

Hybride KI

Wissen und Daten kombiniert nutzen

IN KÜRZE

Hybride KI kombiniert auf Wissensrepräsentation basierende Ansätze und datengetriebene Herangehensweisen (maschinelles Lernen).

- **Credo:** Was die Menschheit schon weiß, muss nicht aus Daten gelernt werden.
- **Versprechen:** (Energie-)effiziente, robuste, erklärbare und vertrauenswürdige KI-Systeme, die weniger Bias unterliegen, weniger Daten für den Lernprozess benötigen und tolerant gegenüber fehlerhaften bzw. ungenauen Datenpunkten sind.
- **Potenzial:** Anwendungen, die sichere und genaue Ergebnisse erfordern (z. B. Medizin, Qualitätskontrolle).
- **Herausforderung:** Komplexität und fehlende Leitlinien für die Umsetzung sowie mangelnde Benchmarks.

Kontext

Im Bereich der Künstlichen Intelligenz (KI) wird aktuell vor allem dem maschinellen Lernen (ML) mit neuronalen Netzen (Deep Learning) große Aufmerksamkeit geschenkt. Grund dafür sind beeindruckende Ergebnisse, die zuletzt etwa bei der automatischen Text- oder Bildgenerierung erzielt wurden. Diese Erfolge beruhen im Wesentlichen auf großen Datenmengen, der Skalierbarkeit der Modelle und hohen Rechenkapazitäten. Es entsteht leicht der Eindruck, dass jedes Ziel mit maschinellem Lernen erreicht werden kann, wenn diese drei Faktoren verstärkt werden. Fundamentale Probleme großer KI-Modelle lassen sich jedoch nicht durch weitere Skalierung lösen, hinzu kommt ihr großer Ressourcenverbrauch.

Zudem wird oft übersehen, dass es sich bei einigen der viel diskutierten erfolgreichen Anwendungen um so genannte hybride KI-Systeme handelt. Diese kombinieren die Vorteile des maschinellen Lernens mit menschlichen Wissensbeständen, die auf verschiedene Weise formal repräsentiert und von Computern verarbeitet werden (siehe Tab. 3). Stößt eine der Herangehensweisen an Grenzen oder erzielt unerwünschte Ergebnisse, so kann eine Kombination Lösungswege bieten.

Ausgangspunkt für KI-Systeme: Menschliches Wissen

Um Systeme zu erstellen, die automatisch Informationen verarbeiten oder sogar auf intelligente Weise Schlussfolgerungen ziehen, kann bestehendes Wissen als Ausgangspunkt genutzt werden – sei es in Form von Erfahrungs-, Experten- oder aus Forschung gewonnenem Wissen.

Wissens- und regelbasierte Ansätze

In vielen wissenschaftlichen Disziplinen wird menschliches Wissen in Zusammenhängen und Variablen systematisiert und über mathematisch formalisierte Modelle repräsentiert. Beispiele sind Gleichungen der Regelungstheorie in der Robotik oder Modelle zur Berechnung von Meeresströmungen in der Klimaforschung. In weniger komplexen Zusammenhängen ist Wissen auch durch Wenn-Dann-Regeln oder als Heuristiken für Suchverfahren abbildbar, aber auch durch formallogische Regelwerke, Taxonomien, Ontologien oder Wissensgraphen – etwa der systematisierten Darstellung von Beziehungen zwischen Orten, Entitäten (z. B. Personen, Unternehmen) und Ereignissen. Solche Ansätze verarbeiten zum Teil automatisch Wissen. Sie führen aber keine (eigenständigen) Schlussfolgerungen aus (Reasoning).

Wissensbasierte KI (Symbolische KI)

Ziel der Wissensrepräsentation und -verarbeitung ist es, vorhandenes Wissen durch Symbole (z.B. Wörter, Zeichen) so darzustellen, dass Computer es verarbeiten können. Indem sie symbolische Informationen sortieren, (durch)suchen oder verknüpfen und eigenständig logisch schlussfolgern, erledigen sie Aufgaben oder generieren neues Wissen. Beispiele sind Verfahren zur automatischen Erstellung von Logik-basierten Programmen wie die Induktive logische Programmierung (ILP). Symbolische KI war in den 1960er- und 1970er-Jahren der führende KI-Ansatz, stieß dann jedoch an Grenzen (Tab. 1).

Tabelle 1: Vor- und Nachteile Symbolischer KI

Vorteile	Nachteile
Vorhandenes menschliches Wissen kann in Entwicklung und Betrieb von Systemen einfließen	Kostenintensiv , da viel manuelle Codierung erforderlich, um Problemstellungen in Input für die Systeme umzuwandeln
Transfer von Wissensseinheiten bei ähnlichen Anwendungen möglich	Implizites Wissen schwer darstellbar ; nicht alle denkbaren Fälle im Voraus implementierbar
Ergebnisse sind erklärbar , Schlussfolgerungen nachvollziehbar	Schwer skalierbar ; schwer verallgemeinerbar bei unterschiedlichen Anwendungen
Prozess kann kontrolliert und Fehler können korrigiert sowie formale Korrektheit geprüft werden	Schlechte Performance bei großen empirischen Datenströmen (in Echtzeit)
Am besten geeignet für gut definierbare und statische Problemstellungen sowie zur Bearbeitung und Modellierung von Abstraktionen	Systeme können schlecht mit neuen und widersprüchlichen Situationen umgehen
	Wartung ggf. schwierig , da komplexe Verifikation und Validierung erforderlich

Eigene Zusammenstellung orientiert an:
Ilkou & Koutraki (2020), Saker et al. (2021).

Ausgangspunkt für KI-Systeme: Erfasste und gesammelte Daten

Einen Gegensatz zur Symbolischen KI bildet das datenintensive maschinelle Lernen, das dem Paradigma der Subsymbolischen KI zuzuordnen ist. Dabei werden statistische Modelle auf Basis quantitativer Zusammenhänge in großen Datenmengen erlernt, um bestimmte Aufgaben (z. B. Treffen von Unterscheidungen) durchzuführen. Ziel ist es, durch mathematische Formalisierung über eine Funktion Eingabedaten auf Ausgabedaten oder Zielvariablen abzubilden, z. B. bei Bildern aus dem Straßenverkehr auf Kategorien wie „Autos“ oder „Fußgänger“. Das Modell wird aus den Daten gelernt und nicht durch den Menschen erstellt.

Eingesetzt wurden dabei lange Zeit weniger komplexe Arten des maschinellen Lernens, z. B. Support Vector-Maschinen. Aktuell dominieren künstliche neuronale Netze, die sehr abstrakt der Funktion biologischer Neuronen nachempfunden sind. Werden die künstlichen Neuronen während des Trainings aktiviert, stärkt dies bestimmte Verbindungen im Netzwerk. Die Information wird also durch die unterschiedliche Stärke der Verbindungen, auch Gewichtung genannt, repräsentiert. So wird ein Modell trainiert, das Zusammenhänge zwischen Eingabedaten (z. B. Bildern) und Ausgabedaten (z. B. Klassifikationen) abbilden kann. Sind mehrere Netzwerkschichten zwischen Ein- und Ausgabeschicht vorhanden, spricht man von Deep Learning.

Innerhalb der datengetriebenen KI werden unterschiedliche Lernverfahren eingesetzt:



Während im letzten Jahrzehnt vor allem mit überwachtem Lernen beachtliche Erfolge erzielt wurden, beeindruckt heute große, durch selbstüberwachtes Lernen erzeugte neuronale Netze durch ihre Leistungsfähigkeit – beispielsweise Sprachmodelle, die Texte entsprechend einer Anfrage generieren. Dieser Trend zeigt auch: KI-Modelle können nicht mehr nur spezifische, sondern durchaus unterschiedliche Aufgaben ausführen (z. B. Essays, Programmcode oder Übersetzungen erstellen). Allerdings sind Herausforderungen in Bezug auf Erklärbarkeit und logische bzw. mathematische Fähigkeiten nicht gelöst (Löser & Tresp et al., 2023).

Tabelle 2: Vor- und Nachteile datengetriebener KI

Vorteile	Nachteile
Sehr gut geeignet zur Lösung von Wahrnehmungs- und Steuerungsproblemen	Ressourcen- und rechenintensiv: Vorhandenes menschliches Wissen muss neu erlernt werden
Implizite Regelmäßigkeiten und Zusammenhänge werden aus Daten gelernt, daher vor der Anwendung weniger Wissen erforderlich	Erforderliche große Datenmengen und hohe Datenqualität liegen häufig nicht vor
Hohe Skalierbarkeit , insbesondere bei neueren selbstüberwachten Verfahren	Explizites menschliches Wissen oftmals für Datenauswahl und -vorverarbeitung nötig (z. B. Medizin)
Hohe Leistungsfähigkeit	Schlechte Generalisierbarkeit jenseits der Merkmalsverteilung im Trainingsdatensatz
Robustheit bei fehlerhaften, fehlenden oder unbedeutenden Daten	Verzerrungen in Trainingsdatensätzen können reproduziert werden (Bias, Diskriminierung etc.)
Wiederverwendbarkeit bei großen Modellen (z. B. Sprachmodellen) und Modellanpassung für spezifische Aufgaben und Domänen möglich	Schlechte Nachvollziehbarkeit bzw. Erklärbarkeit: sog. Black-Box-Modelle, problematisch v. a. in sicherheitskritischen Bereichen (z. B. Medizin, Mobilität)
	Schwächen beim logischen Schlussfolgern
	Oft viel menschliche Arbeit für Daten-Labeling nötig

Eigene Zusammenstellung orientiert an:
Ilkou & Koutraki (2020), Saker et al. (2021).

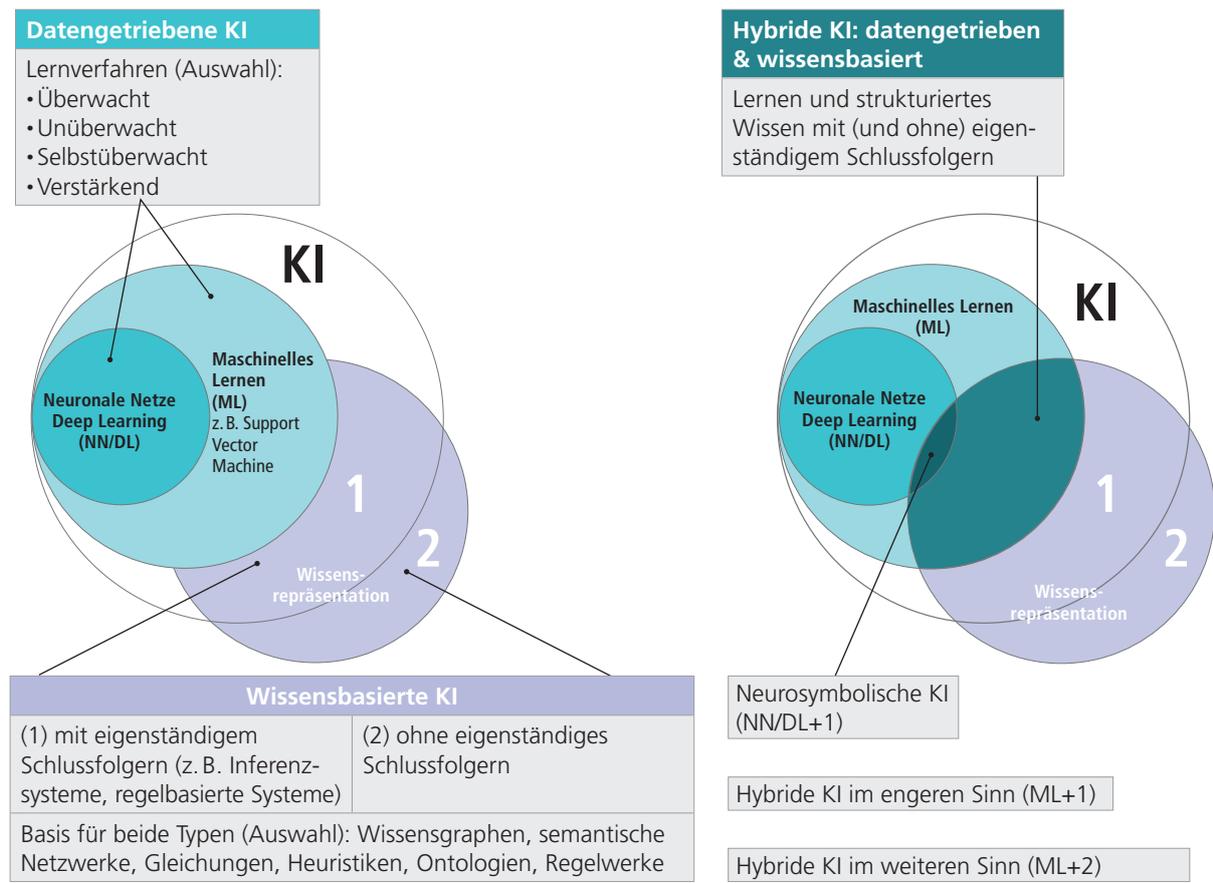
Hybride KI: Wissen und Daten als Ausgangspunkt

Hybride KI nutzt sowohl menschliches Wissen als auch gesammelte Daten, um Lösungen für Problemstellungen zu entwickeln. Möglich sind folgende Ansätze:

- **Kombination von wissensbasierten Ansätzen mit maschinellem Lernen**, z. B. Physics-informed Machine Learning (hybride KI im weiteren Sinn).
- **Kombination unterschiedlicher Paradigmen der KI-Forschung**, d. h. Symbolischer und Subsymbolischer KI (hybride KI im engeren Sinn).

Beide Herangehensweisen haben Vor- und Nachteile und können voneinander profitieren (Tab. 1, 2, 3). Mit den jüngsten Erfolgen von Deep Learning ist vor allem die Forschung zu deren Kombination mit traditioneller Symbolischer KI gewachsen. Hybride KI-Systeme werden daher gegenwärtig auch unter dem Begriff der Neurosymbolischen KI diskutiert (Abb. 1). Sie **versprechen das Beste aus zwei Welten**: Neuronale Netze behalten im Idealfall ihre Trainierbarkeit und Effektivität bei teils fehlerhaften Datensätzen, wissensbasierte Komponenten bringen Erklärbarkeit und die einfache Integration menschlichen Wissens ein.

Abbildung 1: KI-Paradigmen, KI-Typen und Lernverfahren



Quelle: Eigene Zusammenstellung basierend auf Goodfellow (2016). Das Zusammenwirken von maschinellem Lernen (ML), strukturiertem Wissen und Schlussfolgern kann sich für hybride KI im jeweiligen Anwendungskontext durchaus komplex darstellen, siehe van Bekkum et al. (2021, S. 6.539 ff.). In einem Robotersystem können beispielsweise ML, Regeln für Verhaltenseinschränkungen (siehe 2) und Schlussfolgerungen auf Basis von regelbasierten Zusammenhängen zwischen ML-Output und weiterem Analyseoutput (siehe 1) zusammenspielen (Abb. 4).

Tabelle 3: Beispiele hybrider KI

Anwendung	Wissensbasierte KI	Datengetriebene KI
AlphaGo (2016) Das KI-System schlug die besten Spieler des chinesischen Spiels „Go“	Monte-Carlo-Suche in Entscheidungsbäumen	Überwachtes und verstärkendes Lernen
Google (Stand: 2020) Pragmatischer Ansatz zur Optimierung der Internetsuche	Systeme zur Manipulation von Symbolen, z.B. Werkzeuge zur Navigation in Wissensgraphen	u. a. BERT
AlphaFold2 (2020) Vorhersage der 3D-Struktur von Proteinen	Symbolische Darstellungsformen der physikalischen 3-D-Struktur von Molekülen	Transformer
Patel & Ott (2022) Vorhersage von Kippunkten, die komplexe Systeme (z. B. Wetter, Klima) dramatisch verändern	Wissensbasierte Modellierung physikalischer Gesetzmäßigkeiten	Reservoir Computing
Kirchner et al. (2019) Grundfunktionen eines Roboters werden mit Regelungstechnik modelliert, während Wahrnehmung und Lernfähigkeit auf ML basieren	Regeln und/oder parametrische Gleichungen der Regelungstechnik	u. a. verstärkendes Lernen, Deep Learning

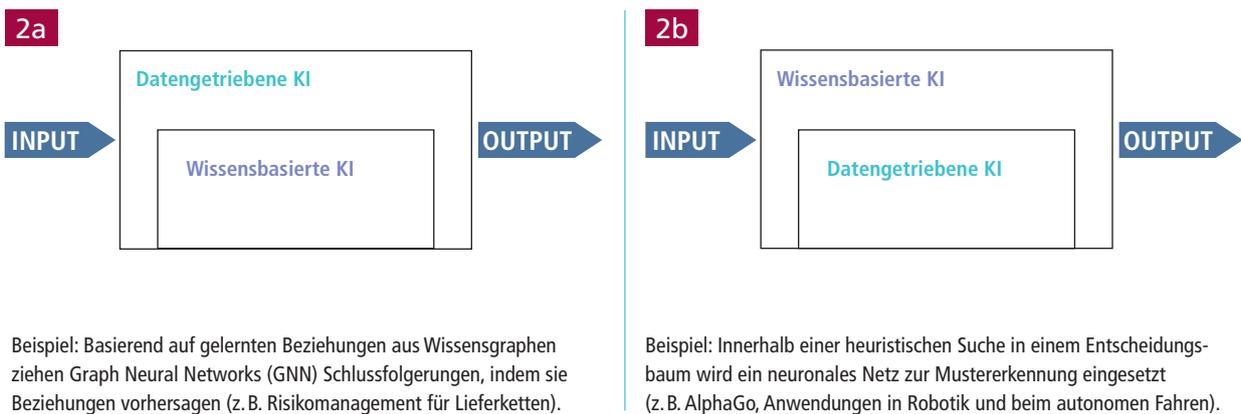
Eigene Zusammenstellung basierend auf: Kirchner et al. (2019), Marcus (2022), Patel & Ott (2022).

Exemplarische Typen hybrider KI

Von den verschiedenen Möglichkeiten für hybride KI-Systeme werden im Folgenden zwei Kombinationstypen vereinfacht vorgestellt (für umfassendere Typologien siehe Kautz, 2021, Ilkou & Koutraki, 2020, Saker et al., 2021, Hamilton et al., 2022, und für komplexere Kombinationen siehe Bekkum et al., 2021).

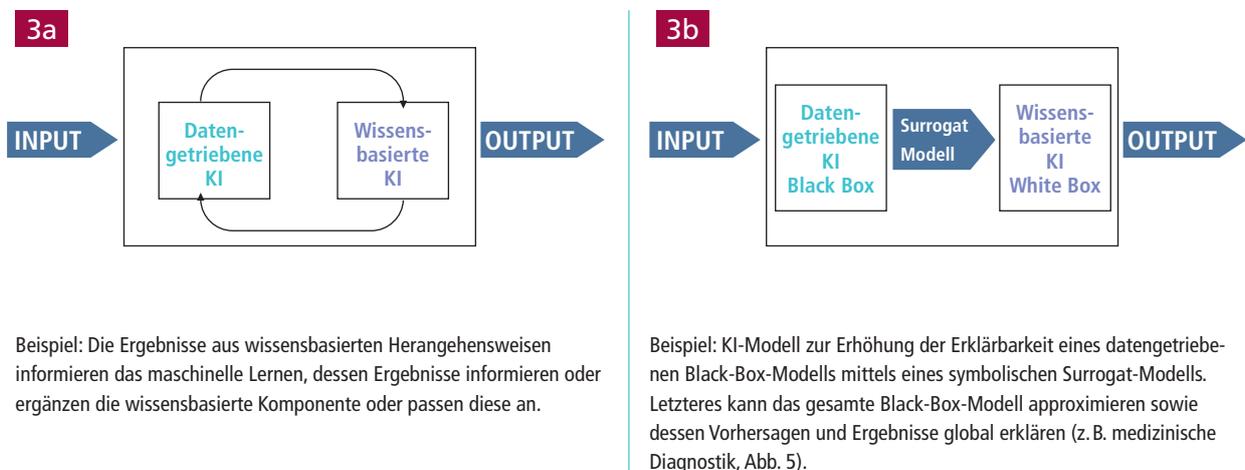
Verschachtelte Systeme: Ein KI-System besteht aus einer datengetriebenen Komponente, in die ein wissensbasiertes System eingebettet ist – oder umgekehrt (Abb. 2a, b).

Abbildung 2: Verschachtelte Systeme



Kooperative Systeme: Input wird in ein wissensbasiertes System gegeben, dessen Output wiederum Input für ein datenbasiertes System liefert – oder umgekehrt (Abb. 3a). Es entsteht ein KI-System in Form eines sich gegenseitig informierenden Kreislaufts. Auch teilkooperative Anordnungen sind möglich (Abb. 3b).

Abbildung 3: Kooperative und teilkooperative Systeme



Menschliches Wissen interaktiv einbeziehen: Anwendungsbeispiele

Hybride KI für mehr Erklärbarkeit

Hybride Ansätze ermöglichen es unter anderem, implizites Wissen zur Klassifikation von Information mit explizitem Wissen aus komplexen, relationalen Zusammenhängen zu verbinden. Zugleich können die gelernten symbolischen Regeln genutzt werden, um Erklärungen für neuronale Netze zu generieren und damit nachvollziehbar zu machen, aufgrund welcher Information das Black-Box-Modell zu einer bestimmten Klassifikation kommt. Symbolische Modelle in Form von Regeln können selbst bereits als Erklärung dienen, wenn sie nicht allzu komplex sind und die Adressaten entsprechende Kenntnisse haben. Andernfalls können aus den Regeln sprachliche Erklärungen generiert werden. In Anwendungsbereichen wie der Medizin kann es notwendig sein, dass gelernte Modelle durch menschliches Feedback korrigierbar sind (erklärbares interaktives Lernen). Dies setzt die Nachvollziehbarkeit von Modellentscheidungen voraus.

Abbildung 4: Verbesserte Erklärbarkeit in der medizinischen Diagnostik

Aufgabe

- PathologInnen bei Diagnose von Tumoren unterstützen
- Tumorgewebe erkennen und in Beziehung setzen

Ziel

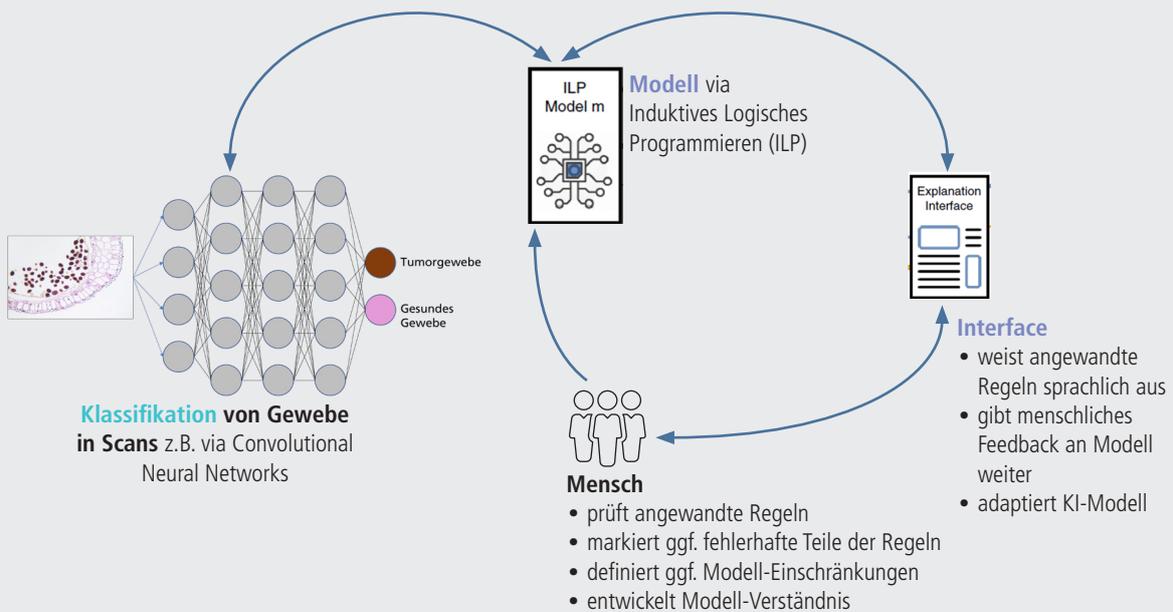
- KI-Entscheidungen transparent und verständlich machen
- Modell verbessern

Lösung

- Gewebescans werden mit datengetriebener KI klassifiziert
- Regelbasierte KI (via ILP) erstellt verständliches und korrigierbares KI-Modell
- Graphische Benutzeroberfläche zur Interaktion zwischen KI-Modell und PathologInnen

Erkennung und Erklärung von Tumoren durch Mensch-KI-Partnerschaft

Ausführung: Durch kontrastiven Vergleich der Klassifikationsergebnisse wird ein Modell gelernt, das auf der Basis von Hintergrundwissen Regeln bzgl. der räumlichen Anordnung von Gewebe in den Scans lernt.



Quelle: Eigene Zusammenstellung basierend auf Schmid und Finzel (2020).

Türkis steht für den Anteil des maschinellen Lernens und Lila für den Anteil der wissensbasierten Komponente.

Verkörperter hybride KI im Dienst des Menschen

Robotersysteme, verstanden als verkörperte KI, haben eine physische Präsenz, sind über Sensoren unmittelbar mit ihrer Umwelt verbunden und können daraus Informationen aufnehmen. Ihre Grundfunktionen gewährleisten oft regelbasierte Modelle, die auf menschliches Vorwissen zurückgehen. Beispiele hierfür sind Reflexe zur Überwindung von Hindernissen beim Laufen oder die Einschränkung des Handlungskorridors eines Roboters durch Regelsätze.

Letztere sichern verkörperte KI ab, sodass ihr Einsatz in risikoreichen Bereichen möglich wird. Auch die Bewegung eines komplexen Roboters wird oft durch Verfahren der Regelungstechnik (z. B. Optimal Control) ermöglicht. Hier werden Modelle nicht gelernt, sondern mittels von Menschen entworfener und parametrisierter Gleichungen erstellt. Mit verstärkendem Lernen können solche Modelle oder Regeln aber auch gelernt werden. Grundfunktionen können schließlich auch mit maschinellem Lernen kombiniert werden (z. B. bei Objekterkennung). Feedback aus den technischen Systemen für Grundfunktionen kann wiederum genutzt werden, um datengetriebene KI inhärent zu trainieren. Es kann als eine Art „Korsett“ oder „Korrektiv“ für das maschinelle Lernen dienen.

Abbildung 5: Unterstützung von Patientinnen und Patienten nach Schlaganfall

Aufgabe

- Rehabilitation von Schlaganfall-Patientinnen und -Patienten mit Lähmungserscheinungen

Ziel

- Gehirn rehabilitieren: Patientinnen und Patienten in intendierter Bewegung unterstützen und so involvierte Gehirnprozesse positiv bestärken

Lösung

- Exoskelette ermöglichen Patientinnen und Patienten selbstbestimmtes und nachhaltiges Training
- **Exoskelett lernt, die Intention des Menschen zu interpretieren und durch die Interaktion mit Menschen sich anzupassen**
- **Symbolische Regelwerke** gewährleisten sichere Interaktion

Mensch-Roboter-Interaktion in der Rehabilitation

Ausführung: Der gelähmte Arm wird ohne TrainerIn automatisiert geführt.

→ Gravitationskompensation des Gewichts des Exoskeletts und ggf. des Armes

Teach-in: Eintrainieren von Bewegungen durch TherapeutInnen

Mirror Mode: Gesunder Arm führt gelähmten Arm über das Exoskelett

Lernen: Algorithmus lernt aus EEG- und Muskelinformationen ein Modell, um intendierte Bewegungen zu erkennen

Korrektur: Fehlerhaften Bewegungsvorhersagen durch Einbettung in ein Regelsystem begegnen (z. B. Regeln zu Blickrichtung und Armbewegung)

Zuverlässigkeit: Logisches Schließen von zeitlicher Abfolge der Bewegungsplanung im Gehirn, Muskelaktivität und Blickrichtung auf Bewegungsziel

Model-Update: Einspeisung von Wissen in das maschinelle Lernen durch positives oder negatives Feedback



Quelle: Eigene Zusammenstellung auf Basis von Kirchner et al., 2013.

Türkis steht für den Anteil des maschinellen Lernens und **Lila** für den Anteil wissensbasierter Komponenten.

Potenziale und Herausforderungen

Hybride KI verspricht effizientere, robustere, erklärbarere und vertrauenswürdiger KI-Systeme, die weniger Bias unterliegen und weniger Daten für den Lernprozess benötigen. Im Folgenden wird ein genauerer Blick auf Potenziale und Herausforderungen geworfen:

Tabelle 4: Potenziale und Herausforderungen hybrider KI-Systeme

Potenziale	Herausforderungen
<p>Performanz und Transparenz:</p> <ul style="list-style-type: none"> Müssen Regeln nicht erst gelernt werden, kann dies die Performanz erhöhen Lernen mit wenig Daten; verbesserte Kohärenz und Konsistenz gelernter Modelle Handhabung von Szenarien, die stark von den Trainingsdaten abweichen Bessere Korrigierbarkeit von fehlerhaftem Modelloutput. Fehler sind z. B. für Domänenexperten leicht erkennbar; schnelle und unaufwändige Modellanpassung durch Einspeisung menschlicher Korrekturen wird möglich Interpretierbarkeit für Nutzende durch transparente KI-Entscheidungen Verbesserte Verankerung der Bedeutung von Wörtern in der Realität (siehe Grounding-Problem bei großen Sprachmodellen) 	<p>Allgemein:</p> <ul style="list-style-type: none"> Hybride KI-Systeme oft nicht auf andere Bereiche übertragbar Fehlende Leitlinien zur Kombination verschiedener KI-Ansätze Kein Konsens über Theorien des logischen Schließens, wie auch bei wissensbasierten Systemen Fehlende Benchmarks in der Forschung und Entwicklung hybrider KI-Systeme <p>In der Praxis:</p> <ul style="list-style-type: none"> Erstellung hybrider Systeme ist komplex und noch mit offenen Fragen verbunden (s. u. exemplarisch) Interdisziplinäre Zusammenarbeit von Forschenden und Domänenexperten nötig Domänenübergreifende Verallgemeinerung und Standardisierung technischer Lösungen
<p>Ressourceneffizienz:</p> <ul style="list-style-type: none"> Vorhandenes explizites Wissen muss nicht aufwändig maschinell gelernt werden 	
<p>Sicherheit:</p> <ul style="list-style-type: none"> Formalisierbare Regeln als Einschränkung für (teil-)autonome KI-Systeme nutzen, um unerwünschtes Systemverhalten zu regulieren 	
<p>In der Praxis:</p> <ul style="list-style-type: none"> Erwartung (Gartner 2022): Mittelfristig breite Anwendung kombinierter KI-Ansätze inkl. hybrider KI, da für Unternehmen meist günstiger als rein ML-basierte Lösungen Beispiel industrielle Qualitätskontrolle: Mustererkennung mittels Deep Learning kombiniert mit wissensbasierten Komponenten, um Ursachen für Qualitätsdefizite nachzuvollziehen 	
<p>Quellen: Eigene Zusammenstellung basierend auf: Ilkou & Koutraki (2020), Kirchner et al. (2021), Saker et al. (2021), Beyer & Müller-Quade (2022), Schmid (2022), Löser & Tresp (2023).</p>	

Welche Fragen sind offen?

- Wie lassen sich neuronale und symbolische Architekturen effektiv integrieren, v. a. zur Lösung komplexer Problemstellungen?
- Wie können Problemstellungen Symbolischer KI mit Deep Learning gelöst werden?
- Wie lässt sich Deep Learning mit Wissensbasen, -graphen und expressiven Messdaten verbessern?
- Wie kann interaktives Lernen mit komplexen symbolischen Erklärungen für eine effektive Mensch-KI-Partnerschaft umgesetzt werden?

Bewertung: Stimmen aus der Plattform Lernende Systeme



Während Ansätze des maschinellen Lernens rein datengetrieben arbeiten, erlaubt es hybride KI, vorhandenes Wissen beim Lernen zu berücksichtigen. Vom Grundsatz entspricht dies Prozessen des menschlichen Lernens: Was man schon weiß, muss man nicht immer wieder neu lernen. Hybride KI führt zu mehr Datensparsamkeit und zu robusteren Modellen.

Prof. Dr. Ute Schmid, Universität Bamberg

Menschen sind lernfähig. Sie handeln zumeist aber auf der Basis von Gelerntem und Reflexen. Entsprechend sollten wir bei der Entwicklung von Robotersystemen „integrativ“ vorgehen, indem wir hybride KI-Ansätze in regelbasierte Grundfunktionen und funktionsvorgebende Strukturen einbetten. Das spart Ressourcen ein und erhöht die Sicherheit der Systeme.

Prof. Dr. Elsa Kirchner, Universität Duisburg-Essen



Quellen

Görz, G., Schmid, U., Braun, T. (2021): Handbuch der Künstlichen Intelligenz (Aufl. 6). De Gruyter. Berlin, Boston.
<https://doi.org/10.1515/9783110659948>

Hitzler, P., Eberhart, A., Ebrahimi, M., Saker, K. & Zhou, L. (06 2022): Neuro-symbolic approaches in artificial intelligence. National Science Review, 9(6). Online unter: <https://academic.oup.com/nsr/article/9/6/nwac035/6542460>

Ilkou, E. & Koutraki, M. (2020): Symbolic Vs Sub-symbolic AI Methods: Friends or Enemies? CIKM. Online unter: <http://ceur-ws.org/Vol-2699/paper06.pdf>

Saker, K. et al. (2021): Neuro-Symbolic Artificial Intelligence. Current Trends. Online unter: <https://arxiv.org/pdf/2105.05330.pdf>



Inhalte von KIKOMPAKT können unter Nennung der Quelle Plattform Lernende Systeme für redaktionelle Zwecke genutzt werden.

Impressum

Expertise: Elsa Kirchner, Ute Schmid

Redaktion: Max Hösl, Birgit Obermeier

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

Stand: November 2023 | Bildnachweis: J. Schabel, UDE - Frank Preuß / S. 10

Folgen Sie uns auf [X](#) und [LinkedIn](#).

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung

acatech
DEUTSCHE AKADEMIE DER
TECHNIKWISSENSCHAFTEN