



Ein Beitrag zur Künstliche Intelligenz - A Contribution to Artificial Intelligence

Authors: Hans Burkhardt
Submitted: 3. April 2023
Published: 3. April 2023
Volume: 10
Issue: 2
Affiliation: Institute for Computer Science, University of Freiburg, Germany
Languages: German
Keywords: Artificial Intelligence, Machine Learning, Neural Networks, Deep Learning, Robotics, Automation, Big Data, Ethics, Future Perspectives,
Categories: News and Views, Artificial Intelligence, Modeling and Simulation
DOI: 10.17160/josha.10.2.892

Abstract:

This paper will not be able to cover the subject comprehensively, rather it will highlight and explain major lines of thought in Artificial Intelligence (AI). Mathematics will be largely avoided. The paper describes the elementary working principles of today's AI, points to a number of successful applications, and presents perspectives for the future. This paper was previously published in Ordnung der Wissenschaft (OdW) Issue 02/2023 (https://ordnungderwissenschaft.de/wp-content/uploads/2023/03/02_02_Burkhardt.pdf).

JOSHA

josha.org

**Journal of Science,
Humanities and Arts**

JOSHA is a service that helps scholars, researchers, and students discover, use, and build upon a wide range of content



Ein Beitrag zur Künstliche Intelligenz – A Contribution to Artificial Intelligence

Hans Burkhardt

burkhardt@cs.uni-freiburg.de

Institute for Computer Science, University of Freiburg, Germany

Abstract

This paper will not be able to cover the subject comprehensively¹, rather it will highlight and explain major lines of thought in Artificial Intelligence (AI).

Mathematics will be largely avoided. The paper describes the elementary working principles of today's AI, points to a number of successful applications, and presents perspectives for the future. This paper was previously published in *Ordnung der Wissenschaft (OdW) Issue 02/2023*

(https://ordnungderwissenschaft.de/wp-content/uploads/2023/03/02_02_Burkhardt.pdf).

¹ 2021 Study Panel Report der Stanford University „The One Hundred Year Study on Artificial Intelligence (AI100)“, umfasst 82 Seiten.



Dieser Aufsatz wird nicht in der Lage sein, das Thema umfassend zu behandeln,¹ vielmehr werden wesentliche Gedankenansätze der Künstlichen Intelligenz (KI) beleuchtet und erläutert. Auf Mathematik wird weitgehend verzichtet. Der Beitrag zeigt die elementaren Wirkprinzipien heutiger KI auf, verweist auf eine Reihe erfolgreicher Anwendungen und zeigt Perspektiven für die Zukunft auf.

I. Was ist künstliche Intelligenz?

Die Vision, dass Maschinen eines Tages sprechen, abstrakte Konzepte bilden, die gleichen Probleme wie Menschen lösen und sich ständig verbessern, führte 1956 zur Gründung des Forschungsgebiets Künstliche Intelligenz (KI). Es war schon immer ein Traum der Informatiker, dass man mit einem Computer intelligentere Dinge tun kann als nur Zahlen zu addieren und zu multiplizieren.

Künstliche Intelligenz (KI, engl. artificial intelligence oder AI) definiert man heute als Teilgebiet der Informatik, das sich mit der Automatisierung intelligenten Verhaltens und dem maschinellen Lernen befasst. Der Begriff, ist schwierig zu definieren, da es bereits an einer genauen Definition von „Intelligenz“ mangelt. Dennoch wird er in Forschung und Entwicklung verwendet.²

Im Allgemeinen bezeichnet Künstliche Intelligenz (KI) den Versuch, bestimmte Entscheidungsstrukturen des Menschen nachzubilden, indem z. B. ein Computer so gebaut und programmiert wird, dass er von Daten lernen und relativ eigenständig Probleme bearbeiten kann. Künstliche Intelligenz gilt als die wichtigste Basistechnologie unserer Zeit, verbunden mit der Aussicht auf substanzielle Produktivitäts- und Wachstumseffekte quer durch alle Branchen. Nach vielen Misserfolgen dauerte es über 55 Jahre bis die KI leistungsfähige Ergebnisse vorweisen konnte. Vor etwa 10-12 Jahren hatte die KI letztendlich ihren Durchbruch.

II. Paradigmenwechsel: vom modellbasierten Ansatz zum Lernen

Die frühen Jahre der Künstlichen Intelligenz (erste Ansätze schon 1956) waren ein ziemlicher Misserfolg (syntaxorientierte, graph- und regelbasierte Ansätze).

² Wikipedia: „Künstliche Intelligenz“.



Der klassische Ansatz der KI zur Lösung von Problemen, wie auch in vielen anderen Bereichen sieht folgendermaßen aus: Man macht sich ein deterministisches oder auch stochastisches mathematisches Modell von einer Problemstellung und mit numerischen Optimierungsmethoden ermittelt man die Parameter des Modells, welche eine Zielfunktion oder ein Gütekriterium optimal erfüllen. Dabei sind i. Allg. sehr schwierige mathematische Gleichungen zu bewältigen. Mit diesem Ansatz war die KI jedoch über einige Jahrzehnte sehr wenig erfolgreich.

1. Künstliche Neuronale Netze

Mit dem Einsatz von künstlichen Neuronalen Netzen (KNN) vollzog man einen radikalen Paradigmenwechsel.

Anstatt für ein Problem ein Modell zu entwickeln, die Parameter eines Lösungsansatzes zu optimieren und einen Algorithmus zu schreiben (prozedurale schrittweise Anweisungen) trainiert man ganz einfach ein Neuronales Netz mit Daten oder Ergebnissen von einem Experiment, um eine optimale Lösung durch systematische Suche über dem gesamten Ereignisraum zu finden.

In Anlehnung an das menschliche Gehirn schuf man ein mathematisches Modell von einem NN. Solch ein Netz lernt, ohne dass man auch nur eine einzige Zeile Programmcode schreiben muss. Den Code für ein Netz schreibt man nur einmal für die Netzoptimierung und dann kann es für unterschiedliche Aufgaben i. Allg. unverändert übernommen werden.

Für ein einzelnes natürliches Neuron (Abb. 1) wurde 1943 ein mathematisches Modell veröffentlicht, welches heute noch Verwendung findet (Abb. 2).



Abb. 1: Natürliches Neuron

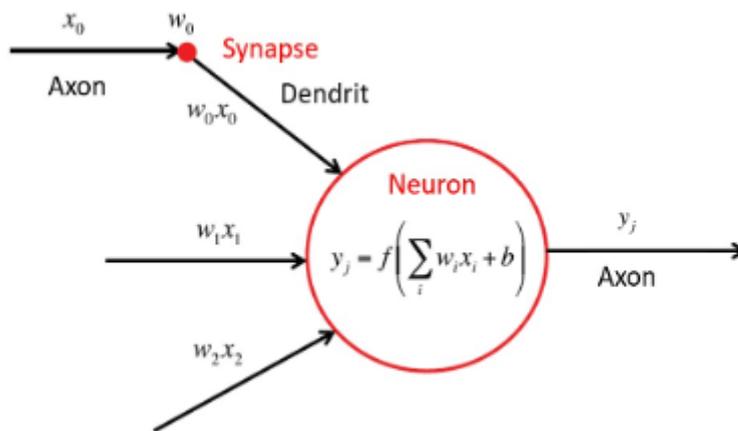


Abb. 2: Mathematisches Modell eines Neurons mit seinen Verbindungen von 1943³

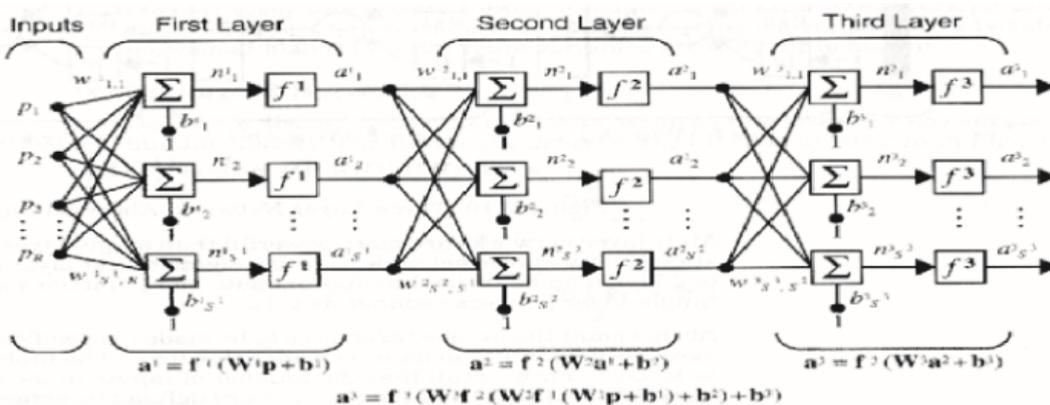


Abb. 3: Das Multilagen-Perceptron mit 3 Schichten⁴

3 W. S. McCulloch and W. Pitts: "A logical calculus of the ideas immanent in neurons activity", Bull. Math. Biophys., vol. 5, pp. 115-1334, 1943.

4 Rosenblatt, in: The perceptron: a probabilistic model for information, storage and organization in the brain", Psychological Review, 1958.



Die neuronale Aktivität wird durch ein Skalarprodukt zwischen dem Gewichtsvektor w und den Eingangskanälen x_i mit einer sich anschließenden nichtlinearen Aktivierungs-Funktion $f(s)$ beschrieben. Die Eingangskanäle werden gespeist von Sensoren wie das Auge oder das Ohr. Dabei können die Erregungen x_i verstärkend oder hemmend wirken, was zu positiven oder negativen Gewichtswerten w_i korrespondiert. Ein hoher Gewichtswert bedeutet, dass ein Neuron seine Information mit hohem Einfluss an ein Neuron der nächsten Schicht weitergibt, ein niedriger Gewichtswert bedeutet, dass das Vorgängerneuron keinen großen Einfluss auf das nachfolgende Neuron besitzt.

Ein einzelnes Neuron kann bis zu 10.000 Synapsen besitzen und damit von so vielen Neuronen der vorhergehenden Schicht beeinflusst werden.

Das gesamte Gehirn besteht nun aus sehr vielen Lagen solcher Neuronen, wobei ein Neuron einer Schicht seine Information an die Neuronen der nachfolgenden Schichten weitergibt. Damit erhält man das Modell des Multilagen-Perceptrons.

Die Ein-Ausgangsabbildung oder die Funktion des Netzes wird allein durch die Gewichte der Synapsen in Abb. 2 festgelegt. Lernen bedeutet diese Gewichte optimal an die Bedürfnisse des Netzes anzupassen. Stark vereinfacht geschieht dies, indem man die Gewichte geringfügig verändert und den Wert beibehält, falls das Ergebnis sich dadurch verbessert hat. Das Netz wird durch das Ergebnis einer Zielfunktion belohnt oder bestraft, falls man eine richtige oder falsche Anpassung eines Gewichtes durchgeführt hat. Dieses verstärkende Lernen („*Reinforcement Learning*“) nutzt ein ähnliches Prinzip wie das menschliche Gehirn. Eine Zielfunktion ist z. B. beim Schachspielen die Anzahl der gewonnenen Partien.

Genauer gesagt beinhaltet Lernen den Einsatz von numerischen Optimierungsverfahren für die Berechnung der Gewichte. Beliebte sind Gradientenalgorithmien (z.B. Backpropagation-Algorithmus) zur Maximierung einer Zielfunktion. Wenn man auf den höchsten Berg im Schwarzwald möchte, so erreicht man das, indem man immer den Weg des steilsten Anstiegs folgt (Gradientenalgorithmus). Sucht man die xy -Koordinaten des Feldbergs und startet man mit den Koordinaten von Bärenthal, so wird man damit aller Voraussicht nach am Feldberg rauskommen. Der Feldberg ist das globale Maximum im ganzen Schwarzwald mit 1493 m. Startet man hingegen in Menzenschwand und folgt immer dem Weg des steilsten Anstiegs, so wird man voraussichtlich am



Herzogenhorn rauskommen. Dies ist nur ein lokales Maximum mit nur 1414 m Höhe und damit lediglich eine suboptimale Lösung.

Universalität eines KNNs: Es gibt einen schönen Beweis, dass man mit nur 3 Lagen eines Perceptrons jede beliebige mathematische Abbildung realisieren kann. Aber mit immer mehr Lagen erhöht man die Flexibilität und damit die Leistungsfähigkeit eines KNNs.

Generalisierungsfähigkeit eines NN: Wichtig zu wissen ist, wie sich das Netz in nicht gelernten Situationen verhält. KNNs sind im Allgemeinen in der Lage zu interpolieren oder auch zu extrapolieren und damit auch auf nicht gelernte Situationen zu reagieren.

Dieser Lernansatz mit Künstlichen Neuronalen Netzen war revolutionär in der KI, aber die Netze waren für die Praxis weitgehend untauglich. KNNs erfüllten vor 20 Jahren noch nicht die an sie gesetzten Hoffnungen und wurden ad acta gelegt. Man konnte lediglich relativ kleine Netze bis etwa 1.000 - 10.000 Neuronen numerisch stabil beherrschen. Dies reichte wegen der geringen Variabilität nicht aus, um reale große Probleme zu lösen. Wählte man größere Netze, so erzielte die Optimierung i. Allg. nur suboptimale und weitgehend unbrauchbare Ergebnisse und man hat deshalb den KNNs keine Zukunft gegeben.

Sie waren zu diesem Zeitpunkt lediglich eine akademische Spielwiese, aber kein reales Instrument für harte Anwendungen. Andere mathematische Methoden waren wesentlich leistungsfähiger (z.B. Support Vector Machines).

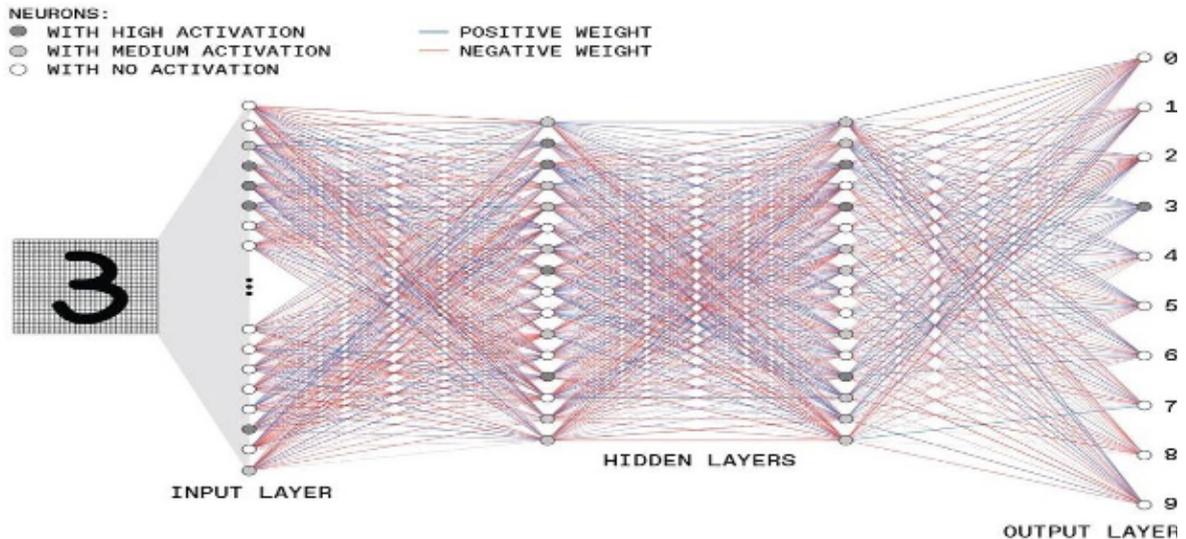


Abb. 4: Ein künstliches Neuronales Netz mit mehreren Lagen zur Musterkennung von handgeschriebenen Ziffern

III. Überkopfpendel

Ein sehr frühes Experiment in der KI war das Überkopfpendel, wobei damit insbesondere der Paradigmenwechsel verdeutlicht werden kann.

Ein kleiner Wagen muss so bewegt werden, dass ein Stab mit einem Gelenk auf dem Wagen nicht umfällt (Abb. 5). Selbst wenn man den Stab antippt (Störung), muss er wieder ausgegeregelt werden und darf nicht umfallen.

Dieses Problem wurde schon vor längerer Zeit analytisch gelöst. Man hat eine Differentialgleichung für die Bewegung und die Dynamik des Stabes aufgestellt und dann mit Methoden der Regelungstheorie einen Regler entwickelt. Dies gelingt auch für den schwierigeren Fall, dass der Stab noch ein zweites Gelenk hat (theoretisch wurde auch der Fall mit n Gelenken gelöst); auch dieser Stab wird senkrecht gehalten.

Die gleiche Regelung wird z.B. beim Start einer Rakete benötigt. Ohne Regelung würde die Rakete nach kurzer Zeit umkippen.

Man kann nun aber einwenden, dass es auch einem Kind nach einiger Zeit Übung gelingt, einen Stab auf der Hand zu balancieren, ohne etwas von

Differentialgleichungen und Reglerentwurf zu verstehen. Das Kind lernt die Lösung durch Experimentieren.

Dies hat KI-Wissenschaftler motiviert, das Problem des Überkopfpendels mit einem KNN zu lösen, was mit großem Erfolg gelang und mit einem wesentlich geringerem Entwicklungsaufwand verbunden war als die analytische Lösung. Ein schönes Video für die Regelung eines Überkopfpendels mit einem zweiten Gelenk findet man unter der Internet-Adresse.⁵

Ein sehr ähnliches Beispiel, aber noch wesentlich komplexer, ist die Aufgabe, einem humanoiden Roboter den aufrechten Gang oder Treppen steigen beizubringen. Die Robotik hat erstaunlich lange gebraucht, um wirklich funktionierende humanoide Zweibeiner zu entwickeln. Denn Gehen ist keine einfache Aufgabe, vor allem auf zwei Beinen. Man muss die Vorwärtsbewegung kontrollieren und sich gleichzeitig aufrecht halten. Es gelang mit Hilfe eines Neuronales Netzes und Reinforcement Lernen erfolgreich eine recht flüssig aussehende humanoide Gehbewegung nachzuahmen.⁶ Ein eindrucksvolles Video findet man unter.⁷

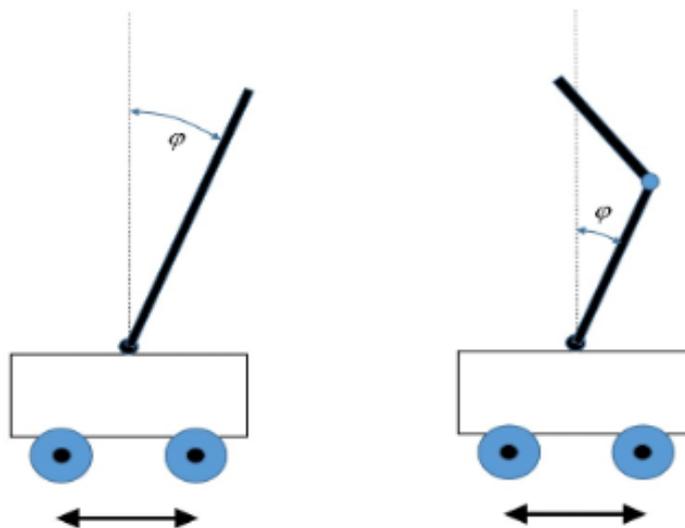


Abb. 5a: Überkopfpendel Abb. 5b: Überkopfpendel mit einem zweiten Gelenk

5 Video Überkopfpendel: <https://blog.otoro.net/2015/02/11/cne-algorithm-to-train-self-balancing-double-inverted-pendulum/> (letzter Zugriff am 08.03.2023)
<https://otoro.net/ml/pendulum-cne/> (letzter Zugriff am 08.03.2023)

6 Haamoja, Tuomas, et al. „Learning to walk via deep reinforcement learning.“ arXiv preprint arXiv:1812.11103 (2018).

7 Video zum Thema Laufen lernen: <https://youtu.be/WmN7zq-D3ca> (letzter Zugriff am 08.03.2023)



IV. Deep Blue

Ein erster Durchbruch der KI gelang 1996 als mit dem von IBM entwickelten System Deep Blue, mit der Schach-Weltmeister Garri Kasparov in sechs Partien geschlagen wurde. Die Software dazu war klassisch regelbasiert geschrieben und der Entwicklungsaufwand dafür war erheblich. Schachcomputer im Stil von Deep Blue verrichten ihre Arbeit mithilfe des sogenannten AlphaBeta-Algorithmus. Dahinter steckt im wesentlichen brutale Rechengewalt („*brute force*“-Ansatz), wobei alle möglichen Züge bis zu einer gewissen Spieltiefe durchgerechnet werden. Außerdem war der Ansatz zwar adaptiv, aber nicht lernend.

Das Projekt Deep-Blue kostete IBM insgesamt etwa 5 Millionen US-Dollar. Zudem musste ein sehr leistungsfähiger großer Rechner verwendet werden.

Im Vorgriff auf die nächsten Kapitel: Alpha Zero lernte Schach in nur 4 Stunden und erreichte einen EloWert von ca. 3300. Der Elo-Wert ist eine Maßzahl für die Spielstärke einer Person oder einer Maschine. Der amtierende Weltmeister Magnus Carlsen hat einen EloWert von etwa 2.850. Ein Mensch braucht in der Regel mindestens 15 Jahre um auf Weltniveau Schach zu spielen.

V. Der Durchbruch: Deep Learning mit Faltungsnetzen.

Es gab einen historischen Durchbruch der künstlichen Intelligenz in den Jahren 2008-2016 mit Hilfe sehr großer künstlicher Neuronaler Faltungsnetze (convolutional networks) mit vielen Lagen (Deep Learning). Damit ist man in der Lage sehr große Datenmengen zu verarbeiten. Wir können Maschinen entwickeln, welche intelligentes Handeln direkt aus den vorliegenden Daten lernen können, anstatt programmiert zu werden.

Heute beherrscht man durchaus Netze mit $10^8 - 10^{11}$ Neuronen mit stabilen numerischen Ergebnissen. Das menschliche Gehirn zum Vergleich, besitzt $10^{11} = 100$ Milliarden Neuronen.

Bei Faltungsnetzen (convolutional networks, CNN) sind lokal benachbarte Neuronen miteinander gekoppelt. Dies kann als mathematische Regularisierung des KNNs interpretiert werden und deshalb konvergieren damit auch sehr große und tiefe Netze mit vielen Lagen, wie sie in realen Anwendungen benötigt werden.



Es gab glücklicherweise ein paar wenige Wissenschaftler, welche den Glauben an das Potential der KNNs trotz der frühen Misserfolge nicht verloren. Ihnen ist es zu verdanken, dass KNNs heute auch für sehr große Netze in realen Anwendungen eingesetzt werden können. *Yoshua Bengio*, *Geoffrey Hinton* und *Yann LeCun*, wurde 2018 der Turing Award verliehen; diese Auszeichnung gilt als der Nobelpreis der Informatik. Alle drei werden durch ihre zum Teil gemeinsamen Arbeiten als „Väter der *Deep-Learning-Revolution*“ angesehen (siehe dazu auch^{8,9}). *Yan LeCun* gilt als Schöpfer der Convolutional Neural Networks.

VI. AlphaGo Zero und Alpha Zero von Deep Mind (Google)

1. AlphaGo Zero (Okt 2017)¹⁰

Das Chinesische Brettspiel Go besteht aus nur vier Grundregeln, gilt aber als eines der komplexesten Brettspiele der Welt, wesentlich komplexer als Schach.

Vier Versionen von AlphaGo zählt DeepMind mittlerweile. Sie alle beruhen auf einer Kombination von neuronalen Netzen und der Baumsuchtechnik Monte Carlo Tree Search (MCTS).

Die ursprüngliche AlphaGo-Version, besiegte 2016 den 18-fachen Go-Weltmeister Lee Sedol mit 4:1. Alpha Go trainierte ein KNN zunächst mit allen je international aufgezeichneten Go-Wettbewerben. Danach spielten zwei AlphaGo-Maschinen gegeneinander und verbesserten ihre Spielstärke noch einmal um einen deutlichen Prozentsatz.

Der Nachfolger AlphaGo Zero, lernt durch Millionen von Partien gegen sich selbst, vorgegeben werden lediglich die Spielregeln.

Ein neues Paradigma: Lernen ohne jegliches Vorwissen und Verzicht auf menschliches Wissen! Vorhergehende Versionen lernten zunächst tausende von Menschen auf Turnieren gespielte Partien. Der Lernvorgang funktioniert alleine nach

8 Sze, Y. H. Chen, T. J. Yang and J. S. Emer: „Efficient Processing of Deep Neural Networks: A Tutorial and Survey“, In Proceedings of the IEEE, vol. 105, no. 12, pp. 2295-2329, Dec. 2017

9 Jason Mayes: „Machine Learning 101“,

https://docs.google.com/presentation/d/1kSuQyW5DTnkVaZEiGYCkFOxvzCqGEFzWBv4e9Uedd9k/edit#slide=id.g168a3288f7_0_58 (letzter Zugriff am 08.03.2023).

10 David Silver et al.: „Mastering the game of Go without human knowledge“, Nature 550, 354–359 (19. October 2017).



dem Prinzip des „*Reinforcement-Learning*“, indem das Programm gegen sich selbst spielte und ohne das menschliche Vorwissen über Eröffnungen und Endspiele zu verwenden und ohne die komplexe Theorie der Spiele zu studieren. Es stellte sich heraus, dass die Verwendung von menschlichem Wissen eher hinderlich war und zu einer schlechteren Konvergenz des Lernvorgangs führte.

Ein menschlicher Spieler hätte inzwischen keine Chance mehr gegen die Maschine zu gewinnen (Abb. 6).

Sehr interessant ist auch, dass die KI vollkommen neue Spielstrategien herausfand, welche zuvor noch von keinem menschlichen Spieler gespielt wurden.

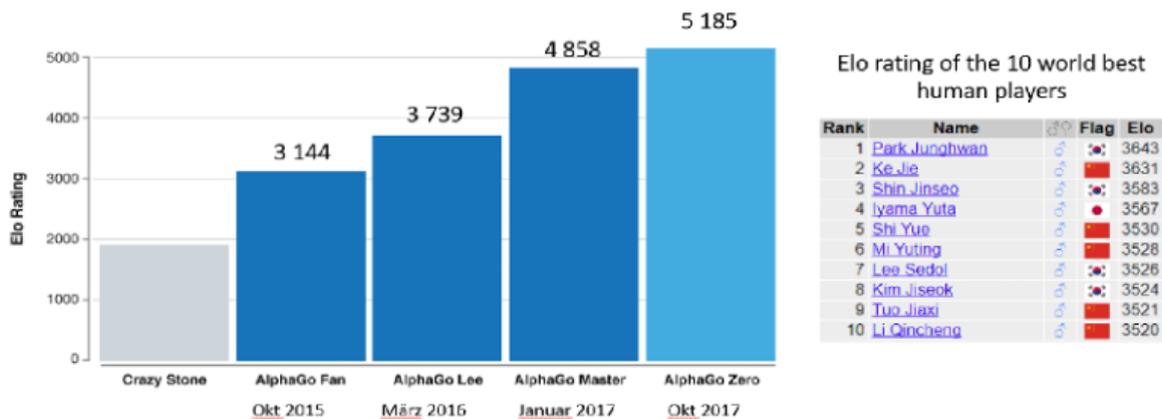


Abb. 6: Fortschritt in der Spielstärke von AlphaGO

2. Alpha Zero von DeepMind (Dez 2017)¹¹ Alpha Zero zeigt eine völlig neue Entwicklung auf, nämlich hin zur universellen Lernmaschine.

AlphaZero ist ebenfalls eine Software der GoogleTochter DeepMind. Der Nachfolger von AlphaGo lernt durch Millionen von Partien gegen sich selbst, vorgegeben werden lediglich die Spielregeln.

Ein selbstlernender Algorithmus hat 3 komplexe strategische Spiele gelernt, ohne die komplizierte Theorie, welche sich dahinter verbirgt, zu studieren. AlphaZero war in der Lage, mit einem einzigen KNN gleichzeitig Go, Schach und Shogi (Japanisches Schach) zu lernen.

¹¹ David Silver et al.: „Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm“, arXiv:1712.01815 [cs.AI], Cornell University.



Ohne jegliches Vorwissen, außer den Spielregeln, erreichte das System nach 24 Stunden übermenschliche Spielstärke in allen drei Spielen.

Das System lernte:

- Shogun in nur 2 Stunden
- Schach in 4 Stunden
- Go in 8 Stunden

Die ursprüngliche AlphaGo-Version, musste noch mehrere Monate lang trainiert werden!

Bei der hohen Überlegenheit des Ansatzes gegenüber Menschen macht es keinen Sinn mehr KI-Lösungen durch Testspiele gegen die besten Spieler der Welt zu beweisen. „*Computerschachprogramme sind mittlerweile so gut, dass es illusorisch ist, dagegen zu spielen*“, sagt der Weltklassespieler Johannes Zwanzger.

Deshalb hat man Alpha Zero gegen die bisher besten klassisch entworfenen Brettspielprogramme antreten lassen. Es spielte stärker als Stockfish (Schach) und Elmo (Shogi) und bewies damit eindrucksvoll die Überlegenheit des selbstlernenden Ansatzes der KI, bei gleichzeitig wesentlich geringerem Entwicklungsaufwand. Außerdem war es stärker als das zuvor nur für Go entwickelte AlphaGo Zero.

In 100 Spielen hat AlphaZero kein einziges Spiel in Schach verloren, es verlor 8 bei Shogi und 40 bei Go. Der Algorithmus lief auf einem einzigen PC **mit 4 TPUs**. Stockfish und Elmo verwendeten 64 CPU-Kerne.

3. Fortschritte bei der Hardware und dem Energieverbrauch beim Spielen

Die Fortschritte beim Energieverbrauch und bei der Komplexität der verwendeten Hardware sind enorm.

Nur noch eine Maschine mit 4 TPUs braucht AlphaGo Zero; bei der ersten Version war es noch ein Cluster mit über 1000 CPU-Kernen und 176 GPUs. Tensor Processing Units (TPUs), auch Tensor-Prozessoren, sind von Google entwickelte anwendungsspezifische Chips um Anwendungen im Rahmen des maschinellen Lernens zu beschleunigen.

Es wird voraussichtlich nicht lange dauern, bis diese Spielleistung auch auf Mobiltelefonen verfügbar sein wird.



VII. Besser als der Mensch

Der Gradmesser für Leistungsmessungen bei Künstlicher Intelligenz war immer der Mensch

Inzwischen sind viele KI-Lösungen in unterschiedlichsten Anwendungen wesentlich besser geworden als der Mensch und sie lernen auch wesentlich schneller. Man darf gespannt sein, was von dieser Entwicklung noch zu erwarten ist. Neurochips lernen 10.000-mal schneller als unser Gehirn und sie finden häufig neue Lösungen für Probleme, welche Menschen zuvor noch nie entdeckt haben. Weitere Anwendungsbeispiele der KI:

- **Klarer Sieg für die künstliche Intelligenz:** Beim US-Game-show-Klassiker „Jeopardy“ hat der IBM-Computer „Watson“ (semantische Suchmaschine) zwei menschliche Champions besiegt (2011).
- **Lernen von Atari-Spielen mit KI** basierend alleine auf Videoaufnahmen des Computer-Bildschirms. Ersten Ansätzen mit Reinforcement Learning gelang es sehr erfolgreich eine Anzahl von Atari-Spielen zu lernen. Man scheiterte jedoch bei bestimmten Spielen. Die Autoren von „Go-Explore“¹² erzielten erhebliche Fortschritte durch eine Kombination von CNNs mit strategischen Entscheidungsstrategien und Domänenwissen. Go-Explore merkt sich konkrete Zustände der Lösungsdomäne und geht immer wieder zum letzten erfolgreichen Punkt zurück, um von dort aus erneut alles zu erkunden. In allen 55 getesteten Titeln spielte Go-Explore insgesamt übermenschlich, selbst im Erkundungsspiel „Pitfall!“, in dem ältere KIs bislang überhaupt keine Punkte erzielen konnten. Das Programm setzte einen Rekord indem es den menschlichen Weltrekord brach.
- **Handschrifterkennung:** Handschrifterkennung war schon immer eine Domäne des Menschen, welche man von Kind auf trainiert hat. Maschinelle Lösungen taten sich zunächst schwer, vergleichbare Lösungen zu finden. Klassische Ansätze der Mustererkennung erreichten dann doch bemerkenswerte Ergebnisse mit einer Fehlerrate von nur 0,6%. Getestet wurden die Lösungen anhand der MNIST-Datenbank, welche tausende von handgeschriebenen Buchstaben und Ziffern enthält. Menschen erreichen bei dieser Datenbank eine Fehlerrate von

¹² Ecoffet, A., Huizinga, J., Lehman, J., Stanley, K. O., & Clune, J. (2021). „First return, then explore“, Nature, 590(7847), 580-586.



1,4%. Die besten Ergebnisse mit Deep Learning liegen inzwischen bei einer Fehlerrate von 0,21% und damit fast 7-mal besser als der Mensch.¹³

- **Ankündigung von DeepMind Health durch Google** (24. Febr. 2016)
- **Google: DeepMind reduzierte mit maschinellem Lernen den Energieverbrauch der Kühlsysteme in ihren Forschungszentren um erstaunliche 40%.**
- **Google trainiert ein einziges Neuronales Netz welches 100 Sprachen übersetzen kann.**
- **Luftkampf (Dog Fight) gegen einen der erfahrensten Piloten der US-Air Force.** Der Pilot hatte keine Chance gegen die KI.
- **Sieg beim Pokerspiel:** Die siegreiche KI-Software mit Namen Libratus wurde von zwei Forschern der – Carnegie Mellon-Universität entwickelt und strich bei dem Match gegen vier der weltbesten Pokerspieler mit deutlichem Vorsprung den angeblichen Millionen-Pot ein. Dies ist insofern bemerkenswert, weil man der KI keinen so großen Erfolg prophezeit hat, wo die menschliche Intuition oder das „Bauchgefühl“ benötigt wird.
- **ImageNet** ist ein jährlicher Bilderkennungswettbewerb, also z.B. die Frage ist in einem Bild eine Katze zu finden. 2015 unterbot ein Deep-Learning-System von Microsoft in einer Kategorie mit 4,9 Prozent die menschliche Fehlerrate von 5,1 Prozent.
- **Google Musiksuche;** die Musikerkennungssoftware von Google erkennt in wenigen Sekunden, welches Musikstück gerade zu hören ist; vielmehr ist das Programm jetzt auch in der Lage, Musikstücke durch bloßes Vorsummen, Pfeifen oder Singen zu erkennen.

13 A. Baldominos, Y. Saez, P. Isasi: "A survey of handwritten character recognition with MNIST and EMNIST" Applied Sciences, 2019 - mdpi.com (letzter Zugriff am 08.03.2023).

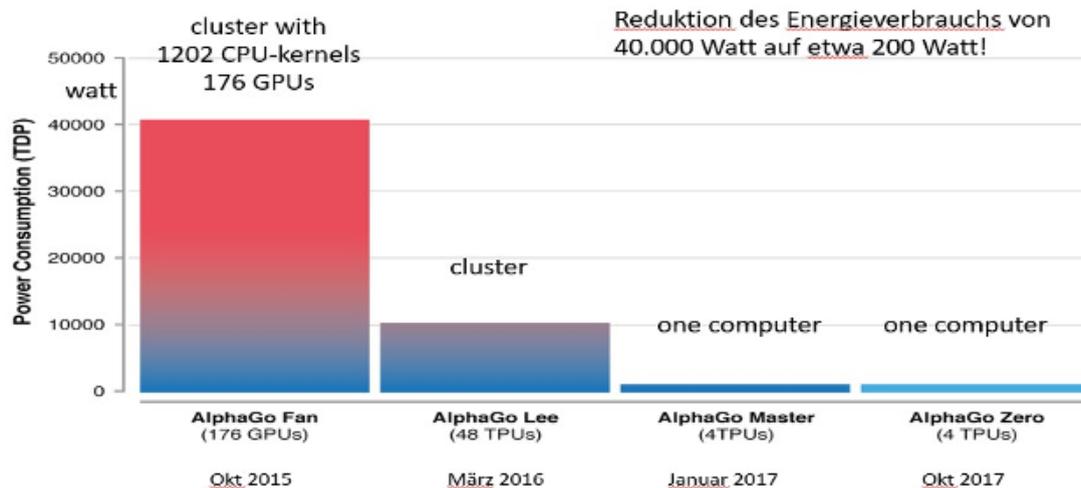


Abb. 7: Fortschritte bei der Hardware und dem Energieverbrauch beim Spielen

VIII. Computer-Hardware

Der Erfolg beim Maschinellen Lernen ist nur möglich mit enormer Rechenleistung. Eine zentrale Rolle spielen dabei GPUs. Eine „GPU“ ist die Graphic Processing Unit, also der Prozessor der Grafikkarte eines PCs. Mit solchen Graphikkarten lassen sich Lernvorgänge bei großen KNNs erheblich beschleunigen. Leistungsdaten der Grafikkarte NVIDIA GeForce GTX 1080:

- 2.560 Kerne, Takt: 2 GHz
- 7,2 Milliarden Transistoren
- 10 TeraFLOPS = 10^{13} FLOPS = 10.000.000.000.000 FLOPS
- (1 FLOP ist eine Floating-Point-Operation wie z.B. eine Addition oder eine Multiplikation zweier Gleitkommazahlen)
- Etwa 100-mal schneller als ein PC
- Energieverbrauch: ca. 150 Watt
- Kosten: ca. 800,-€

Zum Vergleich:

- 2002 erreichte der weltweit schnellste Supercomputer 10 TFLOPS,
- Energieverbrauch: 3,2 MWatt
- Kosten: 50 Mio\$



Dass man heute alles auf einem PC rechnen kann und keinen Supercomputer für 50 Millionen braucht, hat ganz wichtig dazu beigetragen, dass viele tausend Wissenschaftler und Entwickler auf der ganzen Welt heute an solchen Problemen arbeiten und die Systeme weiterentwickeln können.



Abb. 8: Grafikkarte NVIDIA GeForce GTX 1080

XI. Ausblick

In den letzten 5 Jahren hat die KI große Fortschritte insbesondere auf folgenden Gebieten gemacht: Computer Vision, Spracherkennung und Sprachsynthese, natürliches Sprachverstehen, Bild- und Video Generierung, Multiagentensysteme, Planungsstrategien, Robotik, Spiele, medizinische Diagnose, Logistik, autonomes Fahren, Übersetzer, Arzneimittelsynthese. Fortschritte wurden erzielt in Bezug auf: Lernen, Leistungsfähigkeit, Hardware und Energieverbrauch.

Es ist zu erwarten, dass in naher Zukunft viele weitere Anwendungsgebiete hinzukommen. Z.B. werden Suchmaschinen in der Lage sein, wesentlich präzisere semantische Anfragen zu beantworten und nicht nur eine Ansammlung von Stichwörtern auszuwerten. Auf Mobiltelefonen wird die KI bereits intensiv eingesetzt.

Google ist überzeugt vom großen Potential von Deep Learning und hat deshalb mit einer Erstinvestition von 600 Mio US\$ die Tochterfirma Deep Mind gegründet. Apple, IBM und Microsoft ziehen nach und stellen viele neue Mitarbeiter für dieses Gebiet ein.



China strebt nach weltweiter Dominanz bei Künstlicher Intelligenz. Der Staatsrat der Volksrepublik China hat im Juli 2017 die Künstliche Intelligenz zur wichtigsten Schlüsseltechnologie erklärt und einen Plan zu deren Weiterentwicklung beschlossen mit enormen Investitionen. Schon 2030 soll die chinesische KI-Industrie mindestens 150 Milliarden US\$ auf diesem Gebiet umsetzen.

Trotz der großartigen Erfolge der KI im letzten Jahrzehnt, müssen die Ergebnisse jedoch auch etwas relativiert werden, da alle damit gelösten Probleme wie etwa typischerweise das Schachspiel, einer gewissen Klasse von Intelligenz zuzuordnen sind, welche man als „mechanistische Intelligenz“ bezeichnen könnte und welche alle eine klar formulierbare Ein-/Ausgangsfunktionalität aufweisen. Wenn es hingegen um Gebiete der Intelligenz geht, wo Eigenschaften wie etwa Kreativität, Intuition oder Assoziativität gefragt sind, dann kann die KI noch keine so großen Erfolge im Vergleich zum Menschen vorweisen. Hier ist der Mensch der Maschine noch deutlich überlegen; aber es wird daran gearbeitet.

Man kann jedoch feststellen, dass der Traum der Informatiker, menschliche Intelligenz mit Computern nachzubilden, in den letzten 10 Jahren zu einem bemerkenswerten Teil in Erfüllung gegangen ist.



About the Author

The author, Hans Burkhardt, is a professor at the Institute for Computer Science at the University of Freiburg. His research focuses on computer vision, artificial intelligence and pattern recognition.