

Automatische Analyse von Diagnosekompetenzen in Fallsimulationen

Schulz, Claudia¹; Sailer, Michael²; Kiesewetter, Jan³; Meyer, Christian M.¹; Gurevych, Iryna¹; Fischer, Martin³; Fischer, Frank²

Diagnosekompetenzen spielen in vielen beruflichen Situationen eine wichtige Rolle. Diagnostizieren ist das zielgerichtete Sammeln und Integrieren von Informationen zum Zweck der bestmöglichen Entscheidungsfindung. Um Diagnosekompetenzen von Studierenden zu fördern und diese dadurch hinreichend auf ihre beruflichen Aufgaben vorzubereiten, bieten sich Fallsimulationen an. Dabei werden Studierenden berufsnahen Situationen geschildert, in denen diagnostisches Denken und Schlussfolgern erforderlich ist. Ohne hinreichendes inhaltliches Feedback ist es Studierenden jedoch nur schwer möglich ihre Diagnosekompetenzen zu verbessern. Klassische Methoden des Feedbacks, insbesondere für große Gruppen an Studierenden, sind entweder wenig Lehrkraft-intensiv jedoch allgemein (z.B. Muster- bzw. Expertenlösungen) oder adaptiv jedoch Lehrkraft-intensiv (z.B. individuelles Feedback von Experten).

Automatisches adaptives Feedback bezüglich Diagnosekompetenzen kann helfen die Nachteile klassischer Feedback Methoden zu überwinden. Ziel ist es, Methoden zu entwickeln, die Diagnosekompetenzen automatisch analysieren und evaluieren, und daher zur automatischen Erstellung von adaptivem Feedback genutzt werden können. Methoden aus der Künstlichen Intelligenz (KI) wurden bereits erfolgreich in Lehr-Lernumgebungen eingesetzt und haben hohes Zukunftspotential (Luckin, Holmes, Griffiths & Forcier, 2016), da sie sich zur automatischen Analyse von Daten eignen. Die hier untersuchte Forschungsfrage ist, inwieweit Methoden aus der KI auf Studierendenlösungen in Fallsimulationen anwendbar sind, um diese automatisch bezüglich Diagnosekompetenzen zu analysieren.

Um Diagnosekompetenzen zu untersuchen, bieten sich als Falllösungen diagnostische Essays an. Studierende schreiben dabei ihr Diagnosevorgehen während der Fallsimulation detailliert auf. Zu erwartende epistemisch-diagnostische Elemente sind u.a. (Fischer et al., 2014):

- a) Hypothesen generieren,
- b) Evidenz generieren,
- c) Evidenz evaluieren, und
- d) Schlussfolgerungen ziehen.

Um epistemisch-diagnostischen Elemente automatisch in Falllösungen zu erkennen, werden Methoden aus der KI zur automatischen Sprachanalyse verwendet. Diese Methoden lernen anhand von Beispielen, wie eine bestimmte Aufgabe zu bearbeiten ist. Die zu lernende Aufgabe ist hier das Erkennen von epistemisch-diagnostischen Elementen in einer Falllösung. Dazu werden als Beispiele diagnostische Essays verwendet, die von Studierenden während einer Fallsimulationsstudie geschrieben wurden. Damit die KI Methode lernen kann, was epistemisch-diagnostische Elemente sind, müssen diese Elemente von fachspezifischen Lehrkräften in den Beispiel-Essays annotiert werden.

Die hier gewählte Methode aus der KI ist ein Deep Learning neuronales Netzwerk namens LSTM (Long Short-Term Memory) (Hochreiter & Schmidhuber, 1997). Ein LSTM liest einen Text, ähnlich wie Menschen, Wort für Wort, hat jedoch ein „Gedächtnis“, in dem der bereits gelesene Kontext (die vorherigen Worte) gespeichert ist. Dies ermöglicht es dem LSTM, die Bedeutung eines jeden Wortes

¹ TU Darmstadt

² LMU München

³ Klinikum der Universität München

im Zusammenhang des ganzen Textes zu verstehen. Während der Lernphase stehen dem LSTM die annotierten epistemisch-diagnostischen Elemente in den Beispiel-Essays zur Verfügung. Es lernt dadurch den Zusammenhang zwischen Wörtern (im Kontext anderer „gemerkter“ Wörter) und epistemisch-diagnostischen Elemente. Nachdem es mehrere hundert beispielhafte Falllösungen gelesen hat, kann das LSTM so epistemisch-diagnostische Elemente in neuen Falllösungen erkennen.

Je mehr Beispiel-Essays ein LSTM während der Lernphase liest, desto besser kann es danach epistemisch-diagnostische Elemente in neuen Falllösungen erkennen. Jedoch bedarf die Erstellung von Beispiel-Essays eines hohen Aufwands, da diese von Fachexperten annotiert werden müssen. In dieser Arbeit werden LSTMs daher mit einem weiteren Ansatz aus der KI kombiniert, dem sogenannten Transfer Learning. Dieser Ansatz basiert auf der Idee, dass ähnliche Aufgaben ähnlich gelöst werden. Zum Beispiel ist das Erkennen von epistemisch-diagnostischen Elementen ähnlich dem Erkennen von Argumentationsstrukturen. Es gibt bereits hunderte Texte, in denen die Argumentationsstruktur annotiert ist. Ein LSTM kann anhand dieser Beispiele also lernen, Argumentationsstrukturen in neuen Texten zu erkennen. Wie zuvor beschrieben, erlernt das LSTM den Zusammenhang zwischen Wörtern und Argumentationsstruktur. Unter der Annahme, dass dieser Zusammenhang ähnlich dem für diagnostisch-epistemische Elemente ist, kann das LSTM das erlernte Zusammenhangswissen zu Argumentationsstrukturen auf diagnostisch-epistemische Elemente „transferieren“. Dadurch benötigt das LSTM weniger beispielhafte Falllösungen, da es bereits „vorgelernt“ hat.

Zum Zeitpunkt der Tagung liegt eine erste Auswertung des beschriebenen LSTMs bezüglich des Erkennens von epistemisch-diagnostischen Elementen in Falllösungen vor.

Fischer, F., Kollar, I., Ufer, S., Sodian, B., Hussmann, H., Pekrun, R., Neuhaus, B., Dorner, B., Pankofer, S., Fischer, M., Strijbos, J.-W., Heene, M. & Eberle, J. (2014). Scientific Reasoning and Argumentation: Advancing an Interdisciplinary Research Agenda in Education. *Frontline Learning Research*, 2(3), 28-45.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.

Luckin, R., Holmes, W., Griffiths, M. & Forcier, L. B. (2016). *Intelligence Unleashed: An Argument for AI in Education*. Pearson.