

State-of-AI-Report Austria 2023

Vorläufiger Bericht der
Austrian Society for Artificial Intelligence (ASAI)
Juni 2023

Stand der KI-Forschung International

Überblick. Methoden der künstlichen Intelligenz (KI) und KI Systeme haben sich in den letzten 10 Jahren in vielen Bereichen sehr stark verbessert. Drei Gründe für diese rasante Entwicklung können angeführt werden: a) Algorithmische Verbesserungen, b) höhere Rechenkapazität und c) die Verfügbarkeit von großen Datensätzen. Ab etwa 2021-2022 erreichten KI-Systeme bei der Textgenerierung in bestimmten Bereichen fast menschliches Niveau und wurden von 100 Millionen AnwenderInnen aufgenommen, wodurch diese Systeme starke gesellschaftliche Relevanz bekommen.

a) Algorithmische Verbesserungen. Die wohl stärkste algorithmische Strömung der letzten Zeit sind Deep Learning Methoden. Deep Learning ist eine Menge von Algorithmen und Methoden, die auf sogenannten künstlichen neuronalen Netzen mit vielen Schichten bestehen. Im Jahr 2018 erhielten Yoshua Bengio, Yann LeCun und Geoffrey Hinton den Turing Award für "Deep Learning". Die momentan bekannten Sprachmodelle, wie ChatGPT, und Bildgenerierung, wie DALL-E2, sind solche generativen Deep Learning Methoden. Deep Learning Methoden haben auch gewisse Nachteile, z.B. benötigen sie große Datensätze, sind wenig interpretierbar und können sich schlecht auf neue Situationen anpassen. In den letzten fünf Jahren gibt es daher auch immer mehr Bestrebungen, symbolische KI-Methoden mit Deep Learning Methoden zu verbinden.

b) Erhöhte Rechenkapazität und Skalierung. Die Rechenkapazität hat sich in den letzten Jahren, vor allem durch die technologischen Verbesserungen der Grafikkarten (GPUs) stark erhöht. Die GPU Technologie eignet sich hervorragend für die Berechnungen, die für Deep Learning notwendig sind. Es wurde auch gezeigt, dass sich Sprachmodelle wie ChatGPT einfach durch Skalierung, d.h. durch die Erhöhung der Anzahl von einstellbaren Parametern von tiefen neuronalen Netzen, verbessern, was wiederum mit der Entwicklung von GPU-Technologien einhergeht. Insbesondere bei Sprachmodellen sorgt pure Skalierung für eine Verbesserung der Qualität.

c) Große Datensätze. Mittlerweile sind in vielen Bereichen, zB in der Bilderkennung und für Sprachmodelle, sehr große Datensätze verfügbar. Deep Learning Methoden werden während – bevor sie in Einsatz gehen – in einer sogenannten Trainingsphase auf diese Datensätze angepasst. Je größer und diverser diese Datensätze sind, desto besser ist später auch die Qualität der KI-Systeme.

Jüngste Fortschritte von KI Methoden durch Deep Learning. Der jüngste Aufschwung der KI kann auf Fortschritte in Feld der sub-symbolischen KI zurückgeführt werden, insbesondere beim maschinellen Lernen (ML) und vor allem bei Deep Learning (Schmidhuber, 2015; LeCun et al., 2015). Deep Learning hat das Forschungsfeld Computer Vision durch sogenannte Convolutional Neural Networks (LeCun et al., 1998; Schmidhuber et al., 2012), z. B. durch AlexNet (Krizhevsky et al., 2012) und durch Residual Networks (He et al., 2016) revolutioniert. Um 2015 wurde damit die Fehlerrate bei der Bild-Klassifikation durch KI-Methoden fast so gut wie die menschliche Fehlerrate. Die Sprachverarbeitung (Natural-Language-Processing) wurde ebenfalls stark von Deep Learning verbessert, vor allem durch Long Short-Term Memory (LSTM) Netzwerke (Hochreiter und Schmidhuber, 1997), Sequenz-zu-Sequenz-Modelle (Sutskever et al., 2014), Transformer-Modelle und sogenannte Attention-Mechanismen (Vaswani et al., 2017, Devlin et al., 2019). Die in letzter Zeit in das Zentrum der öffentlichen Aufmerksamkeit gerückten großen Sprachmodelle ("Large Language Models"), wie

ChatGPT, basieren auf solchen Transformer-Modellen.

Deep Learning Methoden gehören zu maschinellen Lernmethoden, das heißt, sie müssen auf sogenannte Trainingsdaten angepasst, d.h. "trainiert" werden. Dieser Prozess benötigt große Datensätze, z.B. Millionen von Bildern oder Textdokumenten, und ist auch rechenintensiv, was häufig als Kritikpunkte für diese Methoden angeführt wird. Es gibt verschiedene Arten, wie Deep Learning Methoden trainiert werden können, von denen wir hier die vier am häufigsten verwendeten anführen: Supervised Learning ("überwachtes Lernen"), Self-supervised Learning ("selbst-überwachtes Lernen") und Unsupervised Learning ("unüberwachtes Lernen"), und Reinforcement Learning ("bestärkendes Lernen").

Supervised Deep Learning wurde durch neue Techniken zur Optimierung wie Adam (Kingma und Ba, 2015), zur Normalisierung wie Batch-Normalisierung (Ioffe und Szegedy, 2015) und Selbst-Normalisierung (Klambauer et al., 2017), und für Regularisierung (Robustheit) wie Dropout (Srivastava et al., 2014) in den letzten Jahren stark verbessert. **Unsupervised Deep Learning** hat sich bei der generativen Modellierung bewährt, z. B. durch Generative Adversarial Networks (Goodfellow et al., 2014), Variational Autoencoders (Kingma und Welling, 2014), Normalizing Flows (Rezende und Mohamed, 2015) und Diffusion Probabilistic Models (Ho et al., 2020), kurz Diffusions. Letztere haben auch die Generierung von realistischen Bildern auf ein neues Niveau gebracht (siehe Bildgenerierung). **Self-supervised Deep Learning** stellt eine relativ neue, sehr vielversprechende Forschungsrichtung dar (Hadsell et al., 2009), die bereits in der Sprachverarbeitung eingesetzt wird. Bei self-supervised Learning wird eine Prozedur vorgeschlagen, die ein Signal wie beim supervised Learning erzeugt, während eigentlich unüberwachte Daten vorliegen. Typischerweise wird self-supervised Learning als kontrastives Lernen (Chen et al., 2020) realisiert, wobei der größte Erfolg wohl das Lernen eines gemeinsamen Raumes für Bilder und Texte durch die Methode CLIP ist (Radford et al., 2021). Deep Learning beeinflusst zunehmend verschiedene andere wissenschaftliche und technische Disziplinen, z.B. über Graph Neural Networks (GNNs) (Kipf und Welling, 2017). Diese Graph Neural Networks werden für die Modellierung chemischer Eigenschaften von Molekülen verwendet (Gilmer et al., 2017, Mayr et al., 2018) und für Teilchen-Teilchen-Interaktionen zur Modellierung technischer Geräte (Sanchez-Gonzalez et al., 2020). Das Deep Learning System AlphaFold (Jumper et al., 2021) schaffte einen Durchbruch in der Molekularbiologie: die Vorhersage der 3D Struktur von Protein basierend auf der Aminosäuresequenz. Deep Learning wird auch zur Modellierung gewöhnlicher und partieller Differentialgleichungen in verschiedenen Forschungsbereichen verwendet (Raissi et al., 2019). **Reinforcement Learning** wurde ebenfalls durch Deep Learning erweitert und verbessert, zum Beispiel durch Deep Q-Learning, das bei Atari-Spielen im Durchschnitt besser abschneidet als der Mensch (Mnih et al., 2015). Reinforcement Learning Methoden, die auf einer LSTM-Architektur basieren, erreichten in DOTA II (Berner et al., 2019) und Starcraft II (Vinyals et al., 2019) die Stärke von professionellen GamerInnen. Ebenfalls mit einem LSTM-basierten Reinforcement Learning System wurde für eine kurze Zeit ein Fusionsreaktor gesteuert (Degraeve et al., 2022) – eine große Hoffnung für eine neue nachhaltige Energiequelle.

Symbolische KI. In fast gleicher Weise hat auch die symbolische KI in den letzten Jahren große Erfolge vorzuweisen. Es gab enorme Fortschritte bei der automatischen Deduktion, insbesondere beim Erfüllbarkeitsproblem (SAT) (Biere et al., 2021), beim Lösen von Constraintproblemen (Rossi et al., 2006) und bei Beschreibungslogiken (Baader et al., 2003). Diese Fortschritte haben den Weg für die Behandlung von Probleminstanzen realer Größe in Bereichen wie Planen, Scheduling, Konfiguration, Verifikation sowie im Wissens- und Ontologie-Management geebnet, wie es heute in vielen Industriezweigen verwendet wird. Systeme für ausdrucksstarke logische Sprachen, welche die Beschränkungen der klassischen Logik überwinden, insbesondere die Fähigkeit des nicht-monotonen Schließens als Grundlage für den Umgang mit unvollständigen Informationen (Van Harmelen et al., 2008), haben ebenfalls einen ausgereiften Zustand erreicht, trotz der Herausforderungen der hohen

intrinsic Berechnungskomplexität im Allgemeinen. Insbesondere Answer-Set Programming (Brewka et al., 2011; Gebser et al., 2016; Lifschitz, 2019), eine deklarative Problemlösungsmethode basierend auf logischen Programmen (Gelfond und Lifschitz, 1991), hat dank allgemeiner Problemlösungsmaschinen wie DLV (Leone et al., 2006), clasp (Gebser et al., 2011) und deren Erweiterungen an Bedeutung gewonnen und wird in so unterschiedlichen Bereichen wie kombinatorische Optimierung, Ingenieurwesen, Wissensmanagement, Biowissenschaften und Geisteswissenschaften eingesetzt (Erdem et al., 2016; Falkner et al., 2018). Im Windschatten dieser Entwicklung hat sich Datalog+/- (Cali et al., 2012; Gottlob et al., 2014) als regelbasierter Formalismus für den semantischen Umgang mit Big Data herauskristallisiert und findet in der Industrie zunehmend Beachtung. Die symbolische KI war eine treibende Kraft für das Semantic Web, indem sie ausdrucksstarke Sprachen mit geringer Komplexität wie DL-Lite und EL++ für Schlussfolgerungen in Web-Ontologiesprachen wie OWL bereit stellte (Grau et al., 2008). Knowledge Graphs (Hogan et al., 2021), die ursprünglich von Google konzipiert wurden, haben in jüngster Zeit die Fähigkeiten von KI-Systemen z.B. bei der semantischen Suche, bei der Beantwortung von Fragen basierend auf symbolischem Faktenwissen, und bei der Problemlösung in einer Reihe von Industriesystemen erweitert (Bellomarini et al., 2019).

Text-Generierung durch große Sprachmodelle (Large Language Models, LLMs). Obwohl diese zum Teil auf den oben beschriebenen Methoden basieren, genießen momentan (Stand Mai 2023) große Sprachmodelle, wie ChatGPT und GPT-4, die meiste mediale Aufmerksamkeit – auch weil eine breite Öffentlichkeit über ein einfaches Web-Interface Zugang zur Interaktionen mit den Modellen hat. Diese Sprachmodelle basieren grundsätzlich auf Transformer-Netzwerken (Vaswani et al., 2017) und somit auf der Nachfolgetechnologie von LSTM-Netzwerken (Hochreiter & Schmidhuber, 1997), und damit auf Deep Learning Architekturen. In den letzten fünf Jahren wurden Fortschritte in der Qualität der Spracherzeugung vor allem über **Skalierung** gemacht: das bedeutet, dass die Sprachmodelle auf immer größeren Datensätzen mit immer größerem Rechenaufwand trainiert wurden.

Number of Parameters of Select Large Language and Multimodal Models, 2019–22

Source: Epoch, 2022 | Chart: 2023 AI Index Report

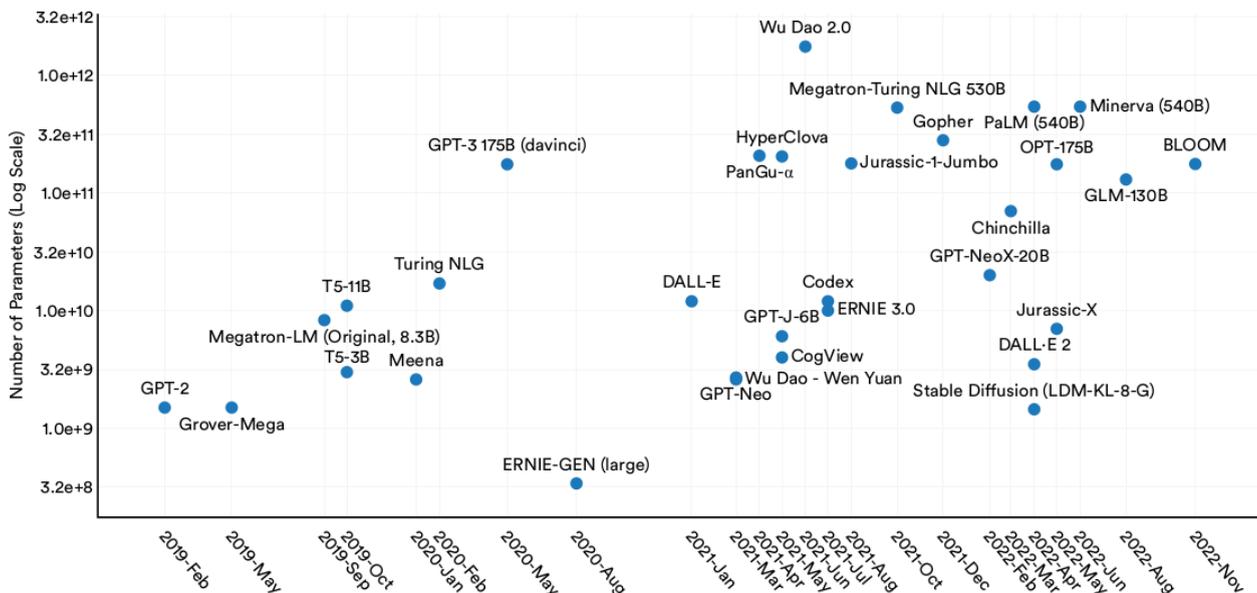


Abbildung 1. Entwicklung der großen Sprachmodelle. Auf y-Achse ist die Anzahl der einstellbaren Parameter (damit die “Größe”) der Sprachmodelle abgebildet. GPT-4 wurde erst später veröffentlicht und ist daher nicht in der Abbildung zu sehen. Quelle: Artificial Intelligence Index Report 2023 (Stanford University, 2023).

Diese großen Sprachmodelle werden üblicherweise durch selbst-überwachtes Lernen trainiert, z.B. indem bestimmte Wörter gelöscht werden, die das Modell wieder ergänzen muss (Devlin et al., 2018), oder indem der Anfang eines Satzes dem Modell gezeigt wird und es den Rest ergänzen soll (Radford et al., 2018). Diese Trainingsprozesse basieren auch auf riesigen Datensätzen, d.h. alle möglichen Texte, die digital zur Verfügung stehen, wobei durchaus an das gesamte Internet gedacht werden kann (z.T. sogar noch darüber hinaus). Dadurch ergeben sich mehrere Probleme, von denen nur einige aufgelistet werden: a) Alle in den Daten bestehende Verzerrungen (“Biases”), z.B. Gender-Biases, Fehler und Unwahrheiten werden prinzipiell vom Modell ebenfalls mitgelernt und bei Anwendung des Modells weitergegeben. b) Durch die benötigte große Rechenkapazität ist das Erstellen von solchen Sprachmodellen nur mehr sehr wenigen Institutionen möglich, konkret den IT-Giants. Aufgrund des hohen Rechenaufwands sind Universitäten und andere Forschungseinrichtungen fast nicht mehr konkurrenzfähig. Dadurch verlagert sich die Forschung stark in den industriellen Sektor (Stanford University, 2023) und in die kommerzielle Forschung von wenigen internationalen Großunternehmen, welche auch aktiv Expertinnen und Experten aus dem akademischen Umfeld abwerben. c) Die verwendeten Trainingsdaten werden oft nicht mehr angegeben und veröffentlicht, so dass eine Datenschutz-Problematik entsteht, ob diese Daten überhaupt zum Trainieren der Modelle verwendet werden dürfen, bzw. ob die davon abgeleiteten Daten, d.h. vom Sprachmodell erzeugte Texte, den Datenschutz verletzen. d) Die Sprachmodelle werden nicht mehr veröffentlicht, sondern nur mehr Interaktionsmöglichkeiten (wie bei “ChatGPT”) zur Verfügung gestellt, so dass universitäre Forschungseinrichtungen auch keine weiterführende Forschung oder ein De-Biasing (Ganhör, et al. 2022) durchführen können. e) Hinzu kommt der Konsens in der Forschung, dass die Probleme dieser Technologie durch Deep Learning basierte Methoden allein nicht lösbar sind, sondern eine Kombination von allen oben genannten Methoden und Technologien nötig sein wird, welche nur durch die aktive Vernetzung dieser Forschungsgebiete erreicht werden kann.

Realistische Bildgenerierung mit KI-Methoden Deep Generative Models. Generative KI-Modelle können heutzutage (Stand: Mai 2023) basierend auf Hinweisen durch Text-Eingaben, sogenannten Text-Prompts, realistische Bilder erzeugen. Die KI-Methoden basieren zum einen auf multi-modalem Deep Learning (Radford et al., 2021; Fürst et al., 2022), bei dem Text und Bilder in einen gemeinsamen Raum eingebettet werden. Von diesem Raum ausgehend werden mit Diffusionsmodellen (Ho et al., 2020) in einem schrittweisen “denoising” Verfahren realistische Bilder erzeugt. Auch hier gibt es verschiedene bekannte KI-Systeme wie DALL-E2, Midjourney, und Stable Diffusion. Die Problematiken sind sehr ähnlich wie bei den großen Sprachmodellen: a) Verzerrungen, Fehler und Vorurteile werden aus den Daten mitgelernt; b) hohe Rechenkapazität ist notwendig, c) nur wenige zum überwiegenden Teil kommerzielle Institutionen haben die Ressourcen, diese Modelle zu trainieren, und d) Datenschutz Problematiken.

Stand der KI-Forschung in Österreich

Hohes Potenzial für KI-Grundlagenforschung Österreich. Österreich hat prinzipiell das Potenzial, international eine führende Rolle in der KI-Forschung einzunehmen, weil eine ausgewogene Mischung aus jungen und älteren WissenschaftlerInnen mit unterschiedlichem Hintergrund an österreichischen Institutionen forscht. Die ForscherInnen decken fast alle relevanten Teilbereiche von KI ab und haben bereits Pionierarbeit in verschiedenen Gebieten der KI geleistet. Insbesondere gibt es über Österreichs Universitäten hinweg international anerkannte ExpertInnen sowohl im Bereich der symbolischen als auch der sub-symbolischen KI. Die sogenannte dritte KI-Welle, die etwa um 2012 mit stark verbesserten Bilderkennungssystemen basierend auf Deep Learning Systemen startete (Schmidhuber, 2015) wurde von ForscherInnen an vielen Standorten in Österreich angenommen und es wurden neue

Deep Learning Systeme und Algorithmen entwickelt und publiziert. Von den drei Hauptelementen der dritten KI-Welle (Deep Learning Algorithmen, Hardware & Skalierung, und großen Datensätzen, siehe S.1), zeichneten sich ForscherInnen vor allem bei den algorithmischen Elementen aus. Aber auch große Datensätze, wie zum Beispiel ImageNet (Deng, 2009), waren in mehreren Bereichen öffentlich verfügbar, so dass es auch in dieser Hinsicht für einige Jahre möglich war, konkurrenzfähig zu bleiben. Um jedoch mit den weiteren internationalen Entwicklungen, vor allem bei Rechenkapazität und Skalierung, Schritt zu halten, forderte 2019 die österreichische Universitätenkonferenz Mittel für die a) nationale Vernetzung, b) die internationale Vernetzung und c) die Schaffung und den Ausbau von KI-Infrastruktur ([Uniko, 2019](#)). Trotz ausbleibender Maßnahmen vernetzten sich KI-ForscherInnen an Österreichs Universitäten zum **Bilateral AI Konsortium** (siehe weiter unten). Zudem wurden in den letzten Jahren auch **drei ELLIS Units** geschaffen, an der Universität Linz, am IST Austria, und an der TU-Graz. ELLIS ist ein europäisches Exzellenz-Netzwerk für maschinelles Lernen, und nur wenige renommierte Institutionen schafften es, solche Units zu etablieren. An der Johannes Kepler Universität Linz wurde 2019 ein Artificial Intelligence Studium gestartet, das mittlerweile etwa 1,500 Studierende hat. Diese Studierenden, die eine hervorragende Ausbildung sowohl in Deep Learning als auch in symbolischer KI bekommen, stellen für Österreich eine große Chance dar, eine neue Generation von KI-Systemen auf Basis dieser kombinierten Expertise zu entwickeln. Das Ausbleiben der Finanzierung von KI-Infrastruktur, konkret eines GPU-Clusters, erschwert und verhindert die Entwicklungen von größeren KI-Systemen, wie zum Beispiel von Sprachmodellen.

Als Beispiel einer Initiative zur nationalen Vernetzung dieser Expertisen sei das [Bilateral AI Konsortium](#) angeführt, das führenden KI-ForscherInnen Österreichs vereint: Es umfasst Deep Learning Pionier **Sepp Hochreiter**, der sowohl das Vanishing Gradient Problem entdeckt, als auch LSTM Netzwerke erfunden hat. Er schuf Anfang der 1990er Jahre die Grundlagen für das, was heute als Deep Learning bekannt ist. Auch seine Forschungsarbeiten der letzten Jahre hatten hohen Einfluss: Fortschritte bei der Bildgenerierung werden weltweit mit der sogenannten Frechet-Inception-Distance gemessen ([Heusel et al., 2017](#)), LSTMs werden weiterhin in vielen Reinforcement-Learning Systemen, wie AlphaStar und OpenAI Five verwendet. Die von Günter Klambauer und Sepp Hochreiter entwickelten selbst-normalisierenden Netzwerke wurden kurz darauf in Apple's Spracherkennungssoftware SIRI¹ eingebaut (Huang, 2020). **Martina Seidl** ist bekannt für ihre Arbeit im Bereich des "bit-precise reasoning", insbesondere bei der effizienten Lösung von Problemen der Aussagenlogik (SAT). **Christoph Lampert** ist einer der Pioniere von Zero-Shot Learning und der Theorie von Life-long Machine Learning. **Axel Polleres** hat sowohl an Grundlagen als auch an der Standardisierung symbolischer Methoden für die graphen-basierte semantische Datenintegration, logische Programmierung und im Bereich Semantic Web gearbeitet. **Thomas Eiter** ist ein weltweit führender Experte für Knowledge-Representation and Reasoning, logische Programmierung und deklaratives Problemlösen. **Agata Ciabattoni** ist eine Logikerin, die für ihre Arbeit an nicht-klassischen Logiken und deren Anwendungen bekannt ist. **Robert Legenstein** ist ein führender Experte für Spiking Neural Networks – einer biologisch plausiblen Version von Deep Learning. **Gerhard Friedrich** ist für seine Arbeiten zur praktischen Anwendbarkeit von korrekten, logik-basierten Methoden bekannt, insbesondere für die Bereiche des automatischen Entwurfs von komplexen technischen Systemen und der operativen Planung. Viele weitere namhafte ForscherInnen, wie z.B. die Wittgenstein-Preisträger **Georg Gottlob** und **Gerhard Widmer**, die international hoch kompetitive Förderungen durch den **European Research Council (ERC Grants)** erhalten haben, gehören dem [BILAI Konsortium](#) an. Auch außerhalb des Bilateral AI Konsortium, gibt es viele weitere hervorragende KI-ForscherInnen, die an österreichischen Universitäten und anderen Forschungseinrichtungen arbeiten.

Vergleich zu KI-Strategien in Deutschland (5 Mrd. €, 100 KI-Professuren), Niederlande (1 Mrd. €) und Schweden (0.5 Mrd€, 50 KI-Professuren), Österreich (0.007 Mrd€, prüft die Einführung von

¹ <https://machinelearning.apple.com/research/sndcnn>

Stiftungsprofessuren). Im Vergleich zu anderen europäischen Ländern, die um ca. 2019 KI-Strategien vorgestellt haben und seitdem umsetzen, ist Österreich hier leider weit abgeschlagen. Die von der Regierung 2021 vorgestellte “AI Mission Austria 2030” wird nicht als KI-Strategie gesehen, sondern als eine unklare Absichtserklärung. Konkrete Förderung von KI enthält diese Strategie nur in Form von 0.007 Mrd € für das Thema “Green AI” (BMK, 2023, S. 55) und den Hinweis, dass die Einführung von Stiftungsprofessuren geprüft werde (BMK, 2023, S. 43). 2022 wurden dem FWF 0.0019 Mrd € an Fördervolumen für Projekte in der KI-Grundlagenforschung zugeteilt und vom FWF ausgeschrieben (FWF AI, 2023). Für anwendungsorientierte KI-Forschung wurden in Österreich weitere 0.0025 Mrd € zur Verfügung gestellt. Dringend notwendige Förderschienen zur Vernetzung der Forschung auch im Grundlagenbereich sind bisher nicht themenspezifisch ausgeschrieben worden. Ein zusätzliches Problem der momentanen Förderinstrumente ist der Prozess von der Veröffentlichung der Förderschiene (“Call”), der Antragstellung und Begutachtung. Ein typischer Prozess dauert hier mindestens 6 Monate und bis zu 2 Jahre. Dies steht im Gegensatz zur extrem schnellen Entwicklungszyklen von AI Methoden: von der Veröffentlichung der Transformer-Idee bis zur breiten Aufnahme dieser Technologie dauerte es nur 1 Jahr und fünf Jahre bis zu einem Produkt, wie ChatGPT. Deshalb sind für die KI-Forschung spezifische, agile Förderschienen mit sehr kurzen Zyklen von wenigen Wochen von der Antragstellung zur Genehmigung nötig. Im europäischen Vergleich ist Österreich bei der Förderung von KI-Grundlagenforschung weit abgeschlagen. Ende 2020 wurde das Volumen der KI-Strategie von Deutschland von 3 Mrd. € auf 5 Mrd.€ erhöht mit dem Ziel, 100 KI-Professuren einzurichten. Ein vergleichbar großes Land wie Österreich, Schweden, hat mehrere Programme zur Förderung von KI (Business Sweden, 2022). In nur einem davon, WASP, werden 0.5 Mrd. € und 50 KI-Professuren gefördert (Business Sweden, 2022, S.4). Auch die Niederlande haben eine Digitalisierungsstrategie im Umfang von mehreren Milliarden Euro, von denen zumindest 1 Mrd. € an KI-Forschung vorgesehen ist (Nederland Digital, 2021).

Figure 1: State of Technology and Investments By Country

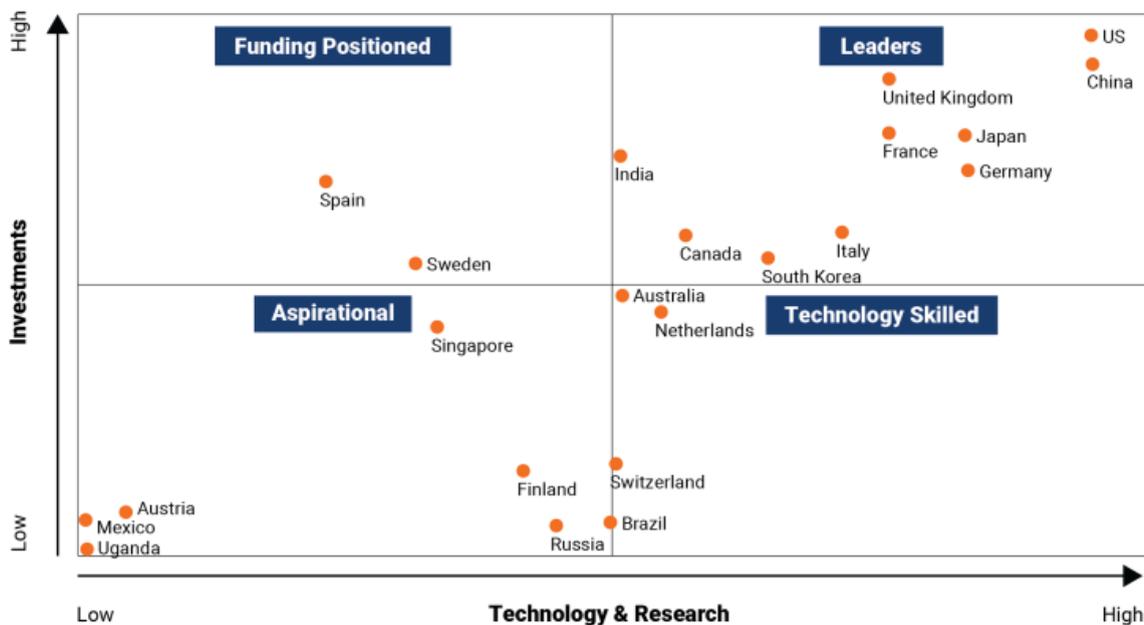


Abbildung 2. Förderung von KI-Forschung in verschiedenen Ländern aufgeschlüsselt nach den zwei Dimensionen. x-Achse: Technologie&Forschung und y-Achse: Investitionen. Österreich ist in beiden Dimensionen weit abgeschlagen. Quelle: [Brookings, 2022](https://www.brookings.edu/).

Österreich, das im Gegensatz zu vielen anderen, grösseren Ländern kaum über internationale Großunternehmen mit eigenen KI-Forschungsabteilungen verfügt, und dessen Wirtschaft stattdessen maßgeblich von KMUs sowie kleineren “Hidden Champions” getrieben ist, sollte einen ähnlichen Weg

gehen, denn nur über die Vernetzung der akademischen KI-Grundlagenforschung im Land kann die bestehende Expertise auch heimischen Unternehmen zugänglich gemacht werden. Andererseits droht die Gefahr, durch neue digitale disruptive Geschäftsmodelle international und global agierender Player, den momentan noch bestehenden Technologie-Vorsprung auch aufgrund der jüngsten raschen Weiterentwicklung im Bereich der KI zu verlieren. Ein funktionierendes Ökosystem gut geförderter und vernetzter KI-Grundlagenforschung an Österreichs Universitäten im Zusammenspiel mit bestehenden momentan jedoch zu stark auf anwendungsorientierte Forschung fokussierten Förderprogrammen könnte dem erfolgreich entgegenwirken, auch weil hier verschiedenste Wissenschaftsdisziplinen um entsprechende Förderungen konkurrieren müssen, anstatt einen klaren strategischen Fokus zu setzen. Mit einem florierenden lokalen KI-Ökosystem und seinem Fokus auf Grundlagenforschung hätte Österreich das Potenzial, einen bedeutenden Beitrag zur Weiterentwicklung der KI-Forschung und -Technologie weltweit zu leisten, die Gefahren der momentanen Technologie zu mindern, und die Potenziale - auch im Sinne der lokalen Wirtschaft - auszuschöpfen.

Konsortien

Austrian Society for Artificial Intelligence.

Bernhard Moser, Georg Dorffner, Bernhard Nessler, Axel Polleres, Stefan Woltran, Robert Legenstein, Wolfgang Faber, Günter Klambauer, Thomas Eiter, Brigitte Krenn.

Bilateral Artificial Intelligence Consortium.

Sepp Hochreiter, Thomas Eiter, Agata Ciabattoni, Gerhard Friedrich, Robert Legenstein, Christoph Lampert, Axel Polleres, Martina Seidl, Dan Alistarh, Horst Bischof, Krishnendu Chatterjee, Wolfgang Faber, Johannes Fürnkranz, Robert Galian, Martin Gebser, Georg Gottlob, Kurt Hornik, Dietmar Jannach, Sabrina Kirrane, Günter Klambauer, Elisabeth Lex, Thomas Lukasiewicz, Wolfgang Maass, Silvia Miksch, Marco Mondelli, Nysret Musliu, Magdalena Ortiz, Elisabeth Oswald, Robert Peharz, Thomas Pock, Emanuel Sallinger, Markus Schedl, Stefan Seider, Gerhard Widmer, Stefan Woltran, Franz Wotawa.

Bibliographie und Quellen

- J. Schmidhuber. Deep learning in neural networks: An overview. *Neural Networks*, 61:85–117, 2015.
- J. Schmidhuber, U. Meier, and D. Ciresan. Multi-column deep neural networks for image classification. In *CVPR*, 2012.
- Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. *P. IEEE.*, 86(11):2278–2324, 1998.
- Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. *Nature*, 521(7553):436–444, 2015.
- A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. *Adv. Neur. In.*, 25:1097–1105, 2012.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009, June). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition* (pp. 248-255). Ieee.
- K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. In *CVPR*, 2016.
- S. Hochreiter and J. Schmidhuber. Long short-term memory. *Neural Comput.*, 9(8):1735–1780, 1997.
- I. Sutskever, O. Vinyals, and Q. V. Le. Sequence to sequence learning with neural networks. *Adv. Neur. In.*, 27:3104–3112, 2014.
- A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin. Attention is all you need. *Adv. Neur. In.*, 2017.
- J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova. BERT: pre-training of deep bidirectional transformers for language understanding. In *NAACL*, 2019.
- D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. In *ICLR*, 2015.
- S. Ioffe and C. Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *ICML*, 2015.
- G. Klambauer, T. Unterthiner, A. Mayr, and S. Hochreiter. Self-normalizing neural networks. In *Adv. Neur. In.*, 2017.
- I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. Generative adversarial nets. *Adv. Neur. In.*, 27, 2014.
- D. P. Kingma and M. Welling. Auto-encoding variational Bayes. In *ICLR*, 2014.

- D. Rezende and S. Mohamed. Variational inference with normalizing flows. In ICML, 2015.
- Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. *Adv. Neur. In.* 33, 6840-6851.
- A. Radford, J. W. Kim, C. Hallacy, A. Ramesh, G. Goh, S. Agarwal, G. Sastry, A. Askell, P. Mishkin, J. Clark, G. Krueger, and I. Sutskever. Learning transferable visual models from natural language supervision. In ICML, volume 139, 2021.
- R. Hadsell, P. Sermanet, J. Ben, A. Erkan, M. Scoffier, K. Kavukcuoglu, U. Muller, and Y. LeCun. Learning long-range vision for autonomous off-road driving. *J. Field. Robot.*, 26(2):120–144, 2009.
- T. Chen, S. Kornblith, M. Norouzi, and G. Hinton. A simple framework for contrastive learning of visual representations. In ICML, 2020b.
- J. Gilmer, S. S. Schoenholz, P. F. Riley, O. Vinyals, and G. E. Dahl. Neural message passing for quantum chemistry. In ICML, 2017.
- T. N. Kipf and M. Welling. Semi-supervised classification with graph convolutional networks. In ICLR, 2017.
- A. Mayr, G. Klambauer, T. Unterthiner, M. Steijaert, J. K. Wegner, H. Ceulemans, D.-A. Clevert, and S. Hochreiter. Large-scale comparison of machine learning methods for drug target prediction on chembl. *Chem. Sci.*, 9(24): 5441–5451, 2018.
- A. Sanchez-Gonzalez, J. Godwin, T. Pfaff, R. Ying, J. Leskovec, and P. Battaglia. Learning to simulate complex physics with graph networks. In ICML, 2020
- M. Raissi, P. Perdikaris, and G. E. Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *J. Comput. Phys.*, 378:686–707, 2019.
- V. Mnih, K. Kavukcuoglu, D. Silver, A. A. Rusu, J. Veness, M. G. Bellemare, A. Graves, M. Riedmiller, A. K. Fidjeland, G. Ostrovski, et al. Human-level control through deep reinforcement learning. *Nature*, 518(7540): 529–533, 2015.
- C. Berner, G. Brockman, B. Chan, V. Cheung, P. Debiak, et al. Dota 2 with large scale deep reinforcement learning. *arXiv:1912.06680*, 2019.
- O. Vinyals, I. Babuschkin, W. M. Czarnecki, M. Mathieu, A. Dudzik, J. Chung, D. H. Choi, R. Powell, T. Ewalds, P. Georgiev, et al. Grandmaster level in starcraft ii using multi-agent reinforcement learning. *Nature*, 575(7782): 350–354, 2019.
- A. Biere, M. Jarvisalo, and B. Kiesl. Preprocessing SAT solving. In *Handbook of Satisfiability*, 2021.
- F. Rossi, P. Van Beek, and T. Walsh. *Handbook of constraint programming*. Elsevier, 2006.
- F. Baader, D. Calvanese, D. McGuinness, D. Nardi, and P. Patel-Schneider. *The description logic handbook*. Cambridge Univ. Press, 2003.
- F. Van Harmelen, V. Lifschitz, and B. Porter. *Handbook of knowledge representation*. 2008.
- G. Brewka, T. Eiter, and M. Truszczyński. Answer set programming at a glance. *Commun. ACM*, 54(12):92–103, 2011.
- M. Gebser, M. Maratea, and F. Ricca. What's hot in the answer set programming competition. In *AAAI*, 2016.
- V. Lifschitz. *Answer set programming*. Springer, 2019.
- N. Leone, G. Pfeifer, W. Faber, T. Eiter, G. Gottlob, S. Perri, and F. Scarcello. The dlv system for knowledge representation and reasoning. *ACM T. Comput. Log.*, 7 (3), 2006.
- M. Gebser, B. Kaufmann, R. Kaminski, M. Ostrowski, T. Schaub, and M. Schneider. Potassco: The potsdam answer set solving collection. *AI. Commun.*, 24(2):107–124, 2011.
- E. Erdem, M. Gelfond, and N. Leone. Applications of answer set programming. *AI. Mag.*, 37(3):53–68, 2016.
- A. Falkner, G. Friedrich, K. Schekotihin, R. Taupe, and E. C. Teppan. Industrial applications of answer set programming. *KI - Künstliche Intelligenz*, 32(2):165–176, 2018.
- A. Cali, G. Gottlob, and T. Lukasiewicz. A general datalog- based framework for tractable query answering over ontologies. *J. Web. Semant.*, 14:57–83, 2012.
- G. Gottlob, T. Lukasiewicz, and A. Pieris. Datalog+/-: Questions and answers. In *KR*, 2014.
- B. C. Grau, I. Horrocks, B. Motik, B. Parsia, P. Patel- Schneider, and U. Sattler. Owl 2: The next step for owl. *J. Web. Semant.*, 6(4):309–322, 2008.
- A. Hogan, E. Blomqvist, M. Cochez, C. d'Amato, G. D. Melo, C. Gutierrez, S. Kirrane, J. E. L. Gayo, R. Navigli S. Neumaier, et al. Knowledge graphs. *ACM Comput. Surv.*, 54(4):1–37, 2021.
- L. Bellomarini, D. Fakhoury, G. Gottlob, and E. Sallinger. Knowledge graphs and enterprise ai: the promise of an enabling technology. In *ICDE*, pages 26–37, 2019.
- J. Jumper, R. Evans, A. Pritzel, T. Green, M. Figurnov, O. Ronneberger, K. Tunyasuvunakool, R. Bates, A. Židek, A. Potapenko, et al. Highly accurate protein structure prediction with alphafold. *Nature*, 596(7873): 583–589, 2021.
- Degrave, J., Felici, F., Buchli, J., Neunert, M., Tracey, B., Carpanese, F., ... & Riedmiller, M. (2022). Magnetic control of tokamak plasmas through deep reinforcement learning. *Nature*, 602(7897), 414-419.
- Zhang, D., Mishra, S., Brynjolfsson, E., Etchemendy, J., Ganguli, D., Grosz, B., ... & Perrault, R. (2021). The AI index 2021 annual report. *arXiv preprint arXiv:2103.06312*.
- Stanford University (2023). *Artificial Intelligence Index Report 2023*.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
- Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving language understanding by generative pre-training.
- Fürst, A., Rumetshofer, E., Lehner, J., Tran, V. T., Tang, F., Ramsauer, H., ... & Hochreiter, S. (2022). Cloob: Modern hopfield networks with InfoLOOB outperform clip. *Advances in neural information processing systems*, 35, 20450-20468.
- Ganhör, C., Penz, D., Rekabsaz, N., Lesota, O., & Schedl, M. (2022, July). Unlearning Protected User Attributes in Recommendations with Adversarial Training. In *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 2142-2147).
- Heusel, Martin, Hubert Ramsauer, Thomas Unterthiner, Bernhard Nessler, Günter Klambauer, and Sepp Hochreiter. "GANs Trained by a Two Time-Scale Update Rule Converge to a Nash Equilibrium." *arXiv preprint arXiv:1706.08500* (2017).
- Huang, Z., Ng, T., Liu, L., Mason, H., Zhuang, X., & Liu, D. (2020, May). SNN-CNN: Self-normalizing deep CNNs with scaled exponential linear units for speech recognition. In *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 6854-6858). IEEE.

(Brookings,2022)

<https://www.brookings.edu/blog/techtank/2022/01/12/how-countries-are-leveraging-computing-power-to-achieve-their-national-artificial-intelligence-strategies/>

(Brutkasten, 2023) <https://brutkasten.com/artikel/wasner-zur-ki-in-oesterreich-minister-hat-job-verfehlt>

(BMK, 2021) Strategie der Bundesregierung für Künstliche Intelligenz. AI Mission Austria 2030 (AIM AT 2030)

https://www.bmf.gv.at/dam/jcr:c1312d0a-6209-4e92-8631-aea93130e392/2021-AIM_AT_2030_UA-bf.pdf

(T3N, 2021) <https://t3n.de/news/ki-strategie-investition-regierung-1342547/>

(Business Sweden, 2022) Business Sweden. SEASONS OF CHANGE AI powered by Swedish collaboration, innovation and data;

<https://www.business-sweden.com/globalassets/insights/reports/seasons-of-change.pdf>

(Nederland Digital, 2021) The Dutch Digitalisation Strategy 2021 (2021).

<https://www.nederlanddigitaal.nl/binaries/nederlanddigitaal-nl/documenten/publicaties/2021/06/22/the-dutch-digitalisation-strategy-2021-eng/210621-min-ezk-digitaliseringstrategie-en-v03.pdf>

(Uniko, 2019) Österreichische Universitätenkonferenz (2019). Positionspapier zur österreichischen Artificial

Intelligence Strategie AIM AT 2030. http://www.polleres.net/publications/uniko_POS_AI_2019.pdf

(FWF AI) FWF (2022), AI Mission Austria: aws, FFG und FWF starten gemeinsame Förderinitiative zu künstlicher Intelligenz.

<https://www.fwf.ac.at/de/news-presse/news/nachricht/nid/20221021-0>