

PCK handlungsnah abbilden – individuell und unmittelbar

Pedagogical Content Knowledge (PCK) gilt in den Naturwissenschaften als zentral für erfolgreiches Unterrichten (Shulman, 1986, 1987; Van Driel et al., 1998; Loughran et al., 2006; Kind, 2009; Park et al., 2011; Carlson et al., 2019; ...). Gleichzeitig gilt PCK als komplexes und anspruchsvolles Konzept, das schwer zu fassen ist (Van Driel & Berry, 2012; Gess-Newsome et al., 2019; Sarkar et al., 2024; ...). Vielfach bestehen Versuche der PCK-Messung in large-scale Assessments (z.B. paper-pencil tests) oder individuellen Beobachtungen, Interviews oder mixed-methods-Ansätzen (mit entsprechendem Analyseaufwand). Die Ansätze bergen jedoch die Herausforderung, nicht hinreichend situations- bzw. personenspezifisch zu sein oder objektive Tiefenanalyse durchführen zu müssen, bevor beispielsweise Feedback gegeben werden kann. Nachfolgend wird daher eine Methodik vorgestellt, die etablierte Methoden der Unterrichtsvor- und -nachbereitung verwendet, um mittels Large-Language-Models (LLMs) Ähnlichkeiten der genutzten PCK-Facetten rund um eine spezifische Unterrichtssituation zu analysieren.

PCK-Facetten in der Unterrichtsvorbereitung

Seit der Einführung des Refined Consensus Models of PCK in Science Teaching (RCM) (Carlson et al., 2019) nutzen zahlreiche Forschende das Modell als theoretischen Bezugsrahmen für Studien zur Lehrkräfteprofessionalisierung (Mientus et al., 2022). Die Verwendung der PCK-Facetten des Modells kann daher wertvoll sein (Content Knowledge [CK], Pedagogical Knowledge [PK], Knowledge of Students [KS], Curriculum Knowledge [CuK] und Assessment Knowledge [AK]; sowie der Learning Context [Context]). Diese PCK-Facetten können im Rahmen einer Unterrichtsvorbereitung mithilfe von Content Representations (CoRes) aufgezeigt werden (Loughran et al., 2006). Die Methode wird als hilfreiches Instrument eingeschätzt, um eigenes Professionswissen zu reflektieren und träges Wissen in praxisnahe Unterrichtsplanungen zu überführen (Hume & Berry, 2011; Hume, 2010; Bertram & Loughran, 2012). In CoRes bestimmen Lehrkräfte zentrale Ideen eines Lerngegenstands und bearbeiten sie anhand strukturierender Leitfragen, wobei die Leitfragen PCK-Facetten zugeordnet werden können (z.B. Sannert et al., 2025; Mientus & Borowski, 2024). Für diesen Beitrag wird erwartet, dass die Antworten auf die Leitfragen der CoRes jeweils personen-, kontext- und themenspezifisches Professionswissen beinhalten, welches unter Verwendung eines LLM analysiert werden kann.

Unterrichtsnachbereitung und Ähnlichkeit

Als Pendant zur Methode der CoRes vor einer Unterrichtssituation kann eine schriftliche Reflexion nach dem Unterricht wertvoll sein und unter Verwendung von LLMs analysiert werden (z.B. Poldner et al., 2014; Ullmann, 2019; Wulff et al., 2022). Generell kann erwartet werden, dass (Biases außenvorgelesen) LLMs durch Ihre Embedding-Strukturen hervorragend in der Lage sind, semantische Ähnlichkeiten abzubilden (Ivan Vulic et al., 2020). Diese Eigenschaft soll im Folgenden für die Ähnlichkeitsanalyse von schriftlichen Reflexionen nach dem Unterricht und Antworten aus den Content Representations vor dem

Unterricht genutzt werden, um fachdidaktischen Entscheidungsprozessen von Lehrkräften (Pedagogical Reasoning) näher untersuchen zu können.

Methodik

Für das vorliegende Konzept wurden Datenpaare aus dem Praxissemester Physik an der Universität Potsdam verwendet. Sechs Studierende erstellten dreimalig zur eigenen Unterrichtspraxis je eine CoRe und verfassten im Nachgang je eine schriftliche Selbstreflexion. Nach Datacleaning konnten von fünf Studierenden insgesamt 15 CoRe-RT-Paare genutzt werden. Unter Verwendung eines lokalen Embedding-Modells der Ollama-Familie werden im entwickelten Algorithmus die Sprachprodukte jedes Datenpaares numerisch repräsentiert. Hierbei berechnet der Algorithmus für jeden CoRe-Eintrag (also jede Antwort auf eine Leitfrage) die semantische Ähnlichkeit zu jedem Segment des Reflexionstextes. Durch die Zuordnung der Leitfragen zu PCK-Facetten nach Mientus und Borowski (2024) können nun zur Visualisierung Heatmaps generiert werden, welche qualitativ Zusammenhänge zwischen den Antworten auf Leitfragen vor der Unterrichtssituation und Formulierungen aus den Reflexionstexten nach der Unterrichtssituation aufzeigen. Die Verwendung eines lokalen Embedding-Modells ermöglicht die Analyse aller personenbezogenen Daten DSGVO-konform.

Einblicke

Abbildung 1 zeigt die Heatmap eines einzelnen Datenpaares. Im konkreten Analysebeispiel sind semantische Ähnlichkeiten des gewählten Ollama-Modells zwischen den Einträgen aus der ersten CoRe mit den Paragraphen der ersten schriftlichen Selbstreflexion von Subjekt *GRLAPO02* dargestellt.




Abb. 1) Beispiel für Heatmap aus Ähnlichkeitsanalyse eines CoRe-RT-Paares

Deutlich zu erkennen sind Paragraphen aus der schriftlichen Reflexion, die in engerem semantischem Zusammenhang zum individuellen und situationsspezifischen Vorwissen der angehenden Physiklehrkraft stehen, welches in der CoRe festgehalten werden konnte. Eine ausgeprägte Ähnlichkeit ist in den Segmenten 5 und 6 erkennbar, in welchen Rahmenbedingungen der Lerngruppe erneut aufgegriffen werden und Folgerungen für die Unterrichtssituation vernetzt diskutiert wurden: „sehr schwierige Situation [...] ein Schüler mit Autismus-Spektrum [...] die Skala nicht wirklich verstanden [...] nicht gut erkennen konnte [...] Ich bin Schritt für Schritt durchgegangen [...] alle einigermaßen verstanden“. Das Segment 8 hingegen stellt eine geringere semantische Ähnlichkeit zum verschriftlichten PCK

vor der Unterrichtssituation dar. In derartigen Segmenten werden häufig situative Erfahrungen berichtet, welche erst innerhalb der Unterrichtssituation aufgezeigt wurden. Im konkreten Beispiel berichtet die Person beispielsweise von einem Auswertungsgespräch mit der/dem Mentor:in vor Ort: „sehr erleichtert, dass Auswertung so locker war [...] nicht komplett auseinandergenommen“.

Ausblick

Die gegenwärtig ersten Eindrücke der Analyse ermöglichen die Erwartung, dank der validen Embedding-Struktur von LLMs Zusammenhänge bzw. semantische Ähnlichkeiten zwischen unterrichtsnahen Sprachprodukten automatisiert zu analysieren. Ein besonderer Vorteil dieser Methodik kann hierbei darin gesehen werden, dass LLMs keiner menschlichen Interpretation unterliegen und somit keine Zusammenhänge interpretiert werden, wo keine Zusammenhänge bestehen. Im weiteren Verlauf der Datenanalyse der $N = 15$ CoRe-RT-Paaren wird sich zeigen, inwieweit Einblicke, wie obig dargestellt, Mehrwerte für Analysen von Produkten der Unterrichtsvor- und -nachbereitung bieten, um ggf. der fachdidaktischen Entscheidungsfindung (Pedagogical Reasoning) personen-, kontext- und themenspezifischer näher kommen zu können.

Literatur

- Bertram, A. & Loughran, J. (2012). Science teachers' views on CoRes and PaP-eRs as a framework for articulating and developing pedagogical content knowledge. *Research in Science Education*, 42, 1027–1047. <https://doi.org/10.1007/s11165-011-9227-4>
- Carlson, J., Daehler, K.R., Alonzo, A., Barendsen, E., Berry, A., Borowski, A., ... & Wilson, C. (2019). The refined consensus model of pedagogical content knowledge in science education. In A. Hume, R. Cooper & A. Borowski (Eds.) *Repositioning pedagogical content knowledge in teachers' knowledge for teaching science*. Springer. <https://doi.org/10.1007/978-981-13-5898-2>
- Gess-Newsome, J., Taylor, J., Carlson, J., Gardner, A., Wilson, C., & Stuhlsatz, M. (2019). Teacher pedagogical content knowledge, practice, and student achievement. *International Journal of Science Education*, 41, 944–963. <https://doi.org/10.1080/09500693.2016.1265158>
- Hume, A. (2010). CoRes as tool for promoting pedagogical content knowledge of novice science teachers. *Chemistry Education in New Zealand*, 119, 13–19.
- Hume, A. & Berry, A. (2011). Constructing CoRes – A strategy for building PCK in pre-service science teacher education. *Research in Science Education*, 41(3), 341–355. <https://doi.org/10.1007/s11165-010-9168-3>
- Kind, V. (2009). Pedagogical content knowledge in science education: Perspectives and potential for progress. *Studies in Science Education*, 45(2), 169–204. <https://doi.org/10.1080/03057260903142285>
- Loughran, J., Berry, A. & Mulhall, P. (2006). *Understanding and developing science teachers' pedagogical content knowledge*. Rotterdam. Sense Publishers.
- Mientus, L., Hume, A., Wulff, P., Meiners, A. & Borowski, A. (2022). Modelling STEM teachers pedagogical content knowledge in the framework of the refined consensus model: A systematic literature review. *Education Sciences*, 12(6), 385. <https://doi.org/10.3390/educsci12060385>

- Mientus, L. & Borowski, A. (2024). Content Representations kohärent gedacht. In A. Wehner, N. Masanek, K. Hellmann, T. Heinz, F. Grospietsch & I. Glowinski (Hrsg.), *Vernetzung von Wissen bei Lehramtsstudierenden – Eine Black-Box für die Professionalisierungsforschung?* (S. 89–103). Klinkhardt. <https://doi.org/10.25656/01:31763>
- Park, S. & Oliver, J.S (2008). Revisiting the conceptualisation of pedagogical content knowledge (PCK): PCK as a conceptual tool to understand teachers as professionals. *Research in Science Education*, 38, 261–284. <https://doi.org/10.1007/s11165-007-9049-6>
- Poldner, E., van der Schaaf, M., Simons, P.R.-J., van Tartwijk, J., & Wijngaards, G. (2014). Assessing student teachers' reflective writing through quantitative content analysis. *European Journal of Teacher Education*, 37(3), 348–373.
- Sannert, R., van Driel, J., & Krell, M. (2025). Can content representation (CoRe) accurately capture key components of science teachers' PCK? A methodological perspective. *Journal of Science Teacher Education*, 1–25. <https://doi.org/10.1080/1046560X.2025.2516293>
- Sarkar, M., Gutierrez-Bucheli, L., Yee Yip, S., Lazarus, M., Wright, C., White, P. J., Ilic, D., Hiscox, T. H. & Berry, A. (2024). Pedagogical content knowledge (PCK) in higher education: A systematic scoping review. *Teaching and Teacher Education*, 144. <https://doi.org/10.1016/j.tate.2024.104608>
- Shulman, L. S. (1986). Those who understand: Knowledge growth in teaching. *Educational Researcher*, 15(2), 4–14.
- Shulman, L.S. (1987). Knowledge and teaching: Foundations of the new reform. *Harvard Educational Review*, 57(1), 1–22.
- Ullmann, T.D. (2019). Automated analysis of reflection in writing: Validating machine learning approaches. *International Journal Artificial Intelligence in Education*, 29(2), 217–257.
- Van Driel, J. & Berry, A. (2012). Teacher professional development focusing on pedagogical content knowledge. *Educational Researcher*, 41, 26 - 28. <https://doi.org/10.3102/0013189X11431010>
- Van Driel, J., Verloop, N. & Vos, W. (1998). Developing science teachers' pedagogical content knowledge. *Journal of Research in Science Teaching*, 35, 673–695. [https://doi.org/10.1002/\(SICI\)1098-2736\(199808\)35:6<673::AID-TEA5>3.0.CO;2-J](https://doi.org/10.1002/(SICI)1098-2736(199808)35:6<673::AID-TEA5>3.0.CO;2-J)
- Vulic, I., Baker, S., Ponti, E., Petti, U., Leviant, I., Wing, K., Majewska, O., Bar, E., Malone, M., Poibeau, T., Reichart, R. & Korhonen, A. (2020). Multi-SimLex: A large-scale evaluation of multilingual and crosslingual lexical semantic similarity. *Computational Linguistics*, 46, 847–897. https://doi.org/10.1162/coli_a_00391.
- Wulff, P., Mientus, L., Nowak, A. & Borowski, A. (2022). Utilizing a pretrained language model (BERT) to classify preservice physics teachers' written reflections. *International Journal of Artificial Intelligence in Education*. <https://doi.org/10.1007/s40593-022-00290-6>