

Kognitive Strukturen erheben in Studien mit großen Stichproben: Entwicklung eines Algorithmus

Kognitive Strukturen nach erfolgreichem Lernen

Als eines der Ergebnisse nach erfolgreichem Lernen haben sich „gut organisierte“ kognitive Strukturen herausgestellt (Gruber & Mandl, 1996). Eine solche gute Organisation lässt sich bspw. daran erkennen, dass für einen gegebenen Kontext hauptsächlich relevante Konzepte in den kognitiven Strukturen vorhanden sind (Mintzes & Quinn, 2007), und dass zwischen diesen für den Kontext nur relevante Verknüpfungen bestehen, insbesondere also wenige nicht relevante Verknüpfungen vorhanden sind (Rikers et al., 2000). Die Verknüpfungen, die bestehen, können für den Kontext präzise ausformuliert werden (Schwendimann, 2019).

Stellen wir uns ein bildliches Modell vor, wie eine kognitive Struktur für bspw. den Klimawandel als komplexen Kontext nach erfolgreichem Lernen aussehen kann, dann ergibt sich ein Bild wie in Abbildung 1 dargestellt. Es lassen sich Cluster von Konzepten erkennen, innerhalb derer mehr oder weniger zahlreiche relevante Verbindungen bestehen.




Abb. 1: Bildliche Darstellung der kognitiven Strukturen nach erfolgreichem Lernen. Kreise entsprechen einem für den Kontext relevanten Konzept und verbindende Linien entsprechen relevanten Verbindungen. Kreise einer Farbe bilden ein so genanntes „Konzept-Cluster“.

Wie erfassen wir kognitive Strukturen bislang?

Zum Erfassen von kognitiven Strukturen haben sich offenen *Concept Mapping tasks* als geeignet herausgestellt (Graf, 2014). Die aus diesen *tasks* entstehenden Concept Maps können auf verschiedene Arten ausgewertet werden, wie aus einer Meta-Analyse von de Ries et al. (2022) ersichtlich wird. Deutlich wird dabei, dass sich die erfassten Studien in zwei verschiedene Gruppen einteilen lassen, je nachdem, ob sie qualitativ mit kleinen oder quantitativ mit großen Stichproben arbeiten. Qualitative Ansätze der Auswertung schaffen es, den Inhalt der Concept Maps zu berücksichtigen, benötigen aber viele Ressourcen bei der Analyse der Daten und sind damit für Studien mit großen Stichprobenzahlen nicht ökonomisch umsetzbar. Unter die quantitativen Auswertungsansätzen fallen verschiedene Methoden. Ihnen ist gemein, dass sie einen recht hohen Informationsverlust mit sich bringen, wenn die Analyse z.B. nur die Strukturen, aber nicht die semantischen Informationen der Knoten- und Kantenbeschriftungen berücksichtigt. Die Folge ist, dass Aussagen über die kognitiven Strukturen stark eingeschränkt werden. Das Ziel unseres Projekts besteht in der Entwicklung und Validierung einer ökonomischen, quantitative Auswertungsmethode für

offene *Concept Mapping tasks*, die die strukturellen und semantischen Informationen in Concept Maps berücksichtigt und den Informationsverlust minimiert.

Idee der neuen Auswertungsmethode und Entwicklungsprozess

Um das Ziel zu erreichen, wurde ein Algorithmus entwickelt, der die oben angesprochenen Konzept-Cluster innerhalb einer gegebenen Concept Map bestimmt und dabei die strukturellen und semantischen Inhalte der Concept Map berücksichtigt. Um diesen Algorithmus zu entwickeln, wurde zunächst ein Trainings-Datensatz aus 30 digital erstellten Concept Maps über offene *Concept Mapping tasks* im Kontext des Klimawandels und der Energiewende erhoben. In diesen Concept Maps wurden durch die Forschenden Konzept-Cluster verortet, bei denen einzelne Konzepte in mehreren Clustern verortet sein dürfen. Diese Cluster-Strukturen dienen als Referenz für den entwickelten Algorithmus. Mithilfe dieser Ziel-Strukturen wurden verschiedenen Versionen eines möglichen Algorithmus entwickelt. Dabei wurde die Performanz stets mithilfe der Übereinstimmung der beiden Cluster-Strukturen durch den Omega-Index bestimmt (Murray et al., 2012).

Der entwickelte Concept Map Cluster (CoMaCl) Algorithmus

Der entwickelte CoMaCl Algorithmus verarbeitet die Concept Maps, die er als Input bekommt, in mehreren Schritten. Den letzten Schritt stellt ein bereits etablierter Cluster Algorithmus für mathematische Graphen dar, der sogenannte Leiden-Algorithmus (Traag et al., 2019). Vor diesem letzten Schritt müssen die strukturellen und semantischen Inhalte der Concept Map so aufgearbeitet werden, dass der Leiden-Algorithmus diese zum Finden der Cluster nutzen kann. Um dies zu erreichen, laufen die folgenden Schritte ab:

- **Einlesen der Concept Map als mathematischer Graph:** Die Concept Map wird als mathematischer Graph eingelesen, bei dem die Konzepte die Knoten und die Relationen zwischen den Konzepten die Kanten darstellen. Zusätzlich werden die Positionen der Konzepte (als x-y-Koordinaten) eingelesen sowie die Aussagen, die in der Concept Map über die Kombinationen aus Konzept-Relation-Konzept ausgelesen werden können.
- **Transformation des mathematischen Graphen:** Die Bedeutung eines Konzepts innerhalb einer Concept Map ergibt sich erst durch die Betrachtung der Relationen, in denen das Konzept zu den anderen Konzepten steht (Ruiz-Primo und Shavelson, 1996). Um diesem Umstand bei dem Finden der Cluster gerecht zu werden, wird der Graph wie in Abbildung 2 transformiert, so dass der Fokus beim Finden der Cluster auf die Aussagen gelenkt wird.

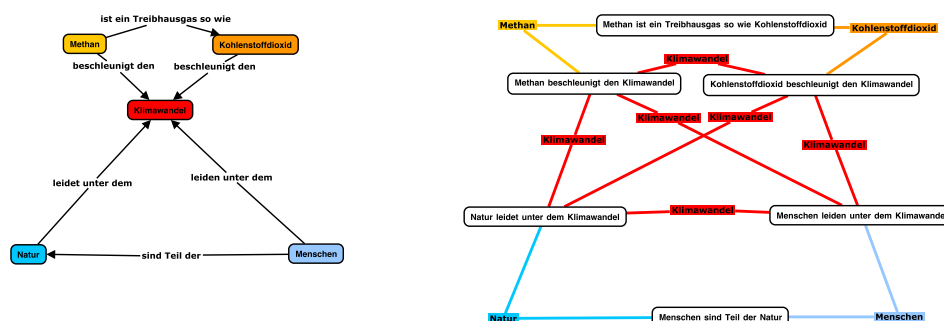


Abb. 2: Darstellung der Transformation anhand einer Beispiel Concept Map. Links der originale Graph und rechts der transformierte Graph.

[illegible]

Literatur

- de Ries, K. E., Schaap, H., van Loon, A.-A. M. J. A. P., Kral, M. M. H., & Meijer, P. C. (2022). A literature review of open-ended concept maps as a research instrument to study knowledge and learning. *Quality & Quantity*, 56, 73–107.
- Graf, D. (2014). Concept Mapping als Diagnosewerkzeug. In D. Krüger, I. Parchmann, & H. Schecker (Hrsg.), *Methoden in der naturwissenschaftsdidaktischen Forschung* (S. 325–337). Springer Spektrum.
- Gruber, H., & Mandl, H. (1996). Expertise und Erfahrung. In H. Gruber & A. Ziegler (Hrsg.), *Expertiseforschung: Theoretische und methodische Grundlagen* (S. 18–34). VS Verlag für Sozialwissenschaften.
- Mintzes, J., & Quinn, H. J. (2007). Knowledge Restructuring in Biology: Testing a Punctuated Model of Conceptual Change. *International Journal of Science and Mathematics Education*, 5(2), 281–306.
- Murray, G., Carenini, G., & Ng, R. T. (2012). Using the Omega Index for Evaluating Abstractive Community Detection. In *Proceedings of Workshop on Evaluation Metrics and System Comparison for Automatic Summarization. Association for Computational Linguistics*, 10–18.
- Reimers, N., & Gurevych, I. (2020). *Making Monolingual Sentence Embeddings Multilingual using Knowledge Distillation* (arXiv:2004.09813). arXiv.
- Rikers, R. M. J. P., Schmidt, H. G., & Boshuizen, H. P. A. (2000). Knowledge Encapsulation and the Intermediate Effect. *Contemporary Educational Psychology*, 25(2), 150–166.
- Ruiz-Primo, M. A., & Shavelson, R. J. (1996). Problems and issues in the use of concept maps in science assessment. *Journal of Research in Science Teaching*, 33(6), 569–600.
- Schwendimann, B. A. (2016). Comparing Expert and Novice Concept Map Construction Through a Talk-Aloud Protocol. In A. Cañas, P. Reiska, & J. Novak (Hrsg.), *Innovating with Concept Mapping* (S. 16–28). Springer International Publishing.
- Traag, V. A., Waltman, L., & van Eck, N. J. (2019). From Louvain to Leiden: Guaranteeing well-connected communities. *Scientific Reports*, 9(1), Article 1.