

## **Intuitiver Zugang zu datenbasierten Entscheidungsbäumen**

### **Einleitung**

Dieser Beitrag befasst sich mit Ausschnitten einer Unterrichtsreihe in der Sekundarstufe zum maschinellen Lernen (ML) und künstlicher Intelligenz (KI) am Beispiel datenbasierter Entscheidungsbäume. In der Entwicklung im ProDaBi Projekt ([prodabi.de](http://prodabi.de)) war u. a. der Diskurs über den Begriff Artificial Intelligence (AI) Literacy eine Orientierung. Es werden dazu Kompetenzen vorgeschlagen, die von eher technischen Inhalten (z. B. ML Steps; Decision-Making) bis hin zu eher diskursiven Inhalten (z. B. Human Role in AI; Ethics) reichen (Casal-Otero et al., 2023; Long & Magerko, 2020). Auf dieser Basis konzipierten wir eine dreiteilige Unterrichtsreihe mit den Schwerpunkten (Datenbasierte Modellerstellung, Phänomene in der Anwendung von ML, Verantwortungsvoller Umgang mit ML). In diesem Beitrag fokussieren wir auf Teil 1 der Reihe, der sich mit dem datenbasierten Erstellungsprozess eines Entscheidungsbaums befasst. Wir verfolgen dabei einen White-Box Ansatz (Mike & Hazzan, 2022), d. h. es soll umfassend vermittelt werden, was ein Entscheidungsbaum ist und wie man ihn datenbasiert erstellt. In Black-Box Ansätzen (Hitron et al., 2019; Vartiainen et al., 2020) wird auf ein solch genaues Verständnis des Prozesses verzichtet und man zielt eher darauf ab das Verhalten der resultierenden Modelle zu untersuchen. Im Mathematikunterricht möchten wir aber den datenbasierten Erstellungsprozess beleuchten, da dadurch die Nützlichkeit mathematischer Konzepte offenbar wird und das Verständnis vieler weiterer Aspekte sonst nur oberflächlich bleiben könnte. Eine Herausforderung des White-Box Ansatzes ist, dass bei den Lernenden keine höheren mathematischen Vorkenntnisse und keine Programmierkenntnisse vorausgesetzt werden können.

### **Datenbasierte Entscheidungsbäumen mit der Software CODAP**

Ein Werkzeug für das manuelle Erstellen und Visualisieren von Entscheidungsbäumen ist die Software CODAP ([codap.concord.org](http://codap.concord.org)). Entscheidungsbäume sind Klassifikatoren, d. h. damit kann man einem Objekt basierend auf charakterisierenden (Prädiktor-)Merkmalen die Ausprägung eines Zielmerkmals zuordnen. Ein solcher Klassifikator wird auf der Basis einer Menge von Objekten entwickelt, für die die Ausprägungen der Prädiktormerkmale und des Zielmerkmals bekannt sind. Das sind die sogenannten Trainingsdaten. Später wird er dann an Testdaten getestet. Als Gütemaßstab dienen statistische Gütemaße (z. B. Fehlklassifikationsrate (FKR), Sensitivi-

tät). Mit CODAP ist es möglich, zu gegebenen Daten manuell einen Entscheidungsbaum zu erstellen und dynamisch die Gütekriterien des Baums zu erfassen. Für den Unterricht wird ein im Jahr 2021 von uns erhobener Datensatz zur Mediennutzung von über 1200 Jugendlichen (160 Merkmale) genutzt (Podworny et al., 2022). Eine Stichprobe mit 53 Fällen und 15 je binär codierten Merkmalen ist eine reduzierte Form dieses Datensatzes (Abb. 1).

cases (53 Fälle)															
In- dex	Spielen OnlineSpiele	Geschlecht	Tablet Besitz	Computer Besitz	FesteKonsol e Besitz	Smartpho ne Besitz	E Reader Besitz	Nutzen Twitter	Nutzen Snapchat	Nutzen Ins- tagram	Youtube Mu- sikvideos	Youtube LetsPlay	Youtube LustigeClips	Youtube Sportvideos	Youtube ModeBeauty
1	Häufig	männlich	Ja	Nein	Ja	Ja	Nein	Selten	Selten	Häufig	Häufig	Häufig	Selten	Selten	Selten
2	Häufig	männlich	Nein	Ja	Nein	Ja	Nein	Selten	Häufig	Häufig	Häufig	Häufig	Häufig	Häufig	Selten
3	Häufig	männlich	Nein	Nein	Ja	Ja	Ja	Häufig	Häufig	Selten	Häufig	Häufig	Häufig	Häufig	Selten
4	Selten	weiblich	Nein	Nein	Nein	Ja	Nein	Selten	Selten	Häufig	Selten	Selten	Selten	Selten	Selten

Abb. 1: Ausschnitt eines reduzierten JIM-Paderborn (JIM-PB) Datensatzes

Das betrachtete Zielmerkmal ist "Spielen\_OnlineSpiele" (Häufig, Selten). CODAP kann nun genutzt werden, um Entscheidungsbäume halbautomatisch zu erstellen und Zwischenstände zu evaluieren. Die Lernenden wählen Merkmale aus, wobei datenbezogene Kriterien oder inhaltliche Vorstellungen über kausal-probabilistische Zusammenhänge zum Zielmerkmal zum Tragen kommen. Die gelisteten Merkmale werden per „Drag & Drop“ als Prädiktor ausgewählt. Dann wird automatisch ein sogenannter Datensplit durchgeführt, der den Datensatz nach den Ausprägungen des Merkmals teilt und die Teildatensätze hinsichtlich des Zielmerkmals auswertet. In Abb. 2 (links) wurde das Merkmal „FesteKonsole\_Besitz“ ausgewählt. Man kann ablesen, dass von den 26 Personen, die eine Konsole besitzen 20 häufig Onlinespiele spielen und 6 selten (20 zu 6). Unter denjenigen die keine Konsole besitzen, spielen 12 häufig und 15 selten (12 zu 15).

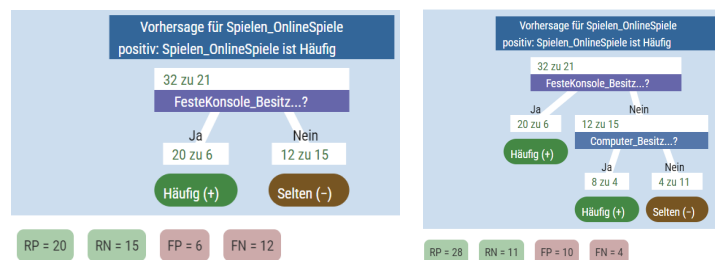


Abb. 2: Entscheidungsbäume in CODAP

Der Entscheidungsbaum klassifiziert nach dem Mehrheitsprinzip und es ergibt sich die Entscheidungsregel: wenn "FesteKonsole = Ja" dann "OnlineSpiele = Häufig", wenn "FesteKonsole = Nein" dann "OnlineSpiele = Selten. Eine Ausprägung des Zielmerkmals (hier: Häufig) gilt dabei immer als positives Ergebnis, wie oben im Baum spezifiziert. Wie gut der Baum den Datensatz klassifiziert, wird dementsprechend durch die angezeigten Anzahlen der Richtig Positiven (RP), Richtig Negativen (RN), Falsch Positiven (FP) und Falsch Negativen (FN) ausgedrückt, die auch als sogenannte Konfusionsmatrix dargestellt werden können (Abb. 3 links). Aus diesen Werten kann man die FKR und weitere statistische Gütekriterien (z. B. Sensitivität,

Spezifität) berechnen. Der einstufige Baum liegt bei 18 Fällen falsch (FKR: 0.34). Um den Baum zu verbessern, können weitere Merkmale am Ende der Äste angefügt werden (Abb. 2, rechts). Außerdem bietet CODAP die Funktion eine Tabelle anzulegen (Abb. 3 rechts) mit der ausgewertet wird, welches Merkmal im nächsten Schritt die FKR am stärksten reduziert.




Abb. 3: Evaluation von Entscheidungsbäumen in CODAP

Mit dieser Funktion wird das systematische Erstellen von Entscheidungsbäumen thematisiert, um zu verstehen, wie ein Computer lediglich auf Basis der Zahlenwerte ohne "Verständnis" des Sachkontexts arbeitet. Die Lernenden „spielen Maschine“, indem Sie algorithmisch alle Optionen durchtesten, wie ein Computer. Anschließend wird das Evaluieren eines erstellten Baums mit Testdaten, thematisiert. Damit werden Mängel des ersten Modells aufgedeckt und korrigierbar. Ferner kann das Phänomen der Überanpassung an die Trainingsdaten untersucht werden.

### Datenerhebung und ausgewählte Einblicke

In einer Teilstudie zur Unterrichtsreihe untersuchen wir, welche intuitiven Zugänge Lernende für das Erstellen von Entscheidungsbäumen wählen. Dafür haben wir zu einem frühen Zeitpunkt der Unterrichtsreihe Ergebnisse der Lernenden dokumentiert. Bevor die Lernenden mit der Software CODAP arbeiten, wurden im Unterricht vier grundlegende Komponenten datenbasierter Entscheidungsbäume (Datensplit, Mehrheitsentscheidung, Evaluation durch Fehlklassifikationen, Baumvisualisierung) erarbeitet. So sollen die Lernenden in die Lage versetzt werden, das in CODAP dargestellte zu interpretieren. Nach einer kurzen Einführung in die Software erhalten die Lernenden in Paaren die Aufgabe einen Entscheidungsbaum zu erstellen, der dafür geeignet ist, später neue Personen dahingehend zu klassifizieren, ob sie häufig oder selten Onlinespiele spielen. Außerdem haben die Lernenden zwei weitere Aufträge. Sie sollen erklären, auf welche Weise sie die Prädiktormerkmale ausgewählt haben und wie sie entschieden haben den Erstellungsprozess abubrechen. Dokumentiert wurden die fertigen Bäume, sowie die mündlichen Erläuterungen von 25 Paaren. Von der Auswertung versprechen wir uns Einsichten darüber, welche typischen Arte und Lösungsansätze bei Lernenden zu erwarten sind, um darauf aufbauend deren Mehrwert für den weiteren Unterrichtsverlauf zu erörtern. Ein erster anekdotischer Bericht ist, dass sehr unterschiedliche Ergebnisse (Abb. 4) dabei herauskamen.

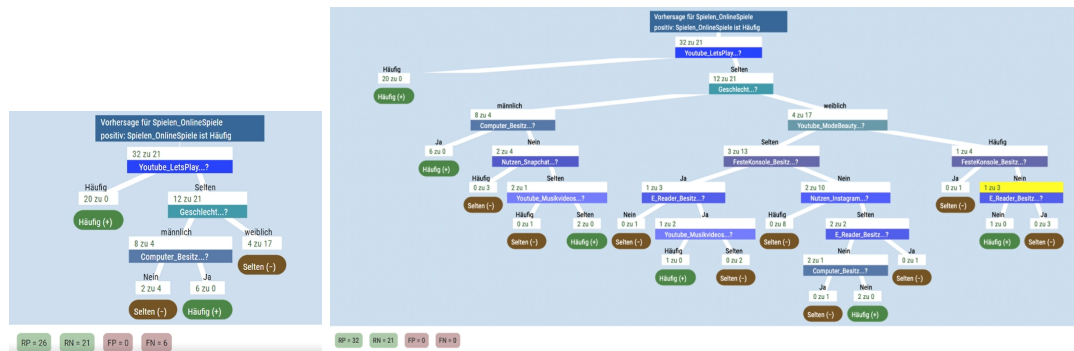


Abb. 4: Zwei Beispiele für von Lernenden erstellte Entscheidungsbäume

Einerseits gab es Paare mit eher kleinen Bäumen und andere mit sehr großen Bäumen. Bei der Auswahl der Prädiktormerkmale achteten einige besonders darauf die Fehlklassifikationen zu reduzieren, andere legten Wert auf inhaltliche Plausibilität. Im Vortrag werden wir eine systematische Auswertung der Ergebnisse sowie die Designideen unserer Unterrichtsreihe (Biehler & Fleischer, 2021) präsentieren. Außerdem gibt es einen Ausblick auf das Unterrichten des Themas in höheren Jahrgangsstufen (Fleischer et al., 2022).

## Literatur

Biehler, R., & Fleischer, Y. (2021). Introducing students to machine learning with decision trees using CODAP and Jupyter Notebooks. *Teaching Statistics*, 43(S1), 133–142. <https://doi.org/10.1111/test.12279>

Casal-Otero, L., Catala, A., Fernández-Morante, C., Taboada, M., Cebreiro, B., & Barro, S. (2023). AI literacy in K-12: A systematic literature review. *International Journal of STEM Education*, 10(1), 29.

Fleischer, Y., Biehler, R., & Schulte, C. (2022). Teaching and Learning Data-Driven Machine Learning with Educationally Designed Jupyter Notebooks. *Statistics Education Research Journal*, 21(2), 7. <https://doi.org/10/gqv59w>

Hitron, T., Orlev, Y., Wald, I., Shamir, A., Erel, H., & Zuckerman, O. (2019). Can Children Understand Machine Learning Concepts?: The Effect of Uncovering Black Boxes. *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, 1–11. <https://doi.org/10.1145/3290605.3300645>

Long, D., & Magerko, B. (2020). What is AI Literacy? Competencies and Design Considerations. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 1–16. <https://doi.org/10/ghbz2q>

Mike, K., & Hazzan, O. (2022). Machine Learning for Non-Majors: A White Box Approach. *Statistics Education Research Journal*, 21(2), 10. <https://doi.org/10.52041/serj.v21i2.45>

Podworny, S., Fleischer, Y., Stroop, D., & Biehler, R. (2022). An example of rich, real and multivariate survey data for use in school. *CERME 12*, Bozen, Italy.

Vartiainen, H., Tedre, M., & Valtonen, T. (2020). Learning machine learning with very young children: Who is teaching whom? *International Journal of Child-Computer Interaction*, 25, 100182. <https://doi.org/10/gjvbc9>