

Intelligente Tutorielle Systeme mit Deep Knowledge Tracing Tracing in der Elektrizitätslehre

Hintergrund

- Wir haben uns die Frage gestellt, wie Lehre, insbesondere auch bei größerer Teilnehmendenzahl, Binnendifferenzierung realisieren kann, um den heterogenen Voraussetzungen von Studierenden gerecht zu werden.
- Intelligente Tutorielle Systeme (ITS) sind Lehr-Lernplattformen, die Künstliche Intelligenz einsetzen, um erfolgreiche menschliche Tutorinnen und Tutoren in Einzeltutoring nachzuahmen (Nwana, 1990).
- Sie haben dabei den Anspruch, ein effektiveres Lernen zu ermöglichen als die klassische Gruppeninstruktion.
- Das Ziel des Student Model innerhalb des ITS ist das Ableiten des momentanen Wissens und der Fähigkeiten der Lernenden aus den beobachtbaren Aufgabenlösungen.
- In ITS erfolgt die automatische Leistungsevaluation der Lernenden durch Knowledge Tracing Algorithmen (Corbett und Anderson, 1994). Das Deep Knowledge Tracing von Piech et al. (2015) nutzt rekurrente neuronale Netze, um die automatische Leistungsevaluation umzusetzen.
- Der grundsätzliche Programmablauf von ITS kann nach VanLehn (2006) durch zwei Schleifen, eine innere und eine äußere, beschrieben werden. Die äußere Schleife entscheidet, welche Aufgabe den Lernenden als nächstes präsentiert wird. Die innere Schleife ist verantwortlich u.a. für Feedbacks und Lösungshinweise.

Anwendung in der Elektrizitätslehre

- Urban-Woldron und Hopf (2012): Testinstrument zum Verständnis in der Elektrizitätslehre. Keine signifikanten Unterschiede zwischen den Ergebnissen in Bezug auf Schulform oder Schulstufe. Möglicher Hinweis auf eine sehr niedrige Effektivität des Elektrizitätslehreunterrichts.
- Das Deep Knowledge Tracing verspricht theoretisch eine Optimierung des Lernertrags.
- Forschungsfrage:** Ist ein Intelligentes Tutorielles System mit Deep Knowledge Tracing dazu geeignet, Themen der Elektrizität zu lehren?

Design und Stichprobe

- Beginn der Entwicklung eines Systems zur Datengenerierung für das Deep Knowledge Tracing:
 - Adaption von 16 Aufgaben von Urban-Woldron und Hopf (2012) und von Rhöneck (1986), die vier Präkonzepte von Schülerinnen und Schülern in der Elektrizitätslehre abbilden.
 - Berücksichtigte Präkonzepte: Lokales Denken, Sequentielle Argumentation, Erfassen von Parallelschaltungen, Zugriff auf Spannung und Strom.
 - Entwicklung von Lösungshinweisen zu allen 16 Aufgaben.
 - Implementierung der Lernplattform mit dem Learning Management System ILIAS.
 - Rekrutierung von Probandinnen und Probanden über digitale Kanäle und Flyer: Studierende der Physik, Mathematik und Medizin.

Ergebnisse

- N=203 Teilnehmende, davon haben 135 Teilnehmende alle 16 Aufgaben beantwortet.
- Training des Deep Knowledge Tracing Algorithmus mit den Daten des Tutoriellen Systems. Pythoncode adaptiert nach Yeung und Yeung (2018).

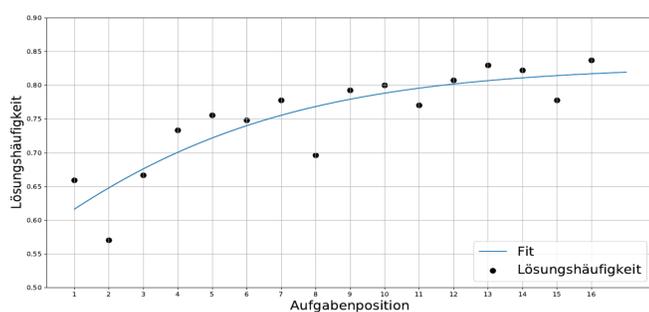


Abb. 1: Lösungshäufigkeit in Abhängigkeit der Aufgabenposition und Fit (berücksichtigt wurden nur die Teilnehmenden, die alle Aufgaben beantwortet haben).

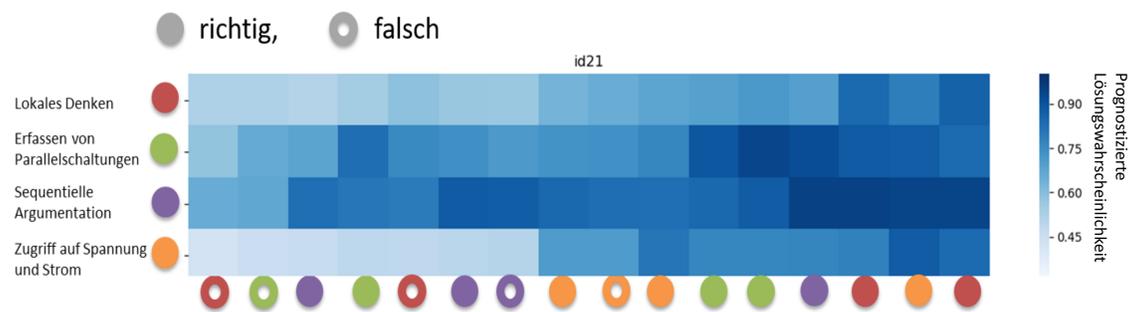


Abb. 3: Aufgabenverlauf aus dem Tutoriellen System und Prognosen des Deep Knowledge Tracing.

Fazit

- Sichtbarer Lerneffekt
- Die Ergebnisse des trainierten Deep Knowledge Tracing Algorithmus können pädagogisch interpretiert werden.
- Das Deep Knowledge Tracing kann zur Individualisierung in Intelligenten Tutoriellen Systemen genutzt werden:
 - Effizientes Lernen durch Optimierung der Aufgabensequenz.
 - Aufdecken von latenten Strukturen innerhalb der Kompetenzbereich des Tutoriellen Systems.

Link zum System:

Literatur

- Bundesministerium für Bildung und Forschung. (2019). DigitalPakt Schule 2019 bis 2024.
- Nwana, H. S. (1990). Intelligent tutoring systems: an overview. *Artificial Intelligence Review*, 4(4), 251–277.
- Corbett, A. T. & Anderson, J. R. (1994). Knowledge tracing: Modeling the acquisition of procedural knowledge. *User Modeling and User-Adapted Interaction*, 4(4), 253–278
- Piech, C., Bassen, J., Huang, J., Ganguli, S., Sahami, M., Guibas, L. J. & Sohl-Dickstein, J. (2015). Deep Knowledge Tracing. In C. Cortes, N. D. Lawrence, D. D. Lee, M. Sugiyama & R. Garnett (Hrsg.), *Advances in Neural Information Processing Systems* 28 (S. 505–513). Curran Associates, Inc.
- Urban-Woldron, H. & Hopf, M. (2012). Entwicklung eines Testinstruments zum Verständnis in der Elektrizitätslehre. *Zeitschrift für Didaktik der Naturwissenschaften*, Jg. 18, 201–227.
- von Rhöneck, C. (1986). Vorstellungen vom elektrischen Stromkreis. *Naturwissenschaften im Unterricht-Physik/Chemie*, 34(13), 10–14.
- Yeung, C.-K. & Yeung, D.-Y. (2018). Addressing Two Problems in Deep Knowledge Tracing via Prediction-consistent Regularization. In *Proceedings of the Fifth Annual ACM Conference on Learning at Scale* (5:1–5:10). L@S '18.