

Katharina BATA, Köln, Angela SCHMITZ, Köln &
Andreas EICHLER, Kassel

Einblicke in die Bearbeitung einer Aufgabe zur Erstellung von Modellen mit Maschinellen Lernverfahren

Theoretischer Hintergrund und Fragestellung

Da Methoden der Datenanalyse und des Maschinellen Lernens (ML) im Kontext Industrie 4.0 zunehmend Anwendung finden, ist Data Science (DS) zu einem obligatorischen Bestandteil ingenieurwissenschaftlicher Curricula geworden (Heidling & Neumer, 2021). Das Lehren und Lernen von ML ist ein noch wenig erforschtes Thema, und es gibt viele offene Fragen bezüglich der Lernziele, Lehrmethoden und Lernprozesse (Steinbach et al., 2020). Ein dennoch allgemein anerkanntes Lernziel ist die Modellerstellung und -validierung (z.B. Lavesson, 2010; Steinbach et al., 2020). Modellerstellung meint dabei die Anwendung eines ML-Verfahrens auf einen Datensatz mit dem Ziel einer systematischen Abbildung und Nutzung der in den Daten vorliegenden Information. Modellvalidierung ist die anschließende Überprüfung des Modells auf seine Qualität hin. Dabei scheint insbesondere die Validierung mit den hierfür notwendigen mathematischen Gütemaßen eine Schwierigkeit für Studierende darzustellen (Lavesson, 2010).

Die Analyse des studentischen Vorgehens bei der Modellerstellung kann Aufschluss über das Erreichen der Lernziele und Hinweise auf systematische Schwierigkeiten geben. Eine solche Analyse wurde innerhalb eines Design Research (DR) Projektes zur Entwicklung eines Einführungskurses in DS und insbesondere ML für Ingenieurstudierende (Bata et al., im Druck) durchgeführt. Ein entwickeltes Kategoriensystem (Bata et al., 2021) ermöglicht, die Modellerstellung von Studierenden zu beschreiben und zu strukturieren. Hierbei werden unter anderem Phasen des begründeten Vorgehens identifiziert. Die zur Begründung genutzten Aussagen mit subjektiv allgemeingültigem Charakter werden im Folgenden in Anlehnung an das Argumentationsmodell von Toulmin (2003) als „Regeln“ (original „warrant“) bezeichnet.

In diesem Beitrag untersuchen wir, welche Arten von inhaltlichen Regeln Studierende bei der Modellerstellung von ML-Modellen nutzen, und kategorisieren anhand eines Fallbeispiels verschiedenartige rekonstruierte Regeln.

Methode

Im Rahmen des übergeordneten DR Projektes wurden mit zwölf Gruppen zu zwei bis drei Studierenden mit unterschiedlichen Programmierkenntnissen und ohne themenspezifisches Vorwissen Designexperimente im Laborset-

ting (Gravemeijer & Cobb, 2006) durchgeführt. Jede Gruppe hat Lernmaterial, welches innerhalb des DR Projektes entstanden ist, eng betreut am geteilten Bildschirm bearbeitet. Alle Sitzungen (pro Gruppe 3 Sitzungen à 2,5 Stunden) wurden videografiert, zusätzlich wurden schriftlich Bearbeitungen zu vorgegebenen Fragen erhoben.

In der nachfolgend analysierten Aufgabe werden die Studierenden aufgefordert, ein Modell mit der k-Nearest-Neighbor-Methode (kNN) zu erstellen. Der zugrundeliegende Datensatz zur Qualität von Stahl besteht aus zwei metrischen Merkmalen (Anzahl der Risse/Breite des größten Risses) und einem Label (gute Qualität/schlechte Qualität). Die Studierenden arbeiten mit einem vorbereiteten Python-basierten Jupyter Notebook, in dem unter anderem Code-Bausteine für eine Auswahl von Gütemaßen sowie einer grafischen Darstellung des Modells gegeben sind.

Das im Rahmen der Bearbeitung entstandene Videomaterial wurde mit Hilfe einer inhaltlich strukturierenden qualitativen Inhaltsanalyse (Kuckartz, 2014) auf die Regeln hin untersucht. In die Analyse wurden nur die Abschnitte der Videos einbezogen, die vorher mit dem Kategoriensystem zum Erfassen von Modellerstellungsprozessen (Bata et al., 2021) als Phasen des begründeten Vorgehens identifiziert wurden.

Ergebnisse

Dargestellt werden zwei Ausschnitte aus der Bearbeitung der Gruppe HBW, bestehend aus den Studierenden mit Pseudonymen Hanna (H), Bastian (B) und Wael (W). In beiden Ausschnitten geht es um die Festlegung der Metrik, einer der Parameter des Modells. Der erste Ausschnitt stammt vom Beginn der Bearbeitung, hier wird der Parameter zum ersten Mal festgelegt:

- 1 *H: Wollen wir Betragsmetrik oder euklidische Metrik?*
- 2 *B: Ich glaube standardmäßig war euklidisch und das haben wir bei den*
- 3 *letzten Malen auch nicht geändert, ich bin mir aber nicht zu 100% sicher.*
- 4 *H: Ja, ich fand euklidisch eigentlich auch ganz hübsch.*
- 5 *B: Wir können dann auch fast das ... ja okay, ich weiß nicht, auf was man –*
- 6 *W: Ich finde, Betrags- ist irgendwie weird also es geht ja auch // also wenn*
- 7 *man beides gleichgewichtet, wird man euklidische Metrik machen, oder?*
(B stellt den Parameter $p=2$ (euklidische Metrik) ein.)

Aus diesem Ausschnitt lassen sich zwei unterschiedliche Regeln rekonstruieren. Zunächst von Bastian in Zeile 2-3: „Die euklidische Metrik ist die StandardEinstellung/hat sich bewährt“. Diese Regel führt nicht unmittelbar zu einer Entscheidung, ein Einfluss auf die Entscheidung am Ende ist unklar. In Zeile 7 folgt außerdem die Äußerung einer Regel durch Wael, welche dann zu der anschließenden Entscheidung ($p=2$, euklidische Metrik) führt:

„Die euklidische Metrik sorgt dafür, dass beide Merkmale gleich gewichtet werden“. Beide in diesem Ausschnitt geäußerten Regeln werden von uns als „Parameterregeln“ bezeichnet. In Parameterregeln wird entweder eine (allgemeingültige) Bewertung eines Parameters vorgenommen (vgl. Regel aus Zeile 2-3) oder der Zusammenhang eines Parameters mit einer Modelleigenschaft beschrieben (vgl. Regel aus Zeile 7).

Im zweiten Ausschnitt hinterfragen die Studierenden ihre Entscheidung:

- 1 W: Sollen wir mal eine andere Metrik nehmen und die Zahlen gucken?
- 2 B: Joa, können wir gerne eigentlich mal machen.
(W fertigt Screenshot der Werte an, fittet das Modell mit $p=1$ (Betragsmetrik) und lässt die Gütemaße ausgeben)
- 4 W: Ja gut, die ist schlechter, kann man sofort sehen, ne?
- 5 B: Ja (3sek) Ja okay, ist ja // ist ja auch ne gute Erkenntnis.
- 6 W: Alle Werte sind schlechter, wenn ich das richtig sehe.
(W stellt im Modell wieder $p=2$ (euklidische Metrik) ein.)

Die Studierenden tauschen die bisher eingestellte Metrik gegen die Betragsmetrik, um die Gütemaße zu vergleichen (Zeile 1-2). Das entstehende Modell führt zu einer Entscheidung ($p=2$, euklidische Metrik) nach der rekonstruierten Regel „Je besser die Gütemaße sind, desto besser ist das Modell“ (Zeile 4-6). Regeln dieser Art, die das Modell, seine Eigenschaften oder Qualität betreffen, aber nicht im direkten Zusammenhang mit den Parametern stehen, werden von uns als „Modellregeln“ bezeichnet.

Die Analyse der gesamten Datengrundlage zeigt, dass es sich bei allen inhaltlich verständlichen Regeln, die die Studierenden äußern, entweder um Modellregeln oder Parameterregeln handelt. Durch die offen gestellte Aufgabe „Erstellen Sie ein möglichst gutes Modell“, gibt es keine optimale Lösung der Aufgabe. Für eine sinnvollen Lösung ist es wichtig, Modell- und Parameterregeln miteinander zu kombinieren, um erst den Anspruch an das Modell (Modellregel) und dann die Umsetzung durch die Parameter (Parameterregel) zu formulieren. Insgesamt wurden im vorliegenden Datenmaterial im Kontext des Parameters Metrik vier unterschiedliche Parameterregeln und drei unterschiedliche Modellregeln genutzt.

Diskussion

Studierende scheinen in Phasen des begründeten Vorgehens bei der Erstellung von Modellen mit maschinellen Lernverfahren zwei Arten von Regeln zu verwenden, die in diesem Beitrag an einem Fallbeispiel vorgestellt wurden. Die Betrachtung der Regeln, von uns als „Modellregeln“ und „Parameterregeln“ bezeichnet, kann Aufschluss darüber geben, auf welcher Detailebene Begriffe und Zusammenhänge erfasst werden. Modellregeln stellen Zusammenhänge zwischen Anforderungen an das Modell, beispielsweise

aufgrund der übergeordneten Fragestellung, und tatsächlichem Modell dar. Parameterregeln dagegen thematisieren Zusammenhänge zwischen Festlegung der Parameter und Modelleigenschaften oder -qualität.

Bei der Analyse der Regeln sollte im Hinblick auf das Erfassen von Begriffen und Zusammenhängen perspektivisch auch die von den Studierenden geäußerten Stützungen (original „backing“ (Toulmin, 2003)) Beachtung finden. Mit Stützungen untermauern die Studierenden die verwendeten Regeln, geben also einen Einblick in Zusammenhänge auf dem Weg zur Regel.

Innerhalb der Regeln kann man zusätzlich unterscheiden, auf welchen Arten von Elementen sie basieren. Solche Elemente sind beispielsweise die vorgegebenen graphischen Darstellungen oder die Gütemaße (wie in der Regel des zweiten Ausschnitts des Fallbeispiels). Erste Ergebnisse zu den innerhalb der Regeln genutzten Elementen sind auch in Bata et al. (2021) zu finden.

Im Vortrag werden weitere Ausschnitte aus den Modellerstellungsprozessen der Studierenden gezeigt und unterschiedliche Regeln bezüglich ihrer Bedeutung für das Erfassen von Begriffen und Zusammenhängen verglichen.

Literatur

- Bata, K., Schmitz, A. & Eichler, A. (im Druck). Insights into the design of an introductory course for data science and machine learning for engineering students. In G. Bolondi, F. Ferretti & J. Hodgen (Hrsg.), *Proceedings of the 12th Congress of the European Society for Research in Mathematics Education*, Freie Universität Bozen/Bolzano: ERME.
- Bata, K., Eichler, A. & Schmitz, A. (2021). How Engineering Students Argue in an Introductory Course in Data Science. In R. Helenius (Hrsg.), *Proceedings of the IASE 2021 Satellite Conference*, International Association for Statistical Education.
- Heidling, E. & Neumer, J. (2021). Kompetenzprofile von Ingenieurinnen und Ingenieuren im digitalen Wandel. In: Lehmann, L., Engelhardt, D. & Wilke, W. (eds) *Kompetenzen für die digitale Transformation 2020*. Springer Vieweg, Berlin, Heidelberg.
- Gravemeijer, K. P. E. & Cobb, P. (2006). Design research from a learning design perspective. In Van den Akker, J., Gravemeijer, K., McKenney, S. & Nieveen, N. (Eds.). *Educational Design Research* (pp. 45-85). London, England: Taylor and Francis Ltd.
- Kuckartz, U. (2014). *Qualitative Inhaltsanalyse. Methoden, Praxis, Computerunterstützung* (2nd ed.). Weinheim, Germany: Beltz Verlagsgruppe.
- Lavesson, N. (2010). Learning Machine Learning: A Case Study. *IEEE Transactions on Education*, 53, 672-676.
- Steinbach, P., Seibold, H. & Guhr, O. (2020). Teaching Machine Learning in 2020. *Proceedings of Machine Learning Research*, 141, 1-6.
- Toulmin, S. (2003). *The uses of argument* (2nd ed.). Cambridge, England: Cambridge University Press.