dass in der Produktion Roboter immer anspruchsvollere Tätigkeiten ausüben werden. Die Techniken der Künstlichen Intelligenz werden auch in Bereichen von Menschen mit einer hochqualifizierten Ausbildung Einzug halten. Beispielsweise gab es kürzlich eine Veröffentlichung in der Zeitschrift Nature, in der ein System vorgestellt wurde, welches auf der Basis von mit dem Mobiltelefon aufgenommenen Bildern der Haut diagnostizieren konnte, ob in dem Bild ein Hautkrebs zu sehen ist oder nicht [5]. Das Interessante an dieser Arbeit ist, dass die Autoren mit ihrem auf Deep Neural Networks basierenden System tatsächlich die Erkennungsrate von Dermatologen erreichen konnten. Dies zeigt deutlich auf, dass in der Künstlichen Intelligenz ein enormes Potential steckt, um auch Prozesse, die eine hohe Expertise erfordern, weiter zu optimieren.

Insgesamt steckt in der Weiterentwicklung der Künstlichen Intelligenz und der damit verbundenen fortschreitenden Digitalisierung ein enormes Potential. Natürlich geht davon auch eine Gefährdung für ein breites Spektrum von Arbeitsplätzen aus. Bereits im Jahr 2013 schätzten Frey and Osborne [8] die Wahrscheinlichkeit, dass in den nächsten ein bis zwei Jahrzehnten in den USA Ar-

beitstätigkeiten von Computern ausgeführt werden, und kamen zu dem Schluss, dass innerhalb dieses Zeitraums wahrscheinlich 50% der derzeitigen Arbeitsplätze davon bedroht sind. Bis heute waren davon im Wesentlichen die unteren Einkommensschichten betroffen. Je besser Computer und Roboter hinsichtlich der Wahrnehmung und Klassifikation werden, desto mehr werden auch solche Arbeitstätigkeiten automatisierbar, die höhere intellektuelle Leistungen erfordern, wie beispielsweise das Taxi fahren, Manipulationsaufgaben in der Fertigung oder sogar Klassifikationsaufgaben (zum Beispiel in der medizinischen Diagnostik). Um unsere Gesellschaft auf diesen Wandel optimal vorzubereiten und bei diesem Wandel Schritt halten zu können, benötigt es natürlich Initiativen für die Digitalisierung aber in gleichem Maße auch Angebote für die Weiterbildung der Bevölkerung und darüber hinaus auch eine entsprechende Begleitung unter ethischen Gesichtspunkten.

Literatur

- [1] P. Agarwal, W. Burgard, and C. Stachniss. A survey of geodetic approaches to mapping and the relationship to graph-based SLAM. *IEEE Robotics and Automation Magazine*, September 2014.
- [2] Luis Von Ahn, Manuel Blum, Nicholas J. Hopper, and John Langford. CAPTCHA: Using hard AI problems for security. In *Proceedings of the 22Nd International Conference on Theory and Applications of Cryptographic Techniques*, EUROCRYPT'03, pages 294–311, Berlin, Heidelberg, 2003. Springer-Verlag.
- [3] Itamar Arel, Derek C. Rose, and Thomas P. Karnowski. Research frontier: Deep machine learning—a new frontier in artificial intelligence research. *IEEE Computational Intelligence Magazine*, 5(4):13–18, 2010.
- [4] Cisco. The zettabyte era: Trends and analysis. <https://www.cisco.com/c/en/us/solutions/collateral/service-provider/visual-networking-index-vni/vni-hyperconnectivity-wp.html>, 7 2017. Accessed: 2017-12-31.
- [5] Andre Esteva, Brett Kuprel, Roberto A. Novoa, Justin Ko, Susan M. Swetter, Helen M. Blau, and Sebastian Thrun. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639):115–118, 2017.




Abbildung 1: Einfluss der Digitalisierung auf verschiedene Branchen in den USA nach einer Schätzung von Frey and Osborne aus dem Jahr 2013 [8]. Die Gesamtfläche entspricht der Gesamtbeschäftigung. Es wird geschätzt, dass 47% der existierenden Tätigkeiten mit hoher Wahrscheinlichkeit von einer Computerisierung bedroht sind.

- [6] Ethan Fast and Eric Horvitz. Long-term trends in the public perception of Artificial Intelligence. In *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI)*, 2017.
- [7] Dieter Fox, Wolfram Burgard, Frank Dellaert, and Sebastian Thrun. Monte carlo localization: Efficient position estimation for mobile robots. In *Proceedings of the Sixteenth National Conference on Artificial Intelligence (AAAI)*, pages 343–349, 1999.
- [8] Carl Benedict Frey and Michael Osborne. The future of employment. Technical report, The University of Oxford, 2013. published by the Oxford Martin Programme on Technology and Employment.
- [9] Google. We knew the web was big... <https://googleblog.blogspot.de/2008/07/we-knew-web-was-big.html>. Accessed: 2017-12-31.
- [10] Peter E. Hart, Nils J. Nilsson, and Bertram Raphael. A formal basis for the heuristic determination of minimum cost paths. *IEEE Transactions on Systems Science and Cybernetics*, 4(2):100–107, December 1968.
- [11] Frederick Hayes-Roth, Donald A. Waterman, and Douglas B. Lenat. *Building Expert Systems*. Addison-Wesley Longman Publishing Co., Inc., 1983.
- [12] R.E. Kalman. A new approach to linear filtering and prediction problems. *ASME-Journal of Basic Engineering*, March:35–45, 1960.
- [13] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *Nature*, 521:436–444, 2015.
- [14] John McCarthy, Marvin Minsky, Nathaniel Rochester, and Claude E. Shannon. A proposal for the Dartmouth summer research project on Artificial Intelligence, august 31, 1955. *AI Magazine*, 27(4):12–14, 2006.
- [15] Warren S. McCulloch and Walter H. Pitts. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:115–133, 1943.
- [16] Thomas M. Mitchell. *Machine Learning*. McGraw-Hill, Inc., 1997.
- [17] Nils J. Nilsson. *Artificial Intelligence: A New Synthesis*. Morgan Kaufmann Publishers Inc., 1998.
- [18] Judea Pearl. *Causality: Models, Reasoning and Inference*. Cambridge University Press, New York, NY, USA, 2nd edition, 2009.

- [19] Carl Edward Rasmussen and Christopher K. I. Williams. *Gaussian Processes for Machine Learning (Adaptive Computation and Machine Learning)*. The MIT Press, 2005.
- [20] S. Russell and P. Norvig. *Artificial Intelligence: A Modern Approach*. Series in Artificial Intelligence. Prentice Hall, third edition, 2010.
- [21] Seagate. Data age 2025: The evolution of data to life-critical. <https://www.seagate.com/files/www-content/our-story/trends/files/Seagate-WP-DataAge2025-March-2017.pdf>. Accessed: 2017-12-31.
- [22] David Silver, Aja Huang, Christopher J. Maddison, Arthur Guez, Laurent Sifre, George van den Driessche, Julian Schrittwieser, Ioannis Antonoglou, Veda Panneershelvam, Marc Lanctot, Sander Dieleman, Dominik Grewe, John Nham, Nal Kalchbrenner, Ilya Sutskever, Timothy Lillicrap, Madeleine Leach, Koray Kavukcuoglu, Thore Graepel, and Demis Hassabis. Mastering the game of go with deep neural networks and tree search. *Nature*, 529:484–503, 2016.
- [23] Chuck Thorpe, Martial Hebert, Takeo Kanade, and Steven Shafer. Toward autonomous driving: The cmu navlab. part i: Perception. 6(4):31 – 42, August 1991.
- [24] S. Thrun, W. Burgard, and D. Fox. *Probabilistic Robotics*. MIT Press, 2005.
- [25] A. Turing. Computing machinery and intelligence. *Mind*, 59:433–460, 1950.
- [26] Vladimir N. Vapnik. *Statistical Learning Theory*. Wiley-Interscience, 1998.

Externe Expertise für das WBGU-Hauptgutachten „Unsere gemeinsame digitale Zukunft“

Berlin: WBGU

Verfügbar im Internet unter www.wbgu.de/de/publikationen/publikation/unsere-gemeinsame-digitale-zukunft#sektion-expertisen

Autor: Prof. Dr. Wolfram Burgard

Albert-Ludwigs-Universität Freiburg, Technische Fakultät, Autonome Intelligente Systeme

Titel: Künstliche Intelligenz

Berlin, 2018

**Wissenschaftlicher Beirat der Bundesregierung
Globale Umweltveränderungen (WBGU)**

Geschäftsstelle
Luisenstraße 46
10117 Berlin

Telefon: (030) 26 39 48 0
E-Mail: wbgu@wbgu.de
Internet: www.wbgu.de
🐦@WBGU_Council

Alle Gutachten können von der Internet-Webseite
<https://www.wbgu.de/de/publikationen/alle-publikationen>
heruntergeladen werden.

© 2019, WBGU