

Custom KI-Chatbots zur Analyse multipler Repräsentationen Unterstützung von Lernprozessen durch personalisiertes Scaffolding

Einleitung

Die Integration Künstlicher Intelligenz (KI) rückt zunehmend in den Fokus schulischer Bildung (Fissore et al., 2024; Wollny et al., 2021). Für die Anwendung von KI-Tools konnten im schulischen Kontext bereits zahlreiche Vorteile identifiziert werden, sowohl für Lehrende als auch Lernende. So besteht die Möglichkeit, Lehrende bei der Unterrichtsplanung sowie der Generierung von Lernmaterialien oder Feedback zu unterstützen (Kasneci et al., 2023; Neumann et al., 2024). Lernende hingegen können von intelligenten tutoriellen Systemen oder der Unterstützung bei Recherche- und Schreibaufgaben profitieren (Adiguzel et al., 2023). Insbesondere KI-Chatbots, die auf großen Sprachmodellen basieren, haben das Potenzial, Lernen durch personalisiertes und interaktives Feedback in Echtzeit zu transformieren, indem sie mit Lernenden in einem interaktiven Dialog kommunizieren (z.B. Küchemann et al., 2024). Trotz dieser vielversprechenden Potenziale und des gestiegenen Forschungsinteresses bleibt offen, wie KI-Chatbots Lernende wirksam unterstützen und wie sich diese Unterstützung auf das Lernerleben auswirkt. Das nachfolgend präsentierte Projekt trägt zur Schließung dieser Forschungslücke bei. Im Anwendungskontext multipler Repräsentationen im Physikunterricht werden KI-Chatbots zur Lernprozessunterstützung untersucht.

Theoretischer Hintergrund und Motivation

Multiple Repräsentationen im Physikunterricht

In den naturwissenschaftlichen Fächern und insbesondere in der Physik ist die Visualisierung von Informationen anhand verschiedener Repräsentationsformen (z.B. Text, Tabelle, Formel, Graph) essenziell, denn diese kodieren relevante Informationen für ein ganzheitliches Verständnis (Kohl et al., 2007; Treagust, 2018). Die Kombination mehrerer Repräsentationen ist ein häufig eingesetztes Mittel, um Lerninhalte zu transportieren. Lernende benötigen die Fähigkeit, die verschiedenen Repräsentationsformen zu interpretieren und zwischen ihnen zu wechseln (Hansen & Richland, 2020; Opfermann et al., 2017). Dies kann eine hohe Komplexität und Dichte der Informationsverarbeitung sowie Schwierigkeiten bei der Verknüpfung der unterschiedlichen Repräsentationsformen bedeuten (Seufert, 2003; van der Meij & de Jong, 2006). Als mögliche Folge kann es zu einer hohen kognitiven Belastung und negativen Lerneffekten kommen (Sweller, 2005).

Unterstützung durch Custom KI-Chatbots

Eine gezielte Unterstützung bei der Verknüpfung der verschiedenen Repräsentationsformen kann das Konzeptverständnis fördern und Fehlvorstellungen unwahrscheinlicher machen (z.B. Hansen & Richland, 2020). Individualisiertes Scaffolding – strukturiert, individuell angepasst, zeitlich begrenzt und in Echtzeit (Guo et al., 2024; Jia et al., 2024) – kann zu einer Reduktion der kognitiven Belastung führen (Chen & Chang, 2024; Stadler et al., 2024; Yin et al., 2024). Der Einsatz von Custom KI-Chatbots nach Load Reduction Instruction (LRI) kann eine mögliche Lösung darstellen (Martin, 2016) und beim Lernen durch personalisiertes Feedback unterstützen (Adiguzel et al., 2023; Kasneci et al., 2023; Neumann et al., 2024).

Custom KI-Chatbots basieren auf bestehenden großen Sprachmodellen und können an spezifische Lernkontexte angepasst werden (Kieser et al., 2023). Eine geeignete Methode ist die sogenannte Retrieval Augmented Generation (RAG), bei der die Fähigkeiten von Sprachmodellen durch die Integration externer Datenquellen präzisiert werden, die als zusätzliche, kontextspezifische Wissensbasis dienen (Kortemeyer, 2024; Lewis et al., o. J.). Custom KI-Chatbots können so konfiguriert werden, dass sie sich bei der Feedbackgenerierung ausschließlich auf genau dieses Wissen berufen. So können sie besser beim Lernen unterstützen und haben einen größeren positiven Einfluss auf die Lernleistung als nicht spezifisch konfigurierte (Hakim et al., 2024).

Pilotstudie

Forschungsfragen

Für die Studie wurde ein Custom KI-Chatbot auf Basis des Sprachmodells GPT-4.0 generiert, der auf die Unterstützung bei der Interpretation und Verknüpfung der verschiedenen Darstellungsformen (Graph, Tabelle, Formel) proportionaler Zuordnungen fokussiert. Der Chatbot kommuniziert in altersgerechter und motivierender Sprache und hat eine externe Wissensbasis zum Thema „Proportionale Zuordnungen“. Auf Grundlage von Schulbuchmaterialien wurde mit dem Chatbot eine Erklärung des Themas generiert.

In der Studie wurden folgende Forschungsfragen adressiert:

- Wie wirkt sich das Lernen mit der von dem Custom KI-Chatbot generierten Erklärung auf ...
- das Lernerleben aus?
- die Lernleistung in einem mathematischen und physikalischen Lernkontext aus?

Methodik

An der Studie nahmen $N = 214$ Schüler*innen der Jahrgangsstufe sechs an weiterführenden Schulen in Deutschland teil. Die Schüler*innen wurden innerhalb ihrer Schulklassen randomisiert der Experimental- (EG) oder der Kontrollgruppe (KG) zugeteilt. Für die Lernphase erhielten beide Gruppen Schulbuchmaterial. Die EG nutzte darüber hinaus die KI-generierte Erklärung, während die KG ergänzende Beispiele aus dem Schulbuch erhielt. Mittels evaluierter Erhebungsinstrument wurden unmittelbar anschließend an die Lernphase das situationale Interesse, positiv-aktivierende und negativ-deaktivierende Emotionen, die kognitive Belastung sowie die Selbstwirksamkeitserwartung erhoben. Abschließend bearbeiteten die Schüler*innen einen Leistungstest, um die Lernleistung der beiden Gruppen zu vergleichen.

Ergebnisse

In der Studie konnte gezeigt werden, dass das Lernen mit der KI-generierten Erklärung positiv-aktivierende Emotionen signifikant verstärkt. Außerdem erlebte die KG tendenziell mehr negativ-deaktivierende Emotionen – hier konnte jedoch nur ein Trend festgestellt werden. Sowohl das situationale Interesse als auch die Selbstwirksamkeitserwartung waren in der EG signifikant höher. Die intrinsische und extrinsische kognitive Belastung wurden in der EG signifikant reduziert. Bezüglich der Lernleistung konnten keine signifikanten Unterschiede festgestellt werden.

Die Methodik und die Ergebnisse der Studie sind vollumfänglich in der im Mai 2025 veröffentlichten Publikation nachzulesen (Lademann et al., 2025).

Ausblick

Im Rahmen einer Folgestudie mit angestrebtem Stichprobenumfang von $N > 300$ sollen die in der Pilotierung identifizierten Effekte und Trends vertiefend untersucht werden. Der bestehende Chatbot wurde dafür überarbeitet, optimiert und an die neuen Rahmenbedingungen der Folgestudie angepasst. Das Konzept sieht eine selbstständige Anwendung des Chatbots seitens der Schüler*innen vor, so dass diese durch die Interaktion Zugang zu individuellem Feedback erhalten. Personalisiertes Scaffolding durch den Custom KI-Chatbot soll beim Lernen mit multiplen Repräsentationen direkt unterstützen. In der Studie sollen im Prä-Post-Design zum einen mögliche Effekte auf die Lernleistung – Konzeptverständnis sowie Repräsentationskompetenz – untersucht werden. Zum anderen werden analog zur Pilotierung die kognitive Belastung, positiv-aktivierende und negativ-deaktivierende Emotionen, situationales Interesse sowie Selbstwirksamkeit erhoben. Im Rahmen der Analyse sollen mögliche Wirkzusammenhänge aufgeklärt werden sowie Betrachtungen unterschiedlicher Gruppierungen, beispielsweise nach Vorwissen oder Motivation, erfolgen.

Literatur

- Adiguzel, T., Kaya, M. H. & Cansu, F. K. (2023). Revolutionizing education with AI: Exploring the transformative potential of ChatGPT. *Contemporary Educational Technology*, 15(3), ep429. <https://doi.org/10.30935/cedtech/13152>
- Chen, C.-H. & Chang, C.-L. (2024). Effectiveness of AI-assisted game-based learning on science learning outcomes, intrinsic motivation, cognitive load, and learning behavior. *Education and Information Technologies*, 29(14), 18621–18642. <https://doi.org/10.1007/s10639-024-12553-x>
- Fissore, C., Floris, F., Fradiante, V., Marchisio Conte, M. & Sacchet, M. (2024). From theory to training: Exploring teachers' attitudes towards artificial intelligence in education. *Proceedings of the 16th International Conference on Computer Supported Education*, 118–127. <https://doi.org/10.5220/0012734700003693>
- Guo, S., Zheng, Y. & Zhai, X. (2024). Artificial intelligence in education research during 2013–2023: A review based on bibliometric analysis. *Education and Information Technologies*, 29(13), 16387–16409. <https://doi.org/10.1007/s10639-024-12491-8>
- Hakim, V. G. A., Paiman, N. A. & Rahman, M. H. S. (2024). Genie-on-demand: A custom AI chatbot for enhancing learning performance, self-efficacy, and technology acceptance in occupational health and safety for engineering education. *Computer Applications in Engineering Education*. <https://doi.org/10.1002/cae.22800>
- Hansen, J. & Richland, L. E. (2020). Teaching and learning science through multiple representations: Intuitions and executive functions. *CBE—Life Sciences Education*, 19(4), ar61. <https://doi.org/10.1187/cbe.19-11-0253>
- Jia, F., Sun, D. & Looi, C. (2024). Artificial intelligence in science education (2013–2023): Research trends in ten years. *Journal of Science Education and Technology*, 33(1), 94–117. <https://doi.org/10.1007/s10956-023-10077-6>
- Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günnemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., ... Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>

- Kieser, F., Wulff, P., Kuhn, J. & Küchemann, S. (2023). Educational data augmentation in physics education research using ChatGPT. *Physical Review Physics Education Research*, 19(2), 020150. <https://doi.org/10.1103/PhysRevPhysEducRes.19.020150>
- Kohl, P. B., Rosengrant, D. & Finkelstein, N. D. (2007). Strongly and weakly directed approaches to teaching multiple representation use in physics. *Physical Review Special Topics - Physics Education Research*, 3(1), 010108. <https://doi.org/10.1103/PhysRevSTPER.3.010108>
- Kortemeyer, G. (2024). *Tailoring Chatbots for Higher Education: Some Insights and Experiences*. <https://doi.org/10.48550/arXiv.2409.06717>
- Küchemann, S., Steinert, S., Kuhn, J., Avila, K. & Ruzika, S. (2024). Large language models—Valuable tools that require a sensitive integration into teaching and learning physics. *The Physics Teacher*, 62, 400–402. <https://doi.org/10.1119/5.0212374>
- Lademann, J., Henze, J. & Becker-Genschow, S. (2025). Augmenting learning environments using AI custom chatbots: Effects on learning performance, cognitive load, and affective variables. *Physical Review Physics Education Research*, 21(1), 010147. <https://doi.org/10.1103/PhysRevPhysEducRes.21.010147>
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W., Rocktäschel, T., Riedel, S. & Kiela, D. (o. J.). Retrieval-augmented generation for knowledge-intensive NLP tasks.
- Martin, A. (2016). Using Load Reduction Instruction (LRI) to boost motivation and engagement.
- Neumann, K., Kuhn, J. & Drachsler, H. (2024). Generative Künstliche Intelligenz in Unterricht und Unterrichtsforschung – Chancen und Herausforderungen. *Unterrichtswissenschaft*, 52(2), 227–237. <https://doi.org/10.1007/s42010-024-00212-6>
- Opfermann, M., Schmeck, A. & Fischer, H. E. (2017). Multiple representations in physics and science education – Why should we use them? In D. F. Treagust, R. Duit, & H. E. Fischer (Hrsg.), *Multiple Representations in Physics Education* (Bd. 10, S. 1–22). Springer International Publishing. https://doi.org/10.1007/978-3-319-58914-5_1
- Seufert, T. (2003). Supporting coherence formation in learning from multiple representations. *Learning and Instruction*, 13(2), 227–237. [https://doi.org/10.1016/S0959-4752\(02\)00022-1](https://doi.org/10.1016/S0959-4752(02)00022-1)
- Stadler, M., Bannert, M. & Sailer, M. (2024). Cognitive ease at a cost: LLMs reduce mental effort but compromise depth in student scientific inquiry. *Computers in Human Behavior*, 160, 108386. <https://doi.org/10.1016/j.chb.2024.108386>
- Sweller, J. (2005). Implications of cognitive load theory for multimedia learning. In *The Cambridge handbook of multimedia learning* (S. 19–30). Cambridge University Press. <https://doi.org/10.1017/CBO9780511816819.003>
- Treagust, D. F. (2018). The importance of multiple representations for teaching and learning science. In *Education Research Highlights in Mathematics, Science and Technology 2018* (S. 215–223). ISRES.
- van der Meij, J., & de Jong, T. (2006). Supporting students' learning with multiple representations in a dynamic simulation-based learning environment. *Learning and Instruction*, 16(3), 199–212. <https://doi.org/10.1016/j.learninstruc.2006.03.007>
- Wollny, S., Schneider, J., Di Mitri, D., Weidlich, J., Rittberger, M. & Drachsler, H. (2021). Are we there yet? - A systematic literature review on chatbots in education. *Frontiers in Artificial Intelligence*, 4. <https://doi.org/10.3389/frai.2021.654924>
- Yin, J., Goh, T.-T. & Hu, Y. (2024). Using a chatbot to provide formative feedback: A longitudinal study of intrinsic motivation, cognitive load, and learning performance. *IEEE Transactions on Learning Technologies*, 17, 1378–1389. <https://doi.org/10.1109/TLT.2024.3364015>