

MASCHINELLES LERNEN ERPROBEN UND ERLEBEN

Die Entwicklung von Anwendungen mit Künstlicher Intelligenz (KI) erfordert von Studierenden ein übergreifendes Verständnis von Algorithmen, Daten und domänenspezifischem Wissen. Der hier beschriebene problemorientierte Lehransatz stützt sich auf Fallstudien.

IMPULSBETRAG: VICTOR PANKRATIUS

Der Begriff „Künstliche Intelligenz“ umfasst eine ganze Palette von Methoden, die typischerweise das Ziel haben, Systeme mit „intelligenten“ Merkmalen wie Kognition, Inferenz, Adaptation und Autonomie auszustatten (vgl. Kaplan & Haenlein 2019). In diesem Rahmen haben maschinelle Lernverfahren – zu denen beispielsweise auch neuronale Netze gehören – die Aufgabe, Muster aus Daten zu erlernen und für Entscheidungen nutzbar zu machen. In der Praxis gewinnen sie an Bedeutung, beispielsweise für Klassifikation in Diagnoseverfahren, Mustererkennung in Bildern und Signalen oder beim Verstehen natürlicher Sprache.

BESONDERE ASPEKTE IN DER LEHRE

In der klassischen Programmierung wird das Verhalten von Software durch eine Anforderungs- und Verhaltensspezifikation a priori vollständig definiert. Der Programmierende hat die Kontrolle über den Programmablauf und kann testen, ob ein Ablauf die Vorgaben erfüllt. Im Gegensatz dazu sind maschinelle Lernverfahren datengetrieben, das heißt, sie leiten ihr Verhalten aus Datenbeispielen beziehungsweise gewünschten Ein-/Ausgaben ab. Sie kommen dann zum Einsatz, wenn genaue Ablaufzusammenhänge nicht vollständig bekannt sind oder deren explizite vollständige Beschreibung zu aufwendig wäre. Daher ist es wichtig, die Rahmenbedingungen für den Einsatz von maschinellem Lernen zu verstehen und die Sichtweise kennenzulernen, dass man typischerweise nicht das „Wie“, sondern das „Was“ definiert.

DIE ROLLE VON FALLSTUDIEN

Fallstudien bieten eine passende Umgebung für das Erlernen, Erproben und Erleben von maschinellen Lernverfahren anhand von konkreten Problemen. Mit einer geeigneten thematischen Abgrenzung können sie eine Brücke zwischen folgenden Aspekten schlagen: (1) Daten: Woraus soll gelernt

werden? (2) Algorithmen: Wie und was wird maschinell gelernt? (3) Domänenspezifisches Wissen: Welches Problem wird gelöst? Wie kann man die Eingaben und die Ergebnisse interpretieren? Welchen Nutzen hat der Benutzer?

Der Nutzen von maschinellen Lernverfahren wird oft aus hypothetischen, kleinen Beispielen nur schwer ersichtlich und macht sich erst bei großen beziehungsweise komplexen Datenmengen bemerkbar. Daher bieten Fallstudien mit geeignet aufbereiteten Datenmengen, Verarbeitungsumgebungen (zum Beispiel voreingestellte Cloud-Umgebungen) und Kontextbeschreibungen eine Möglichkeit, sich modular in der notwendigen Tiefe mit einem Problem explorativ zu beschäftigen. Thematische Breite kann anschließend durch die Bearbeitung mehrerer Fallstudien erreicht werden.

EIN PROBLEMORIENTIERTER LEHRANSATZ

Das folgende Vorgehensmodell strukturiert die Planung und Durchführung von Fallstudien für eine problemorientierte Lehre in der Künstlichen Intelligenz (KI) in mehrere Phasen. Im Folgenden wird dieser Ansatz anhand einer konkreten Erprobung am Massachusetts Institute of Technology, USA, be-

DR. VICTOR PANKRATIUS



Foto: privat

ist Forschungsgruppen- und NASA-Projektleiter für Data Science und künstliche Intelligenz am Massachusetts Institute of Technology (MIT), USA.

pankrat@mit.edu



In den untersuchten Lehrveranstaltungen ging es um Astronomie und Geowissenschaft.

sprochen, die im Rahmen von vier verschiedenen Lehrveranstaltungen von 2015 bis 2019 mit Gruppengrößen bis zu 20 Graduierten-Studierenden durchgeführt wurden.

PHASE 1: WAHL DES PROBLEMKONTEXTS

Die Lehrveranstaltungen wurden mit dem Ziel konzipiert, Interdisziplinarität zu erleben und KI-Anwendungen in der Astronomie und in den Geowissenschaften zu explorieren sowie Prinzipien in diesem Kontext näher zu erläutern. Dementsprechend partizipierten Studierende mit Programmiererfahrung aus der Informatik beziehungsweise der Astro-/Geo-Physik.

Bei der Wahl des Problemkontextes haben mehrere Faktoren eine Rolle gespielt, zum Beispiel: öffentlich zugängliche Daten der Nationalen Aeronautik- und Raumfahrtbehörde NASA (National Aeronautics and Space Administration), der Europäischen Weltraumorganisation ESA (European Space Agency), der US-amerikanischen Wissenschaftsbehörde zur Untersuchung geologischer Strukturen USGS (United States Geological Survey), Amazon Open Data, geeignet strukturierbare Probleme oder Teilprobleme für die Dauer eines Semesters, Ressourcenanforderungen, Interessantheit und Potenzial für intrinsische

Motivation für die Studierenden sowie gesellschaftliche Relevanz. Die Möglichkeit, anhand aktueller Daten potenziell selbst eine neue Entdeckung machen zu können, hat viele Studierende stark motiviert, sich mit KI zu beschäftigen und Phasen des Misserfolgs eigenständig zu überwinden.

Thematisch haben die Lehrveranstaltungen Themen im Weltraum abgedeckt, wie zum Beispiel die Suche nach Planeten außerhalb unseres Sonnensystems (Exoplaneten) mit Daten des TESS-Satelliten (TESS 2019), die Suche nach Phänomenen in Teleskopbildern, die Nutzung von geostationären Satelliten sowie terrestrischen Sensornetzwerken für die Detektion von Naturkatastrophen wie Erdbeben oder Vulkanaktivität.

Bei den Dozierenden hat sich eine Doppelspitze bewährt, der je eine Person aus der Informatik und einer domänenspezifischen Wissenschaft angehört, um dem interdisziplinären Charakter einer solchen Lehrveranstaltung in Breite und Tiefe Rechnung zu tragen (T-Shaped Qualifikationsprofil; Grasso & Burkins 2010). Grundsätzlich ist die Rolle der Dozierenden als Lernbegleiter zu verstehen, die Studierenden relevantes Wissen auf den Weg geben, während sie ihnen bei der Problemlösung beratend zur Seite stehen.

PHASE 2: UMRIS UND VORBEREITUNG VON FALLSTUDIEN

Die Vorbereitung der Lehrveranstaltungen kann sich an Ansätzen wie „Facilitated Problem Solving“ (Hmelo-Silver 2004) orientieren. Dies hat die Entwicklung verschiedener Kompetenzen zum Ziel, etwa Problemlösekompetenz, Befähigung zum selbstgesteuerten und lebenslangen Lernen und zur Kollaboration sowie die Entwicklung intrinsischer Motivation zum Lernen.

UNSERE PARTNER

Die Impulsbeiträge in der Reihe „Praxis lehren“ entstehen in Zusammenarbeit mit dem Hochschuldidaktik-Expertenteam Katrin Klink (KIT Karlsruhe), Kristina Müller (Ruhr-Universität Bochum), Dr. Stephanie Müller-Otto (Hochschule der Medien, Stuttgart), Dr. Birgit Szczyrba (Technische Hochschule Köln) sowie Matthias Wiemer (Universität Göttingen).

„Während der Projektarbeit wechseln die Dozierenden in die Rolle von Coaches“

Für maschinelles Lernen können Dozierende zunächst in Brainstorming-Sessions Problemfelder identifizieren, die für maschinelles Lernen geeignet sind. Als Kriterien fließen dabei die Verfügbarkeit und Qualität von Daten sowie die Zugänglichkeit der Datenformate ein. Falls maschinelle Lernverfahren wie „supervised learning“ zum Einsatz kommen sollen, muss in dieser Phase auch sichergestellt werden, dass annotierte Datensätze zur Verfügung stehen oder sie entsprechend erstellt werden. Anhand von Beispielfällen spielen die Dozierenden kleine Machbarkeitsstudien und didaktisch relevante Szenarien durch.

Der Problemkontext muss möglichst modular gehalten werden, um Studierenden im Rahmen einer Einarbeitung ein Problemverständnis und die Interpretation von Ergebnissen zu erlauben. In dieser Vorbereitungszeit müssen auch Software-Werkzeuge und -Umgebungen evaluiert werden, um ihre Tauglichkeit für den spezifischen Problemhintergrund festzustellen.

PHASE 3: ENABLING

Diese Phase hat zum Ziel, Studierende mit gerade genug Anschubwissen auszustatten, damit sie sich selbstständig in die Details einarbeiten und die Fallstudien bearbeiten können. Diese Phase steht für Hilfe, es selbst zu lernen und zu tun.

In der Erprobung des Lehrkonzepts haben die zwei Fachdozierenden jeweils abwechselnd Vorlesungen gehalten, sodass Studierende schrittweise sowohl für die KI-Verfahren als auch für die Problembereiche in Astro-/Geo-Themen sensibilisiert wurden. Die Vorlesungen hatten interaktiven Charakter und es

wurde auf Vorwissen der Studierenden zurückgegriffen, das in Phase 2 als notwendige Voraussetzung für die Veranstaltung erachtet wurde.

Übungen in der Enabling-Phase sind punktueller Natur, dienen dem Verständnis allgemeiner Prinzipien und dem Ausprobieren von Verfahren im Kleinen auf Basis von Daten bekannter Benchmarks. In dieser kontrollierten, aber vereinfachten Umgebung lassen sich auch maschinelle Lernmethoden und Werkzeuge miteinander vergleichen. Während dieser Phase wurden Studierende aufgefordert, sich gegebenenfalls selbst aus dem Problemkontext ein Thema und damit verbundene Datensätze zu suchen. Am Ende halten die Studierenden einen Vortrag zu ihrem Projektkonzept und bekommen Feedback von den Dozierenden sowie den Mitstudierenden.

PHASE 4: PROJEKTPHASE MIT FALLSTUDIENBEARBEITUNG

In der vierten Phase bearbeiten alle Studierenden selbstständig ein eigenes Projekt, in dem maschinelle Lernverfahren auf einen realen Problemkontext mit realen Daten angewendet werden. Dies begünstigt den eigenständigen Transfer des erlernten Grundlagewissens. Weiterhin können Studierende erleben, dass die Anwendung von maschinellem Lernen oft nicht trivial ist und Kreativität erfordert. Beispielsweise müssen Eingabe-Datenformate verstanden und Rohdaten für die Anwendung von maschinellen Lernverfahren vorbereitet werden. Verbunden damit sind Strategien, wie mit fehlenden oder unvollständigen Daten, Rauschen oder anderen Problemen umgegangen werden soll.

Während der Projektarbeit wechseln die Dozierenden verstärkt in die Rolle von Coaches, die Studierenden helfen, aufkommende Hürden zu nehmen. Besonderes priorisiert werden sollte die schnelle Erstellung einer funktionierenden Software-Umgebung, die iterativ verbessert werden kann. Als Vorlage werden agile Softwareprozesse von Beck et al empfohlen, in denen in „Sprints“ inkrementell neue Funktionen hinzugefügt und getestet werden. Anhand von Metriken (zum Beispiel „Accuracy“ im Lernverfahren) können die Studierenden dann auch selbst entscheiden, wie unterschiedliche Herangehensweisen ihr Ergebnis beeinflussen. Nach Bedarf empfiehlt es sich, in dieser Phase auch vereinzelt Lehrveranstaltungen durchzuführen. Diese sollen auf Schwierigkeiten und „Lessons Learned“ eingehen, die bei Studierenden beobachtet wurden. In den erprobten Lehrveranstaltungen haben Studierende beispielsweise wöchentlich einen kurzen Bericht an die Dozierenden verfasst und etwa nach der Hälfte der Projektarbeitszeit einen Vortrag über den Zwischenstand gehalten. Diese Meilensteine ermöglichen einen Peer-Vergleich, dienen der Lernerfolgskontrolle und bieten auch zusätzliche Motivationsanreize.

PHASE 5: FINALISIERUNG UND REFLEXION

Die Lehrveranstaltung endet mit einer Phase, in der Studierende eine Präsentation über ihr Projekt halten und einen Projektbericht abgeben. In der Präsentation geht es primär darum, dass jeder das für sich selbst neu Erlernte aufzeigt und den eigenen Fortschritt vor und nach der Veranstaltung deutlich macht. In der Finalisierung stehen nicht nur Erfolge im Vordergrund, sondern auch

Misserfolge, eingeschlagene Wege, Einsichten und Empfehlungen für die Zukunft. Erfolge und Misserfolge in der Anwendung von maschinellem Lernen können im Detail sowohl auf der technischen Ebene (wie und warum hat etwas funktioniert?) als auch auf der fachlichen Ebene (was bedeutet das Ergebnis für das Gebiet?) diskutiert werden. Die Präsentationen finden interaktiv statt, das heißt, Mitstudierende und Dozierende können den Vortrag jederzeit unterbrechen und Fragen stellen oder Diskussionen anregen. Die Dozenten und Dozentinnen moderieren und tragen gegebenenfalls auch selbst mit Antworten und Ergänzungen bei.

ZUSÄTZLICHER MEHRWERT DES LEHRANSATZES: FÖRDERUNG VON SCHLÜSSELKOMPETENZEN

Durch seine Problemorientierung und den hohen Grad an Eigenständigkeit der Studierenden ist der oben genannte Lehransatz dazu geeignet, neben fachlichen Kompetenzen auch Schlüsselkompetenzen aus- und aufzubauen:

Strukturierungskompetenz

Für die Anwendung von maschinellem Lernen sind die Entwicklung einer Problemstrukturierungskompetenz sowie der Aufbau einer Verständnisstruktur (vgl. Zumbach) wichtig.

Der beschriebene Ansatz lässt den Studierenden genug Raum, um zu erleben, dass gegebenenfalls einzelne maschinelle Lernverfahren zum Teil nicht ausreichen, um komplexe Gesamtprobleme zu lösen. Daher müssen unterschiedliche Teilaspekte eines Problems auch einzeln und mit unterschiedlichen Mitteln angegangen werden.

Forschungskompetenz

Durch die Wahrnehmung der Grenzen von maschinellen Lernverfahren an realen Problemen wird eine kritische Evaluation und Einsatzkompetenz entwickelt. Studierende, die nach neuen Forschungsthemen suchen, können fundierte Einsichten gewinnen, wo aktuelle Verfahren ganz konkret an Grenzen stoßen, wie die Verfahren etwa erweitert werden könnten oder wo radikal neue Ansätze notwendig werden.

Frustrationstoleranz

In der problemorientierten Fallstudienbearbeitung können Studierende erleben, dass Ansätze, die zunächst vielversprechend scheinen, in konkreten Situationen nicht zum erhofften Erfolg führen. Diese Fälle können die Dozierenden als Vehikel nutzen, um übergeordnete Vorgehensstrategien zu besprechen. In diesem Rahmen können Studierende Entscheidungskompetenz entwickeln und die Bewertung von Erfolgsaussichten mit Kosten-Nutzen-Analysen trainieren. Des Weiteren können Studierende auch Vorschläge unterbreiten, die Problemvoraussetzungen zu ändern. Die Dozierenden müssen den Studierenden immer wieder klar machen, dass der Erfolg nicht notwendigerweise nur im Sinne eines erfolgreichen Endergebnisses messbar ist, sondern auch in der systematischen und reflektierten Verfolgung unterschiedlicher Wege und dem daraus gewonnenen Verständnis. Es geht um den relativen Lernzuwachs für einen selbst und um den individuell gemeisterten Weg („Distance Travelled“).

ZUSAMMENFASSUNG

Zusammenfassend lässt sich feststellen, dass die folgenden Faktoren sich als Erfolg versprechend bei der Lehre Künstlicher Intelligenz herausgestellt haben:

- Fallstudienbasierte/problemorientierte Lehransätze, im Idealfall in Verbindung mit realen Forschungs- oder Industrieprojekten,
- die direkte Verknüpfung mit domänenspezifischen Anforderungen, gegebenenfalls im Teamteaching mit einer Lehrperson aus dem jeweiligen Fach, um eine hohe Anwendungsorientierung zu erzeugen,
- kontinuierliches Feedback sowie Raum zur Reflexion.

In diesem Rahmen ist es Studierenden auch gelungen, diverse Erfolge über die Lehrveranstaltung hinaus zu erzielen. Beispielsweise sind Artikel basierend auf den Ergebnissen der Lehrveranstaltungsprojekte in Fachjournals publiziert und in den MIT-News erwähnt worden. Einige Studierende sind auch im MIT-Team der NASA TESS Mission beschäftigt worden. Weiterhin konnten Erfolge in Vorstellungsgesprächen verzeichnet werden, die Erfahrung mit KI-Anwendungen erforderten. //

LITERATUR

Beck, K. et al. (2001). Manifesto for Agile Software Development. <http://agilemanifesto.org>

Grasso, D. & Burkins, M. (Hrsg.) (2010). Holistic Engineering Education: Beyond Technology. New York, Springer

Hmelo-Silver, C.E. (2004). Problem-Based Learning: What and how do students learn
Educational Psychology Review 16(3), S. 235–266

Kaplan, A. & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons* 62(1), January–February 2019, S. 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>

The Transiting Exoplanets Survey Satellite (TESS) (2019). <https://tess.mit.edu>, zuletzt abgerufen am 29.04.2019

Zumbach, J. (2003). Problembasiertes Lernen. Münster, Waxmann

NOCH MEHR DUZ



BLEIBEN SIE AUF DEM LAUFENDEN!

Registrieren Sie sich für den Newsletter der DUZ-Redaktion und lassen Sie sich regelmäßig über die Themen der DUZ informieren. // www.duz.de/service/newsletter

BESUCHEN SIE UNS!

Werfen Sie einen Blick auf unsere Webseite. Hier finden Sie ausgewählte Beiträge aus dem Magazin, exklusive Online-Artikel sowie ein umfangreiches Archiv. Weiterhin haben Sie Zugriff auf unseren Stellenmarkt für Wissenschaft, Forschung und Management und unseren Web-Kiosk mit allen E-Journals. // duz.de

LESEN SIE MEHR!

Auf die DUZ können Sie sich verlassen. Erhalten Sie das Magazin jeden Monat im Jahresabonnement – als E-Journal im Web-Kiosk und in der DUZ App oder als Print-Ausgabe direkt per Post. // www.duz.de/abo

LESEN SIE WEITER!

Die DUZ App bietet Ihnen ein multimediales Leseerlebnis. In die Texte integrierte Weblinks geben Ihnen die Möglichkeit, sich über die Magazinartikel hinaus zu informieren. Maps, Videos und Bildergalerien vervollständigen die Beiträge. // duz-app.de

LESEN SIE ZWEISEITIG!

Das DUZ Magazin konzentriert sich auf den Dialog von Wissenschaft und Gesellschaft. Allen, die am Management von Wissenschaftseinrichtungen interessiert sind, bietet Wissenschaft & Management nützliches Praxis- und Hintergrundwissen. // wissenschaft-und-management.de