

Grundkonzepte des Maschinellen Lernens für die Grundschule – Algorithmen, Biases, Generalisierungsfehler

Ute Schmid¹ Anja Gärtig-Daug² Linda Müller³ Alexander Werner⁴

Abstract: Da digitale Technologien zunehmend mehr Lebens- und Arbeitsbereiche durchdringen, gewinnt die Förderung digitaler Kompetenzen bereits ab der Grundschule an Bedeutung. Durch entsprechende Bildungsangebote sollen Kinder beim Erschließen, Verstehen und Mitgestalten der digitalen Welt unterstützt werden. Hierbei ist wichtig, nicht nur digitale Handlungskompetenzen auf der Anwendungsebene zu fördern, sondern Kinder beim Verstehen der zugrundeliegenden Funktionsprinzipien zu unterstützen. Ein grundlegendes Verständnis der algorithmischen Konzepte, die den digitalen Anwendungen zugrundeliegen ist hierfür zentral. Zunehmend beinhalten digitale Anwendungen Komponenten, die auf Ansätzen der Künstlichen Intelligenz (KI) basieren. Kinder begegnen solchen Systemen etwa in Form von intelligenten Sprachassistenten bei Fernsehern oder beim Entsperren von Smartphones mittels Gesichtserkennung. Damit das kindliche Verständnis von KI-Technologien gefördert werden kann, muss das komplexe Thema für Kinder in didaktisch reduzierter Form erfahrbar gemacht werden. Wir haben hierzu ein Spiel entwickelt, mit dem Kinder grundlegende Konzepte des maschinellen Lernens wie regelbasierte Algorithmen (Entscheidungsbaumverfahren) und neuronale Netze (Perzeptron) spielerisch erkunden können. Neben einem Grundverständnis von Lernalgorithmen werden Kinder für kritische Aspekte wie Biases und Generalisierungsfehler sensibilisiert. Durch Rückbezug des Spiels auf KI-Algorithmen im Alltag sollen die Kinder zur Reflektion der Möglichkeiten und Grenzen von KI angeregt werden.

Keywords: Künstliche Intelligenz; Maschinelles Lernen; Bias; Generalisierungsfehler; Primarbereich

1 Einleitung

Künstliche Intelligenz (KI) erfährt seit einigen Jahren viel Aufmerksamkeit. Das lang etablierte Forschungsgebiet der Angewandten Informatik befasst sich mit der Entwicklung von Algorithmen zur Lösung von Problemen, die Menschen im Moment noch besser lösen können [Ri83]. KI-Methoden werden immer dann notwendig, wenn ein Problem nicht mit Standardalgorithmen der Informatik lösbar ist. Das ist insbesondere dann der Fall, wenn Probleme so komplex sind, dass deren vollständige Bearbeitung nicht effizient möglich ist, oder wenn das Problem und seine Lösung nicht genau beschreibbar sind. Für den ersten Fall werden heuristische Verfahren der Suche und Inferenz eingesetzt, im zweiten Fall kommt

¹ Universität Bamberg, Kognitive Systeme und Forschungsgruppe Elementarinformatik (FELI), An der Weberei 5, 96045 Bamberg, ute.schmid@uni-bamberg.de

² Universität Bamberg, FELI und Zentrum für Lehrerinnen- und Lehrerbildung Bamberg (ZLB): Kompetenzzentrum Digitales Lehren und Lernen, anja.gaertig-daug@uni-bamberg.de

³ Universität Bamberg, FELI, linda-margareta.mueller@stud.uni-bamberg.de

⁴ Universität Bamberg, FELI und LS Empirische Bildungsforschung, alexander.werner@uni-bamberg.de

maschinelles Lernen zum Einsatz. Einen Überblick über Methoden und Themengebiete der KI gibt zum Beispiel [GSB20].

Infolge der zunehmenden Durchdringung aller Lebens- und Arbeitsbereiche mit digitalen Technologien wird es als Aufgabe der Schule erachtet, Kinder beim Erschließen, Verstehen und Mitgestalten der digitalen Welt zu unterstützen. Für einen souveränen Umgang mit digitalen Medien wird es als wichtig erachtet, nicht nur – oft produktbezogene – Bedien- und Anwendungskompetenzen zu fördern, sondern Kindern ein Verständnis von informatischen Konzepten zu ermöglichen, die den Anwendungen zu Grunde liegen [Dö16; GWS19]. Längst haben intelligente Spielsachen und smarte Geräte Einzug in die kindliche Lebenswelt genommen. Kinder begegnen dem Thema KI in Medien und im Alltag auf unterschiedliche Art, etwa in Form von Roboterhunden, die auf Befehle hören und unterschiedliche Personen erkennen, intelligenten Sprachassistenten bei Fernsehern oder beim Entsperren von Smartphones mittels Gesichtserkennung. Kinder zeigen großes Interesse an diesen Funktionen und haben Spaß daran, die Grenzen dieser Systeme auszutesten. Für sie (wie vermutlich auch für die meisten Jugendlichen und Erwachsenen) ist jedoch nicht ersichtlich, warum ihr Roboterhund nur manchen Befehlen folgt, sie auf eine Anfrage eine sinnvolle Antwort erhalten, auf eine andere hingegen nicht, oder warum das eigene Smartphone auch entsperrt wird, wenn der Bruder in die Kamera blickt, ohne dass seine biometrischen Daten in den Einstellungen hinterlegt wurden.

Die Begegnung mit KI-Technologien beeinflusst die Vorstellung von Kindern zu Eigenschaften, Möglichkeiten und Kontrollierbarkeit von KI [BC08; VTV20]. Je mehr Erfahrung Kinder mit KI-Technologien sammeln und umso intensiver sie sich mit den zugrunde liegenden Algorithmen auseinandersetzen können, desto realistischer schätzen sie smarte Geräte ein. So können sie eher zwischen menschlicher und künstlicher Intelligenz unterscheiden [BC08; WPB19]. Damit das kindliche Verständnis von KI gefördert werden kann, muss das komplexe Thema geeignet aufbereitet und erfahrbar gemacht werden. Um Kindern bereits im Vor- und Grundschulalter den Aufbau richtiger mentaler Modelle zu ermöglichen und Misskonzeptionen zu vermeiden, eignen sich Spiel- und Erfahrungsmaterialien, die einen Blick in die Blackbox KI ermöglichen sowie zum Austausch und zur Reflektion der Erfahrungen innerhalb der Klasse sowie der Familie anregen [Dr18; SLR19].

Angesichts der vielfältigen Ansätze und Forschungsrichtungen innerhalb der KI stellt sich die Frage, welche Themen für Grundschulkinder besondere Relevanz haben und einer kindgerechten Vermittlung zugänglich sind. Orientierungspunkt hierbei können auf der einen Seite die kindliche Lebens- und Erfahrungswelt [Ir18] und auf der anderen Seite die fünf „Big Ideas“ der KI darstellen [To19]. Demzufolge sollte Kindern das Verständnis ermöglicht werden, dass (1) Computer ihre Umwelt nur über Sensoren wahrnehmen können, (2) ihr Denken auf (vereinfachten) Repräsentationen der Umwelt basiert, die mittels Algorithmen manipuliert werden können, um neue Informationen aus bereits Bekanntem zu generieren, (3) sie zum Lernen große Mengen an Daten benötigen, die ihnen (zumeist) von Menschen bereitgestellt werden müssen, (4) die menschliche Interaktion mit intelligenten Agenten eine große Herausforderung darstellt, da menschliche Sprache, Gefühle oder Handlungsabsichten

nur bedingt erkannt werden können und (5) KI-Anwendungen sowohl positive als auch negative Wirkungen auf die Gesellschaft haben können. Dies kann erreicht werden, indem Kinder KI-Aspekte in bekannten Anwendungen entdecken und sich selbst mit einem KI-System (zum Beispiel zur Klassifikation von Bildern) auseinandersetzen.

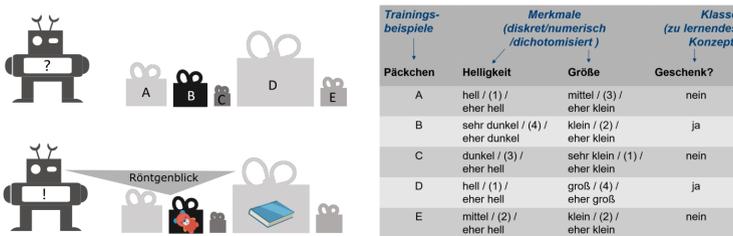
Die aktive Beschäftigung fördert neben der Motivation, sich mehr mit dem Thema auseinanderzusetzen, auch die Fähigkeiten im Bereich Computational Thinking [SL20]. Neben der Anknüpfung an die kindlichen Erfahrungen mit KI sollte auch die aktive Auseinandersetzung mit der Thematik in den Fokus von Lerneinheiten gestellt werden. Hier bieten sich Tätigkeiten an, für die die Kinder die notwendigen Fähigkeiten selbst besitzen, welche aber eben auch von intelligenten Systemen ausgeführt werden können. Anhand der Beobachtung der eigenen Herangehensweise an Aufgaben erwerben Kinder einen eigenen Zugang zum Verständnis der Simulation menschenähnlichen Verhaltens von KI-Systemen [HS19]. Zur Förderung von *AI Literacy* empfiehlt es sich deshalb, grundlegende Konzepte ab Kindergarten oder der Grundschule mit steigendem Schwierigkeits- und Abstraktionsniveau in die schulische Bildung einzubinden [Ka16; To19]. Im Allgemeinen dienen multimodale und spiel-basierte Lernansätze sowie herausfordernde, aber nicht überfordernde Lerninhalte und -materialien dazu, das kindliche Interesse und Verständnis von KI zu fördern [HS19].

Das komplexe Thema KI haben wir seit 2017 für Kinder und Jugendliche ab zwölf Jahren aufgearbeitet [SWS19]: Neben maschinellem Lernen wird in [SWS19] logikbasiertes Schlussfolgern als zweiter grundlegender Methodenbereich eingeführt und Spielen, Sprechen und Fühlen als wichtige Anwendungsgebiete vorgestellt. Um ein Verständnis aufzubauen, wie KI-Algorithmen funktionieren, wurden für alle Themen vereinfachte Umsetzungen in Python schrittweise entwickelt und konkrete Vorschläge zu algorithmischen Erweiterungen gegeben. Für den Bereich maschinelles Lernen wurde ein Anwendungsbeispiel konzipiert, das sich sowohl für das Lernen aus Tabellendaten als auch für das Lernen aus Bilddaten eignet und anhand dessen sowohl symbolische als auch neuronale Ansätze des maschinellen Lernens umgesetzt werden können. Passend zu den in [SWS19] ausgearbeiteten Themen existieren auch erste didaktisch reduzierte analoge Materialien, um Menschen ohne Informatikkenntnisse [SLR19] sowie jüngeren Kindern einen spielerischen, erfahrungsbasierten Zugang zum Thema KI zu geben.⁵ Hier bauen wir auf unsere bereits für andere grundlegenden Themen der Informatik und des algorithmisch-logischen Denkens entwickelten Materialien auf [GWS19; Kö20].⁶

In diesem Beitrag stellen wir die für maschinelles Lernen entwickelten Materialien vor, die sich an Grundschulkindern der 3. und 4. Klasse richten. Im nächsten Abschnitt wird das Lernproblem beschrieben, anhand dessen grundlegende Konzepte und verschiedene Algorithmen des maschinellen Lernens eingeführt werden können. Danach werden Entscheidungsbaumlernen sowie Perzeptronlernen für diese Beispieldomäne demonstriert. Im vierten Abschnitt zeigen wir, wie für das Verständnis und die Beurteilung wichtige

⁵ https://wehrfritz.com/de_DE/wehrfritz-digital-starter-maschinelles-lernen--367487

⁶ https://wehrfritz.com/de_DE/themenmagazin/bildungsbereiche/mathematik-informatik-naturwissenschaft-und-technik/medienkompetenz/digitalstarter



Trainingsbeispiele	Merkmale (diskret/numerisch /dichotomisiert)		Klasse (zu lernendes Konzept)
Päckchen	Helligkeit	Größe	Geschenk?
A	hell / (1) / eher hell	mittel / (3) / eher klein	nein
B	sehr dunkel / (4) / eher dunkel	klein / (2) / eher klein	ja
C	dunkel / (3) / eher hell	sehr klein / (1) / eher klein	nein
D	hell / (1) / eher hell	groß / (4) / eher groß	ja
E	mittel / (2) / eher hell	klein / (2) / eher klein	nein

Abb. 1: Das Lernproblem: Ein Roboter bekommt 5 Päckchen präsentiert, von denen einige ein Geschenk enthalten. Aus der Erfahrung mit diesen Beispielen soll er eine Hypothese aufbauen, welche Eigenschaften Päckchen haben, in denen ein Geschenk zu finden ist. Für neue Päckchen kann er dann entscheiden, ob es sich lohnt, sie zu öffnen oder nicht. Für verschiedene Lernalgorithmen werden unterschiedliche Darstellungen der Werte (z. B. Ziffern oder grobe Kategorien) genutzt.

Eigenschaften sowie grundsätzliche Grenzen von maschinellem Lernen anhand des Beispiels verdeutlicht werden können. Abschließend bewerten wir unser Konzept kritisch und geben einen Ausblick auf geplante weiterführende Arbeiten.

2 Ein induktives Lernproblem: Vielversprechende Päckchen

Die am meisten eingesetzte Art von maschinellen Lernverfahren sind sogenannte überwachte Verfahren (*supervised learning*). Hier geht es darum, aus gegebenen Trainingsbeispielen $D \subset X$ eine Funktion $f : X \rightarrow Y$ zu approximieren, die für eine meist unendliche Menge von Instanzen X eine passende Ausgabe Y liefert. Ist Y zweiwertig, handelt es sich um ein Problem des Konzeptlernens; ist Y eine Menge von diskreten Werten, handelt es sich um Klassifikationslernen; ist Y ein metrischer Wert, so handelt es sich um Regressionslernen. Im Folgenden beschränken wir uns auf Konzeptlernen. Beim überwachten Lernen wird für jedes Trainingsbeispiel die korrekte Ausgabe mit angegeben. Man sagt, die Daten sind gelabelt. Ist die Ausgabe eindeutig bekannt, so spricht man von *ground truth*. Das ist für viele visuelle Alltagskonzepte der Fall. Beispielsweise können wir bei Tieren oder deren Abbildungen eindeutig entscheiden, ob es sich um eine Katze handelt oder nicht. Die meisten Ansätze des maschinellen Lernens sind für Tabellendaten – als Merkmalsvektoren – definiert: Jede Instanz wird als Vektor von Werten für vorgegebene Merkmale beschrieben. Viele Probleme liegen in Form von Tabellendaten vor. Möchte man aber zum Beispiel ein Konzept aus Bilddaten lernen, muss man zunächst Merkmale definieren und die Merkmale dann aus den Bildern extrahieren. Aktuell finden vor allem Ansätze Beachtung, bei denen eine solche Vorverarbeitung von Daten nicht notwendig ist. So kann man etwa mit Faltungsnetzen (*convolutional neural networks*) direkt aus Bildern lernen.

Das Lernproblem, das wir als Beispiel verwenden, um maschinelles Lernen in der Grundschule einzuführen, ist in Abbildung 1 dargestellt. Ein Roboter – oder auch die Kinder selber

– erhalten einige Päckchen und sollen raten, ob ein Geschenk darin ist. Das zu lernende Konzept ist also „Päckchen, das ein Geschenk enthält“. Gegeben sind fünf Trainingsbeispiele. Die Päckchen unterscheiden sich in Größe und Helligkeit der Verpackung. Die Merkmale sind mit diskreten Werten oder alternativ als fünf Zahlenwerte angegeben. Die fünf Beispiele decken nicht alle möglichen Merkmalskombinationen ab. Werden Größe wie Helligkeit mit jeweils vier verschiedenen Werten angegeben, so gibt es 16 verschiedene Päckchen. Würden die Werte metrisch angegeben, existieren prinzipiell unendlich viele Möglichkeiten, wie ein Päckchen aussehen kann. In der letzten Spalte der Tabelle wird die Klasse angegeben, also, ob das Päckchen ein Geschenk enthält oder nicht.

Wir haben bewusst eine Beispieldomäne konstruiert, bei denen auch für uns nicht direkt ersichtlich ist, zu welcher Klasse eine Instanz gehört. Würde man maschinelles Lernen etwa mit Tierbildern vermitteln wollen, so wäre es sehr schwer, Kindern überhaupt zu vermitteln, warum hier ein Lernproblem vorliegt, weil sie ja direkt sehen, um welches Tier es sich handelt. Bevor konkrete Lernalgorithmen eingeführt werden, können die Kinder versuchen, das Lernproblem selber zu lösen. Sie können Vermutungen anstellen, welche Arten von Päckchen (Kombination von Merkmalsausprägungen) wohl ein Geschenk enthalten und dies an neuen Päckchen testen. Dies kann man mit aus Pappe gestanzten Bildern von Päckchen umsetzen, auf deren Rückseite ein Röntgenblick ins Päckchen möglich ist. Dieses Lernproblem ist passend zu der Lebenswelt der Kinder, da diese bei feierlichen Anlässen auch oft versuchen, den Inhalt des Geschenks anhand verschiedener Eigenschaften wie der Größe zu erraten.

3 Grundlegende Algorithmen des Maschinellen Lernens: Perzeptron und Entscheidungsbaum

Will man nun, gegeben die Trainingsbeispiele in Abbildung 1, eine Funktion approximieren, die bei ungesehenen Päckchen vorhersagen kann, ob ein Geschenk enthalten ist, muss man Muster entdecken, die helfen, die beiden Arten von Päckchen möglichst gut zu unterscheiden. Ein einfacher Lernalgorithmus, der bereits in den 1940er Jahren entwickelt wurde, ist das Perzeptron. Das Perzeptron ist ein idealisiertes Neuron und entspricht einer linearen Funktion. Die in Abbildung 2 dargestellte Grundform setzt mathematische Konzepte voraus, die deutlich über die Primarstufe hinausgehen. Es wird eine gewichtete Summe der Eingabewerte berechnet. Auf das Ergebnis wird eine Schwellwertfunktion angewendet. Ist der Wert größer null, so wird angenommen, dass die aktuelle Instanz zum Konzept gehört (1). Der Perzeptron-Lernalgorithmus ändert iterativ die Gewichte so, dass die Vorhersagen für die Trainingsbeispiele immer besser zutreffen. Das Gewicht w_0 wird dabei konstant mit 1 multipliziert und modelliert die Verschiebung der gewichteten Summe von Null.

Als für die Grundschule geeignete Vereinfachung kann hier mit einer festen Zahl von zwei Merkmalen gearbeitet werden. Die Gewichte werden als Wichtigkeit des Merkmals bezeichnet (siehe Abb. 2). Lernen meint also, zu erkennen, welches Merkmal wie wichtig ist, um das Konzept „enthält Geschenk“ vorherzusagen. Sagt das Perzeptron vorher, dass ein

Geschenk enthalten ist, dies ist aber nicht der Fall, sind die Gewichte zu hoch. Sie können erniedrigt werden, indem die Werte der Eingaben von denen der Gewichte subtrahiert werden (für $i = 1 \dots n$: $w_i \leftarrow w_i - x_i$). Umgekehrt werden die Gewichte erhöht, wenn falsch vorhergesagt wurde, dass kein Geschenk enthalten ist. Falls Subtraktion zu schwierig ist, können die Werte auch durch Erhöhung und Erniedrigung um einen festen Wert (zum Beispiel 1) geändert werden. Die Beispiele in Abbildung 1 wurden so konstruiert, dass nach wenigen Anpassungen alle Beispiele korrekt klassifiziert sind und dass die gelernten Gewichte auch für weitere Pakete korrekte Vorhersagen machen. Mögliche Werte für die beiden Gewichte sind 1 und -2. Um negative Zahlen zu vermeiden, kann statt auf „größer als Null“ ein höherer Wert angegeben werden.

Ein klassisches neuronales Netz kann auf Grundlage des Perzeptrons hergeleitet werden: Ändert man die Schwellwertfunktion zu einer differenzierbaren Funktion (beispielsweise eine Sigmoidalfunktion) und schaltet zwischen die Eingabeknoten und die Ausgabe weitere Perzeptrons, so entsteht ein Multi-Layer Perzeptron. Hier werden die Gewichte basierend auf partiellen Ableitungen (*backpropagation*) verändert. Hier könnte man die Kinder

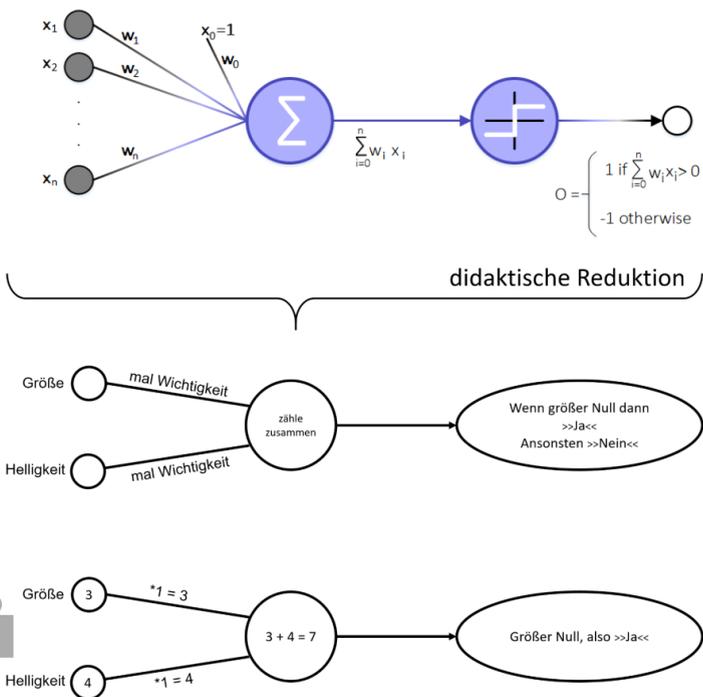


Abb. 2: Perzeptron in seiner allgemeinen Form (oben), in der didaktisch reduzierten Variante (mitte) und mit einer exemplarischen Verrechnung möglicher Merkmalswerte in der didaktisch reduzierten Form (unten).

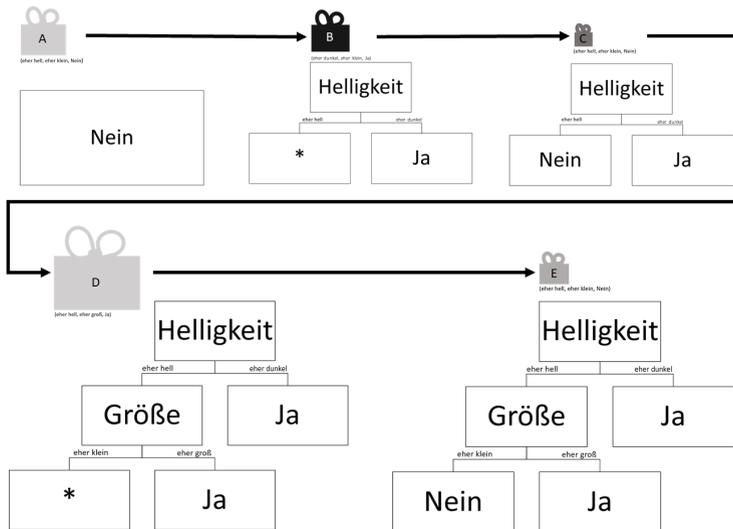


Abb. 3: Durch die serielle Prüfung der einzelnen Trainingsbeispiele, kann schrittweise ein Entscheidungsbaum erstellt werden.

ein Netz aus mehreren Knoten malen lassen und erläutern, dass das Lernen auch hier durch Veränderung der Gewichte passiert, das Rechnen aber komplizierter wird. Mit dem Perzeptron haben die Kinder Lernen als Berechnen von Wichtigkeiten kennengelernt. Dieses Prinzip liegt allen statistischen Ansätzen des maschinellen Lernens zugrunde. Hier können Beziehungen zu Alltagserfahrungen der Kinder, etwa zur Gesichtserkennung beim Entsperren von Smartphones, hergestellt werden.

Alternativ kann Lernen als explizites Konstruieren von Entscheidungsregeln modelliert werden. Der erste Entscheidungsbaumalgorithmus wurde in den 1970er Jahren entwickelt. Moderne Weiterentwicklungen wie Random Forests gehören bis heute zu den am meisten in der Praxis verwendeten Lernverfahren. Um das Beispiel einfach zu halten, werden die Merkmalsausprägungen im Päckchenbeispiel in zwei grobe Wertebereiche eingeteilt (siehe Abb. 1). Entscheidungsbaumlernen funktioniert allgemein aber auch für größere Wertemengen und auch für metrische Werte. Die meisten aktuell verwendeten Algorithmen betrachten die gesamte Trainingsmenge auf einmal. Wir verwenden einen einfachen inkrementellen Algorithmus (CAL2), der auf dem auch bei anderen Regel-Lernverfahren genutzten Prinzip des *sequential covering* basiert. Ausgewählte Zwischenschritte und der resultierende Baum werden in Abbildung 3 dargestellt.

Begonnen wird mit einem Baum, der aus einem einzigen Knoten besteht, der als Klassenausgaben ein Symbol für „unbekannt“ (zum Beispiel einen „*“) liefert. Das erste Päckchen wird präsentiert. Die Rückmeldung ist ein *. Also schauen wir in das Päckchen und sehen,

dass kein Geschenk enthalten ist. Das Fragezeichen wird durch den konstanten Wert „Nein“ überschrieben, was der übergeneralisierten Annahme entspricht, dass Päckchen keine Geschenke enthalten (links oben in Abb. 3). Das zweite Päckchen enthält jedoch ein Geschenk, also muss der Baum korrigiert werden. Das erste Merkmal wird genutzt und wir vermuten nun, dass eher dunkle Päckchen ein Geschenk enthalten. Das dritte Paket widerspricht der Erfahrung nicht. Die Hypothese ist nun, dass sehr dunkle Päckchen ein Geschenk enthalten, eher helle nicht. Das vierte Päckchen ist allerdings eher hell und enthält ein Geschenk. Der Entscheidungsbaum muss wieder korrigiert und erweitert werden. Das zweite Merkmal Größe wird anstelle der falschen Klassenentscheidung eingefügt (unten rechts in Abb. 3). Am Ende wurde der als letztes gezeigte Entscheidungsbaum aufgebaut, der für alle fünf Trainingsbeispiele und die entsprechend konstruierten Testpäckchen korrekt vorhersagen kann, ob ein Päckchen ein Geschenk enthält. Im Kontext von NLP (*Natural Language Processing*) werden häufig solche regelbasierten Ansätze zur Klassifikation hergestellt, etwa um Fakenews zu erkennen. Hier kann für die Kinder ein Bezug zu Anwendungen von Sprachassistenten hergestellt werden.

4 Was man über maschinelles Lernen wissen sollte: Biases und Generalisierungsfehler

Grundlegende Konzepte, mathematische Grundlagen und Algorithmen des maschinellen Lernens werden sowohl in allgemeinen Lehrbüchern zur KI als auch in speziellen Lehrbüchern eingeführt. Einen niedrigschwelligen Einstieg ermöglicht [KLR19]. Dort sind auch die oben besprochenen Algorithmen und deren Hintergrund anschaulich dargestellt.

Wenn Kinder zunächst selbst versuchen, zu schließen, in welchen Päckchen wohl ein Geschenk vorhanden ist, erleben sie ein Grundprinzip des induktiven Lernens – nämlich, dass aus Beispielen generalisierte Konzepte fehlerhaft sein können. Wendet man ein Verfahren des maschinellen Lernens auf einen Echtweltdatensatz an, so behält man eine Teilmenge der Daten zurück. So kann man für das Gelernte Modell abschätzen, wie die Klassifikationsleistung – die prädiktive Performanz des Modells – auf bislang ungesehenen Daten in der Zukunft sein wird. Ein Modell, das zu 99% korrekte Vorhersagen macht, macht bei jeder hundertsten Instanz einen Fehler. Dies kann Kindern sehr gut am Erkennen von Verkehrszeichen oder Ampeln veranschaulicht werden: Jedes hundertste Mal wird ein Stoppschild oder eine rote Ampel übersehen (*miss*) oder ein anderes Schild bzw. eine andere Ampelfarbe fälschlicherweise als Stoppschild oder rot erkannt (*false alarm*). Gemeinsam mit den Kindern kann überlegt werden, was in diesen Szenarien passieren kann. Zudem kann diskutiert werden, in welchen Bereichen solche Fehler schlimme Konsequenzen haben können, beispielsweise in den Bereichen Verkehr oder Medizin, und in welchen Bereichen weniger schlimme Folgen zu erwarten sind, beispielsweise bei Empfehlungssystemen. Als Konsequenz sollte gezogen werden, dass maschinelles Lernen Computer und Roboter dazu befähigt, Aufgaben ähnlich intelligent zu lösen wie wir Menschen, aber, dass sie dann auch Fehler machen – wie wir Menschen auch.

Induktives Lernen ist – egal ob bei Mensch oder Computer – nur möglich, wenn das Lernsystem einen induktiven Bias aufweist. Dieser – typischerweise implizite – Bias ist Voraussetzung dafür, dass generalisiert werden kann. Bei Menschen wird der Bias sichtbar, wenn Kinder erste Konzepte erwerben und etwa das schon erworbene Konzept einer Katze auch auf ein Eichhörnchen anwenden oder die regelmäßige Form der Vergangenheitsbildung auch auf unregelmäßige Verben übertragen („gegangen“). Die Schattenseite unserer enormen Fähigkeit zum induktiven Lernen sind Vorurteile und Stereotype wie „Jungen sind schlecht in Deutsch, Mädchen sind schlecht in Mathematik“. Anders als KI-Systeme verfügen Menschen über die Fähigkeit der Meta-Kognition. Wenn man uns auf ein Vorurteil hinweist, können wir versuchen, dem entgegenzuwirken, auch wenn es nicht immer gelingt.

Eine zweite Art von Bias ist der sogenannte *sampling bias*, der sich auf die Auswahl der Daten, mit denen gelernt wird, bezieht. Wird maschinelles Lernen auf vorhandene Daten angewendet, ohne deren Verteilung auf die verschiedenen Zielklassen zu beachten, kann dies zu unbeabsichtigter Diskriminierung oder zum „Klugen Hans Effekt“ führen. Im zweiten Modell scheint es so, als ob das Modell beispielsweise Pferde erkennen kann, aber die Klassifikation erfolgt aufgrund einer zufällig korrelierten Information wie etwa dem Bildhintergrund. Wird das Modell auf ungesehene Daten angewendet, bei denen diese Information fehlt, kann es die Klasse nicht mehr erkennen. Unfaire Modelle durch Diskriminierung sowie Nutzung irrelevanter Information basieren auf Überanpassung an die Trainingsdaten (*overfitting*). Um Kindern dieses Problem erfahrbar zu machen, kann beispielsweise eine neue Trainingsmenge von Päckchen gezeigt werden, bei der bei allen Päckchen, die ein Geschenk enthalten, eine andere Hintergrundfarbe gegeben ist. Bei den Testdaten haben dann alle Päckchen den gleichen Hintergrund.

Menschen neigen dazu, ihren eigenen Fähigkeiten auch KI-Systemen zuzuschreiben. Beispielsweise verbinden viele Menschen mit der Bezeichnung maschinelles Lernen ähnliche Eigenschaften, wie sie menschliches Lernen aufweist. Insbesondere wird angenommen, dass Lernen grundsätzlich lebenslang (inkrementell) erfolgt, während die meisten maschinellen Lernansätze zunächst aus vielen Daten ein Modell aufbauen und das Modell nachfolgend nicht mehr verändert wird. Menschliches Lernen ist zudem nie rein datengetrieben, bereits erworbenes Wissen wird genutzt, um die Plausibilität von induktiven Schlüssen zu überprüfen. In vielen Bereichen können Menschen aus sehr wenigen Beispielen generalisieren. Dies gilt für symbolische Bereiche wie grammatikalisches Wissen, aber auch für komplexe visuelle Bereiche. Diese Eigenschaften können durch Kontrastierung mit den eingeführten Lernverfahren Perzeptron und Entscheidungsbaum herausgearbeitet werden.

5 Ausblick

Wir haben die Päckchen-Domäne vorgestellt, die geeignet ist, verschiedene Algorithmen und grundlegende Konzepte des maschinellen Lernens auf spielerische Art für den Primarbereich zu vermitteln. Dabei gehen wir von der Perspektive der Informatikdiaktik aus, basierend auf der Annahme, dass digitale Kompetenz nur dann sinnvoll aufgebaut werden kann, wenn

die Funktionsweise der den Anwendungen zugrundeliegenden Algorithmen verstanden wird. Digitale Kompetenz in diesem Sinne zeichnet sich dadurch aus, dass die Nutzung komplexer Systeme auf einem tieferen konzeptuellen Verständnis basiert und damit eine bessere Einschätzung und Bewertung des Systemverhaltens und in der Folge ein souveräner und selbstbestimmter Umgang mit digitalen Medien ermöglicht wird. Gerade bei komplexen Anwendungen mit KI-Komponenten besteht die Gefahr eines zunehmenden Digital Divide. Es ist zu hoffen, dass gezielte schulische Bildungsangebote, die sich nicht auf höhere Bildung beschränken, helfen können, dem entgegenzuwirken. Die Erprobung und empirische Evaluation der vorgestellten Materialien wird im digitalen Lehr- und Lernlabor für Vor- und Grundschule der Otto-Friedrich-Universität Bamberg (FELI-Lab) erfolgen.

Literatur

- [BC08] Bernstein, D.; Crowley, K.: Searching for signs of intelligent life: An investigation of young children's beliefs about robot intelligence. *The Journal of the Learning Sciences* 17/2, S. 225–247, 2008.
- [Dö16] Döbeli Honegger, B.: Mehr als 0 und 1: Schule in einer digitalisierten Welt. Bern, 2016.
- [Dr18] Druga, S.; Williams, R.; Park, H. W.; Breazeal, C.: How smart are the smart toys? children and parents' agent interaction and intelligence attribution. In: *Proc. of 17th ACM Conference on Interaction Design and Children*. S. 231–240, 2018.
- [GSB20] Görz, G.; Schmid, U.; Braun, T., Hrsg.: *Handbuch der Künstlichen Intelligenz*. de Gruyter, 2020.
- [GWS19] Gärtig-Daug, A.; Werner, A.; Schmid, U.: Wie funktioniert das? – Informatische Konzepte in der Vor- und Grundschule spielerisch begreifen und anwenden. In (A. Pasternak, Hrsg.): *INFOS 2019. GI*, S. 377, 2019.
- [HS19] Ho, J. W.; Scadding, M.: Classroom Activities for Teaching Artificial Intelligence to Primary School Students. In: *Proc. Int. Conf. on Computational Thinking Education, CoolThink, Hong Kong*. S. 157–159, 2019.
- [Ir18] Irion, T.: Wozu digitale Medien in der Grundschule? Sollte das Thema Digitalisierung in der Grundschule tabuisiert werden? *Grundschule aktuell* 142/, S. 3–7, 2018.
- [Ka16] Kandlhofer, M.; Steinbauer, G.; Hirschmugl-Gaisch, S.; Huber, P.: Artificial intelligence and computer science in education: From kindergarten to university. In: *2016 IEEE Frontiers in Education Conference (FIE)*. IEEE, S. 1–9, 2016.
- [KLR19] Kersting, K.; Lampert, C.; Rothkopf, C., Hrsg.: *Wie Maschinen lernen – Künstliche Intelligenz verständlich erklärt*. Springer, 2019.

- [Kö20] Köhler, K.; Schmid, U.; Weiß, L.; Weitz, K.: Pixel & Co. - Informatik in der Grundschule. Westermann, 2020.
- [Ri83] Rich, E.: Artificial Intelligence. McGraw-Hill, New York, 1983.
- [SL20] Shamir, G.; Levin, I.: Transformations of computational thinking practices in elementary school on the base of artificial intelligence technologies. In: Proc. of EDULEARN20 Conference. Bd. 6, S. 1596–1605, 2020.
- [SLR19] Seegerer, S.; Lindner, A.; Romeike, R.: AI Unplugged – Wir ziehen Künstlicher Intelligenz den Stecker. In (Pasternak, A., Hrsg.): INFOS 2019. Bd. P-288. LNI, Gik, S. 325–334, 2019.
- [SWS19] Schmid, U.; Weitz, K.; Siebers, M.: Künstliche Intelligenz selber programmieren für Dummies Junior. Wiley, 2019.
- [To19] Touretzky, D.; Gardner-McCune, C.; Martin, F.; Seehorn, D.: Envisioning AI for K-12]: What should every child know about AI? In: Proc. of the AAAI Conference on Artificial Intelligence. Bd. 33. 01, S. 9795–9799, 2019.
- [VTV20] Vartiainen, H.; Tedre, M.; Valtonen, T.: Learning machine learning with very young children: Who is teaching whom? International Journal of Child-Computer Interaction 25/, S. 100182, 2020.
- [WPB19] Williams, R.; Park, H. W.; Breazeal, C.: A is for artificial intelligence: the impact of artificial intelligence activities on young children’s perceptions of robots. In: Proc. of CHI Conference on Human Factors in Computing Systems. S. 1–11, 2019.