

Marvin Roski¹
 Anett Hoppe²
 Andreas Nehring¹

¹Leibniz Universität Hannover
²Technische Informationsbibliothek (TIB)

Individuelles Lernen durch Bayesian Knowledge Tracing in der webbasierte Lernplattform „I₃Lern“ analysieren und unterstützen

Hintergrund

Mit der Weiterentwicklung des Internets gegen Ende des 20. Jahrhunderts etabliert sich zunehmend internetbasiertes Lernen. Die University of Phoenix veröffentlichte 1991 die erste Online-Lernplattform (Kentnor, 2015) und ab dem Jahr 2000 verbreiteten sich sogenannte Learning Management Systems (z. B. Moodle (Ahamer, 2010)). Es konstituierten sich 2008 Massiv Open Online Courses (MOOCs), deren Fokus sich hauptsächlich auf das Erreichen einer maximalen Anzahl an Menschen richtet (Baturay, 2015). Mit Inq-ITS wurde um 2012 eine Lernplattform im Bereich der naturwissenschaftlichen Bildung implementiert, die forschendes Lernen mithilfe von KI-basiertem Feedback unterstützt (Gobert et al., 2012). Durch die pandemische Ausbreitung des Sars-CoV-2 Virus im Jahr 2020 offenbarte sich der drastische Bedarf nach internetbasierten Lernangeboten. Bestehende Lernangebote sind oftmals dahingehend konzipiert, die breite Masse anzusprechen und eignen sich kaum, um individuelles Lernen zu ermöglichen. Individuelles Lernen in internetbasierten Lernplattformen ist aber ein Schlüsselkonzept, um die Bedürfnisse aller Lernenden erfüllen zu können (Hase et al., 2022)

Maschinelles Lernen zur Analyse und Unterstützung individueller Lernprozesse

Eine Möglichkeit individuelles Lernen in internetbasierten Lernplattformen automatisiert zu realisieren ist die Verwendung von Techniken aus dem Bereich Learning Analytics (LA) und Machine Learning (ML; Baker, 2016; Neumann & Waight, 2020; Zhai et al., 2022). Durch den technologischen Fortschritt, die Zunahme an verfügbarer Rechenleistung und einen vereinfachten Zugang zu Wissen und Ressourcen ist es möglich, auf diese Techniken zurückzugreifen, wenn keine weitumfassende Expertise in diesen Bereichen besteht. Systeme, die LA und ML verwenden, haben das Potential, komplexe Daten, die aus Lehr-Lern-Situationen erhoben wurden, zu verarbeiten und Muster zu erkennen, die vom Menschen nicht erkannt werden können (Baker & Siemens, 2014; Mitchell, 1997). Entsprechende Lehr-Lern-Situationen können durch internetbasierte Lernplattformen an Lernende herangetragen werden und gleichzeitig relevante Daten über das Lernverhalten hervorbringen. Diese können wiederum durch LA und ML analysiert werden und schließlich individuelles Lernen ermöglichen (Fischer et al., 2020). Eine Schlüsseltechnologie für individualisiertes Lernen aus dem Bereich LA ist das Modellieren des Wissens der Lernenden mithilfe von erhobenen Daten. Dies bildet die Grundlage, individuelle Lernprozesse zu ermöglichen (Pelánek, 2017).

Forschungsfrage

Eine Technik ist das sogenannte Bayesian Knowledge Tracing (BKT; Corbett & Anderson, 1995). Hierbei wird die Wahrscheinlichkeit berechnet, dass die Lernenden Wissensfacetten, sogenannte Knowledge Components (KC), beherrschen. Die Beantwortung von Aufgaben

dient dabei als Datengrundlage (Pelánek, 2017). Das Ergebnis dieser Vorhersage kann als Ausgangslage für individualisiertes Lernen dienen (Sao Pedro et al., 2013). Daraus lässt sich die folgende Forschungsfrage ableiten: Inwiefern eignet sich Bayesian Knowledge Tracing zur lernprozessbegleitenden Vorhersage der Wissensentwicklung von Lernenden beim Lernen? Dies wird untersucht am Beispiel des Lernens mit der Lernplattform „I₃Lern“.

Datenerhebung

Die internetbasierte Lernplattform „I₃Lern“ fokussiert sich auf das chemisch voraussetzungsvolle Thema der Ionenbindung (Hilbing & Barke, 2004). Die Lernplattform basiert auf Richtlinien des *Universal Design for Learning* (UDL) mit dem Ziel, Barrieren für Lernende zu minimieren und eine Teilhabe aller Lernenden zu ermöglichen (CAST, 2018). Das Lernverhalten wird durch *Log Files* protokolliert. Diese enthalten unter anderem die konkreten Lernwege jedes einzelnen Lernenden, protokollieren aber auch zusätzlich Änderungen im Antwortverhalten, wie beispielsweise die Änderung der Antwort in Multiple-Choice-Fragen oder das Korrigieren von offenen Antworten.

Im Zeitraum von Januar bis Juni 2022 haben 580 Lernende der Klassenstufe 9 und 10 mit I₃Lern interagiert. Die 27 Klassen stammen aus Integrativen Gesamtschulen (IGS), Kooperativen Gesamtschulen (KGS) und Gymnasien aus Niedersachsen. Insgesamt wurden 483.511 Datenpunkte gesammelt. Als Datengrundlage wird dabei die Beantwortung von 152 Items verwendet, die sich zum einem in den Testaufgaben eines Pre- und Posttests und zum anderen in den Lernaufgaben innerhalb der einzelnen Kapitel von I₃Lern, den Lerngelegenheiten, wiederfinden lassen. Insgesamt haben 532 Lernende mindestens ein Item beantwortet und dabei 33.892 Log Files mit der Kodierung richtig/falsch erzeugt. Alle Items lassen sich zu sieben KCs zuordnen, welche die Wissensfacetten der Ionenbindung in I₃Lern abbilden (siehe Tab. 1). Die Bildung der KCs basiert auf Lernendenvorstellung zu Ionenbildung und -bindung und dem Kerncurriculum von Integrativen Gesamtschulen in Niedersachsen (Barke, 2006; Butts & Smith, 1987; Coll & Taylor, 2002; Luxford & Bretz, 2014; Meltafina et al., 2019; Nicoll, 2001; Niedersächsisches Kultusministerium, 2020; Tan & Treagust, 1999; Vrabec & Prokša, 2016).

Tab. 1 Übersicht der sieben KC in I₃Lern.

KC 1	Struktur von Atomen und Ionen
KC 2	Bildung von Ionen durch eine Elektronenübertragung
KC 3	Eigenschaften von Salzen
KC 4	Verhältnisformeln von Salzen
KC 5	Bindung als Anziehung zwischen Ionen
KC 6	Gitterstruktur von Salzen
KC 7	Unterscheidung zwischen mikroskopischer und submikroskopischer Ebene

Methodisches Vorgehen

Mithilfe von pyBKT wurde in Python das BKT Modell, vier einzelne BKT-Varianten (KT-IDEM, BKT + forget, Item Order Effect und Item Learning Effect) und Kombinationen dieser trainiert (Badrinath et al., 2021). Dafür wurde der Datensatz in einer 80/20-Verteilung in ein Trainings- und Testdatensatz geteilt. Die verschiedenen Modelle wurden durch eine 5-fold-

cross-validation des Testdatensatzes verglichen. Die Modellvariante KT-IDEM, welche die Item Schwierigkeit berücksichtigt, zeigt dabei die besten Ergebnisse in Hinblick auf die Metriken Area under the Receiver Operating Characteristic Curve (AUC) und Root Mean Square Error (RMSE). Die Metriken der verschiedenen Modellvarianten kann aus Abb. 1 entnommen werden. Beim AUC-Wert wird bei einem Wert von eins von einer perfekten und bei 0.5 von einer zufälligen Klassifikation gesprochen (Ernst et al., 2020).




Abb. 1 Vergleich der Metriken verschiedenen Modellvarianten der KC 2.

Das ausgewählte Modell wurde anschließend nur mit dem Trainingsdatensatz trainiert und mithilfe des Testdatensatzes abschließend evaluiert. Im Vergleich zu Ergebnissen von den BKT-Modellen anderer Forschungsprojekte zeigt sich, dass die Vorhersage des Wissens mithilfe der in I₃Lern erzeugten Daten in einem ähnlichen Rahmen bewegen. Nur die Metriken von Deep Knowledge Training (DKT) Ansätzen zeigen in einem erwartbaren Rahmen bessere Ergebnisse (siehe Tab. 2).

Tab. 2 Ergebnisse von trainierten BKT Modellen im Vergleich.

	KT-IDEM in I ₃ Lern	KT-IDEM mit 2009-2010 ASSISTments dataset (Badrinath et al., 2021)	Deep Knowledge Tracing mit 2009-2010 ASSISTments dataset (Piech et al., 2015)	Standart BKT mit einem Datensatz zu "scientific inquiry" (Herskovitz et al., 2013)
AUC	0.79	0.78	0.86	0.74
RMSE	0.43	-	-	-

Diskussion und Ausblick

Die Ergebnisse deuten an, dass es mithilfe von BKT möglich sein kann, das Wissen und die Wissensentwicklung der Lernenden innerhalb der Lernplattform lernbegleitend zu modellieren. Weitere Forschungen können nun in Blick nehmen, wie und mit welchen Effekten sich aus BKT-basierten Vorhersagen Maßnahmen der individuellen Lernunterstützung abgeleitet werden können.

Literatur

- Ahamer, G. (2010). A short history of web based learning including GIS. In *International Journal of Computer Science & Emerging Technologies* (Vol. 1, Issue 4).
- Badrinath, A., Wang, F., & Pardos, Z. (2021). *pyBKT: An Accessible Python Library of Bayesian Knowledge Tracing Models*. <http://arxiv.org/abs/2105.00385>
- Baker, R. (2016). Using Learning Analytics in Personalized Learning. In M. Murphy, S. Redding, & J. Twyman (Eds.), *Handbook on personalized learning for states, districts, and schools* (pp. 165–174).
- Baker, R., & Siemens, G. (2014). *Educational Data Mining and Learning Analytics*.
- Barke, H.-D. (2006). *Chemiedidaktik*. Springer.
- Baturay, M. H. (2015). An Overview of the World of MOOCs. *Procedia - Social and Behavioral Sciences*, 174, 427–433. <https://doi.org/10.1016/j.sbspro.2015.01.685>
- Butts, B., & Smith, R. (1987). HSC chemistry students' understanding of the structure and properties of molecular and ionic compounds. *Research in Science Education*, 17(1), 192–201.
- CAST. (2018). *Universal Design for Learning Guidelines version 2.2*.
- Coll, R. K., & Taylor, N. (2002). Mental Models in Chemistry: Senior Chemistry Students Mental Models of Chemical Bonding. *Chem. Educ. Res. Pract.*, 3(2), 175–184. <https://doi.org/10.1039/b2rp90014a>
- Corbett, A., & Anderson, J. (1995). *Knowledge Tracing: Modeling the Acquisition of Procedural Knowledge*.
- Ernst, H., Schmidt, J., & Beneken, G. (2020). Grundkurs Informatik. In *Grundkurs Informatik*. <https://doi.org/10.1007/978-3-658-30331-0>
- Fischer, C., Pardos, Z. A., Baker, R. S., Williams, J. J., Smyth, P., Yu, R., Slater, S., Baker, R., & Warschauer, M. (2020). Mining Big Data in Education: Affordances and Challenges. *Review of Research in Education*, 44(1), 130–160. <https://doi.org/10.3102/0091732X20903304>
- Gobert, J. D., Pedro, M. A. S., Baker, R. S. J. D., Toto, E., & Montalvo, O. (2012). Leveraging Educational Data Mining for Real-time Performance Assessment of Scientific Inquiry Skills within Microworlds. In *JEDM Special Issue, Article* (Vol. 3).
- Hase, A., Kahnbach, L., Kuhl, P., & Lehr, D. (2022). To use or not to use learning data: A survey study to explain German primary school teachers' usage of data from digital learning platforms for purposes of individualization. *Frontiers in Education*, 7. <https://doi.org/10.3389/educ.2022.920498>
- Hershkovitz, A., de Baker, R. S. J., Gobert, J., Wixon, M., & Pedro, M. S. (2013). Discovery With Models: A Case Study on Carelessness in Computer-Based Science Inquiry. *American Behavioral Scientist*, 57(10), 1480–1499. <https://doi.org/10.1177/0002764213479365>
- Hilbing, C., & Barke, H.-D. (2004). Ionen und Ionenbindung: Fehlvorstellungen hausgemacht! Ergebnisse empirischer Erhebungen und unterrichtliche Konsequenzen. *CHEMKON*, 11(3), 115–120. <https://doi.org/10.1002/ckon.200410009>
- Kentnor, H. (2015). Distance Education and the Evolution of Online Learning in the United States. *Curriculum and Teaching Dialogue*, 17(1), 22–34. https://digitalcommons.du.edu/cgi/viewcontent.cgi?article=1026&context=law_facpub
- Luxford, C. J., & Bretz, S. L. (2014). Development of the bonding representations inventory to identify student misconceptions about covalent and ionic bonding representations. *Journal of Chemical Education*, 91(3), 312–320. <https://doi.org/10.1021/ed400700q>
- Meltafina, M., Wiji, W., & Mulyani, S. (2019). Misconceptions and threshold concepts in chemical bonding. *Journal of Physics: Conference Series*, 1157(4), 042030. <https://doi.org/10.1088/1742-6596/1157/4/042030>
- Mitchell, T. M. (1997). *Machine Learning*. <https://doi.org/10.1109/ICDAR.2019.00014>
- Neumann, K., & Waight, N. (2020). The digitalization of science education: Déjà vu all over again? *Journal of Research in Science Teaching*, 57(9), 1519–1528. <https://doi.org/10.1002/tea.21668>
- Nicoll, G. (2001). A report of undergraduates' bonding misconceptions. *International Journal of Science Education*, 23(7), 707–730. <https://doi.org/10.1080/09500690010025012>
- Niedersächsisches Kultusministerium. (2020). *Kerncurriculum für die Integrierte Gesamtschule Schuljahrgänge 5-10. Naturwissenschaften*.
- Pelánek, R. (2017). Bayesian knowledge tracing, logistic models, and beyond: an overview of learner modeling techniques. *User Modeling and User-Adapted Interaction*, 27(3–5), 313–350.
- Piech, C., Bassen, J., Huang, J., Ganguli, S., Sahami, M., Guibas, L., & Sohl-Dickstein, J. (2015). Deep knowledge tracing. *Advances in Neural Information Processing Systems, 2015-Janua*, 505–513.
- Tan, K.-C. D., & Treagust, D. F. (1999). *Evaluating students' understanding of chemical bonding*.
- Vrabec, M., & Prokša, M. (2016). Identifying Misconceptions Related to Chemical Bonding Concepts in the Slovak School System Using the Bonding Representations Inventory as a Diagnostic Tool. *Journal of Chemical Education*, 93(8), 1364–1370. <https://doi.org/10.1021/acs.jchemed.5b00953>
- Zhai, X., He, P., & Krajcik, J. (2022). Applying machine learning to automatically assess scientific models. *Journal of Research in Science Teaching, August 2021*, 1–30. <https://doi.org/10.1002/tea.21773>