

Lifelong Machine Learning

Als aktueller Forschungszeitweig des klassischen maschinellen Lernens (ML) hat sich Lifelong Machine Learning (LML) in letzter Zeit signifikant weiterentwickelt. Es baut auf den Methoden des ML auf, die wesentlich für die aktuellen Erfolge auf dem Gebiet der Künstlichen Intelligenz (KI) verantwortlich sind und deren Anwendungsspektrum vom selbstfahrenden Auto bis hin zum digitalen Sprachassistenten reicht. Mittelfristig werden die Methoden des LML vielfältige Anwendungen in KI-Systemen finden und ein Schlüssel für deren erwartbar erheblichen Einfluss auf die technologische Entwicklung sein.

Bislang steht beim maschinellen Lernen der traditionelle Ansatz, das isolierte Lernen, im Mittelpunkt. Bei diesem Ansatz wird strikt zwischen Trainings- und Anwendungsphase unterschieden. Gelernt wird dabei ausschließlich in der Trainingsphase, die mit der Erstellung eines ML-Modells endet. Während der Anwendungsphase wird das Modell zwar genutzt, aber nicht mehr verändert. Im Gegensatz dazu ist das Ziel von LML, eine KI zu erschaffen, die kontinuierlich lernt, dadurch Wissen aus der Vergangenheit anhäuft und dieses dann in der Zukunft zur Problemlösung und zum weiteren Lernen nutzt. Damit können auch Erfahrungen während der Anwendung direkt in die Verbesserung des zugrunde liegenden ML-Modells einfließen, welches sich somit stetig verändert. Im Ergebnis wächst die KI mit den ihr über die Zeit gestellten Aufgaben und ist so später in der Lage, auch solche Aufgaben erfolgreich zu bearbeiten, für die sie ursprünglich nicht vorgesehen war. LML orientiert sich an der Fähigkeit des Menschen, mit nur wenigen Beispielen effektiv zu lernen. Das in der Vergangenheit angeeignete Wissen – auch und besonders aus der Beschäftigung mit verwandten Aufgabenstellungen heraus – hilft dem Menschen dabei, mit relativ wenigen Trainingsdaten und geringem zeitlichen Aufwand Neues zu erlernen und die eigenen Denkmodelle schnell und effektiv an eine neue Aufgabenstellung anzupassen. LML zielt darauf ab, diese Fähigkeit zum effektiven Lernen nachzuahmen, denn ohne sie kann ein KI-System nicht als wirklich intel-

ligent bezeichnet werden. Es wird hierfür umfangreiches, breites Erfahrungswissen benötigt, um viel leichter und einfacher lernen zu können. Daher ist für LML Wissensanhäufung wichtig. Aus einer Vielzahl unterschiedlicher Aufgaben wird eine große Menge an Erfahrungen gesammelt, um daraus genau diejenigen Teile des Wissens auszuwählen, die beim Lernen einer neuen Aufgabe helfen können.

Hauptmerkmal von Lifelong Machine Learning ist also der kontinuierliche Lernprozess. Idealerweise sollte dieser nicht nur in vordefinierten Umgebungen erfolgen, sondern er entfaltet erst im offenen Umfeld, der sogenannten Open World, sein Potenzial. Dort finden sich neuartige Herausforderungen, die vorher unbekannt waren und daher nicht explizit gelernt werden konnten. Dabei ist zu beachten, dass hier auf den ersten Blick nicht klar ist, ob die in diesem Umfeld vorhandenen Daten vertrauenswürdig und für den Wissenserwerb geeignet sind. Die reale Straßenumgebung für selbstfahrende Autos ist ein Beispiel für eine sehr typische dynamische und offene Umgebung. Der kontinuierliche Lernprozess muss dies berücksichtigen und das in der Vergangenheit erlernte Wissen gezielt auswählen, um es für zukünftiges Lernen zu nutzen. Im Idealfall sollte LML in der Lage sein, seine Lernaufgaben und Trainingsdaten in der Interaktion mit Mensch und Umwelt eigenständig zu finden, selbst wenn die Konfrontation mit einer neuen, bislang unbekanntem Aufgabe nicht schleichend, sondern abrupt erfolgt und die Aufgabe mit ihren Trainingsdaten nicht von externen Systemen oder menschlichen Nutzern bereitgestellt wird. So werden beispielsweise fahrerlose Fahrzeuge sicherer, indem sie das Wissen aus früheren Erfahrungen und Interaktionen – einschließlich der Unfälle, toten Winkeln und Schwachstellen, auf die sie während der Fahrt stoßen – auf die aktuelle Straßensituation anwenden. Jedoch sollten sich diese möglichst nicht von schlechten Angewohnheiten anderer Verkehrsteilnehmer oder von eigenen „kreativen“ Lösungen – z. B. Abkürzen durch Befahren einer Einbahnstraße in falscher Richtung – beeinflussen lassen.

Ein interessantes Resultat der Erforschung von LML-Konzepten für KI-Systeme ist die neue Generation des kommerziell erhältlichen Roboterhundes Sony Aibo (Artificial Intelligence Robot). Dieser nimmt durch Gesichts- und Spracherkennung die Reaktionen seines Besitzers auf und verbessert deren Interpretation durch LML. Ebenfalls werden so über verschiedene Sensoren Berührungen (z. B. Streicheln) immer genauer interpretiert. Damit soll sich Aibo immer besser an seinen Besitzer anpassen und zudem eine eigene Persönlichkeit entwickeln können. Optional werden seine gesammelten Erfahrungen zusammen mit den Erfahrungen anderer Aibos in einer Cloud analysiert. Durch die Ergebnisse des virtuellen Rudels kann der Hund auch von den Erfahrungen seiner Artgenossen lernen.

Obwohl das Verhalten des Aibo auf LML basiert, sind die Möglichkeiten seiner Interaktionen mit der Umwelt stark beschränkt, sodass man hier noch nicht vom Einsatz in einer Open World reden kann. Dennoch zeigt der Aibo bereits heute das künftige Potenzial von LML auf. Mittelfristig gesehen wird LML breite Anwendung in vielen KI-Systemen finden. Für die Forschung ergeben sich für die nächsten Jahre noch viele ungelöste Problemstellungen, wie z. B. die Anfälligkeit einer KI für katastrophales Vergessen. Durch das Anreichern eines ML-Modells mit neuen Trainingsdaten wird in erlerntes Wissen eingegriffen. Bereits erlernte Verhaltensweisen können so gewissermaßen vergessen werden, indem diese im schlimmsten Fall durch neue vollständig ersetzt werden. Dies kann zu einem abrupten Leistungsabfall des Modells führen. Ziel ist es auch hier, die Fähigkeit des menschlichen Gehirns zu erreichen, eine große Anzahl verschiedener Aufgaben zu lernen, ohne dass sich das jeweils Gelernte gegenseitig negativ beeinflusst. Daher wird jedes LML-System immer einen Kompromiss finden müssen zwischen Plastizität, um neues Wissen aufzubauen, und Stabilität, um nicht katastrophal in das konsolidierte Wissen einzugreifen.

Dr. Dirk Thorleuchter