

Mit Erklärvideos und Simulationen Kovariation in Bayesianischen Situationen trainieren

Einleitung und theoretischer Hintergrund

Häufig werden aktuell Corona-Selbsttests durchgeführt, um festzustellen, ob man mit SARS-CoV-2 infiziert ist. Die Struktur in diesen Situationen ist exemplarisch für Bayesianische Situationen, die sich durch eine binäre Hypothese H (z. B. infiziert vs. nicht infiziert) und ein binäres Indiz I zu dieser Hypothese (z. B. ein positives vs. negatives Testergebnis) auszeichnen (Zhu & Gigerenzer, 2006). Bayesianisches Denken umfasst dann die Fähigkeit, in solchen Situationen argumentieren zu können. In einer solchen Bayesianischen Situation sind typischerweise drei Wahrscheinlichkeiten gegeben bzw. notwendig, um mit der Formel von Bayes rechnen zu können:

- Basisrate, $P(H)$: Wahrscheinlichkeit, dass eine Person mit SARS-CoV-2 infiziert ist
- Richtig-Positiv-Rate, $P(I|H)$: Wahrscheinlichkeit, dass das Testergebnis bei einer Person positiv ist, wenn sie mit SARS-CoV-2 infiziert ist
- Falsch-Positiv-Rate, $P(I|\bar{H})$: Wahrscheinlichkeit, dass das Testergebnis bei einer Person positiv ist, wenn sie nicht mit SARS-CoV-2 infiziert ist

Die Richtig- und Falsch-Positiv-Rate sind üblicherweise in den Packungsbeilagen der Selbsttests zu finden. Die Basisrate hingegen muss geschätzt werden und unterliegt zudem großen Schwankungen (z. B. durch das aktuelle Inzidenzgeschehen, Risikokontakte). In der Literatur zum Bayesianischen Denken wird bisher fast ausschließlich das Berechnen von Wahrscheinlichkeiten innerhalb solcher Bayesianischen Situationen untersucht (z. B. McDowell & Jacobs, 2017; für eine Ausnahme siehe Böcherer-Linder et al., 2017). Bedingte Wahrscheinlichkeiten, wie z. B. $P(H|I)$, kann man beispielsweise mit der Formel von Bayes berechnen:
$$P(H|I) = \frac{P(H) \cdot P(I|H)}{P(H) \cdot P(I|H) + P(\bar{H}) \cdot P(I|\bar{H})}$$
. Diesen Aspekt des Bayesianischen Denkens (das Berechnen von Wahrscheinlichkeiten) soll im Folgenden als *Performanz* bezeichnet werden. Die vielfältige Forschung zur Performanz zeigt, dass diese sowohl Laien als auch Experten schwer fällt (McDowell & Jacobs, 2017), jedoch durch zwei Strategien erleichtert werden kann: (1) Die Darstellung der gegebenen statistischen Informationen in Form von sogenannten natürlichen Häufigkeiten statt in Wahrscheinlichkeiten (Gigerenzer & Hoffrage, 1995) und (2) Die Darstellung der Bayesianischen Situation in einer geeigneten

Visualisierung (z. B. Brase, 2009). Zwei besonders geeignete Visualisierungen für die Darstellung von Bayesianischen Situationen sind der sogenannte Doppelbaum (Binder et al., 2021) und das Einheitsquadrat (Böcherer-Linder et al., 2017).

Die Performanz stellt allerdings nur einen von mehreren Aspekten des Bayesianischen Denkens dar. So fordert Borovcnik (2012), dass auch das Einschätzen von Veränderungen der Bayesianischen Situation einen wichtigen Aspekt des Bayesianischen Denkens darstellen sollte. Konkret könnte man z. B. fragen, wie sich $P(H|I)$ verändert, wenn die Basisrate $P(H)$ größer oder kleiner ist. Wir nennen diesen Aspekt des Bayesianischen Denkens *Kovariation*. Dabei beziehen wir uns auf den Kovariationsaspekt des Funktionalen Denkens (Malle, 2000) und übertragen diesen auf Bayesianische Situationen, indem wir die Formel von Bayes als Funktion mit den eingehenden Parametern als Veränderliche auffassen. Ziel dieses Beitrags ist es, einen Einblick in eine Studie im Rahmen unseres Projekts TrainBayes (<http://bayesianreasoning.de/>) zu geben, in der Kovariation als Aspekt des Bayesianischen Denkens mit Erklärvideos und mit Hilfe von Simulationen trainiert wurde.

Forschungsdesign

Da Bayesianisches Denken in vielen Anwendungsdomänen wie beispielsweise Medizin oder Rechtsprechung von Relevanz ist, haben wir als Versuchspersonengruppe Medizin- und Jurastudierende gewählt. 515 Medizin- bzw. Jurastudierende bearbeiteten Aufgaben zur Kovariation direkt vor dem Training (Prättest), direkt nach dem Training (Posttest) und 8-10 Wochen nach dem Training (Follow-up-Test). Dabei sollten die Studierenden z. B. einschätzen, wie sich eine Änderung der Basisrate auf $P(H|I)$ auswirkt, ob diese Wahrscheinlichkeit kleiner wird, gleich bleibt oder größer wird.

Material

Da (dynamische) Veränderungen der Ausgangssituation im Zentrum der Überlegungen zur Kovariation stehen, verwenden wir Erklärvideos und Simulationen zur Vermittlung der Trainingsinhalte, in denen eine dynamische Visualisierung mit zugehörigem dynamischen (Bild-)Bruch das zentrale Element darstellt (vgl. Abb. 1). Für die Entwicklung der Materialien übertragen wir dabei einerseits hilfreiche Strategien, die aus der Forschung zur Performanz bekannt sind (z. B. Visualisierung in Doppelbaum oder Einheitsquadrat und Nutzung natürlicher Häufigkeiten). Andererseits orientieren wir uns beim Design der Materialien an Gestaltungsprinzipien der Multimedia Forschung (z. B. Mayer, 2014).

Wie in der Eingangssituation beschrieben, ist die Basisrate anfällig für Schwankungen. In Abbildung 1 stellen wir die Struktur der Bayesianischen Situation (bei gleichbleibender Richtig- und Falsch-Positiv-Rate) zu zwei verschiedenen Werten der Basisrate (10% und 30%) in einem Einheitsquadrat dar (wir fokussieren uns in diesem Beitrag auf das Einheitsquadrat – in der Studie wurden Trainings mit unterschiedlichen Visualisierungen, u. a. das Einheitsquadrat und der Doppelbaum verglichen). Der positiv prädiktive Wert $P(H|I)$ ist in der jeweiligen Situation durch einen Bildbruch dargestellt.

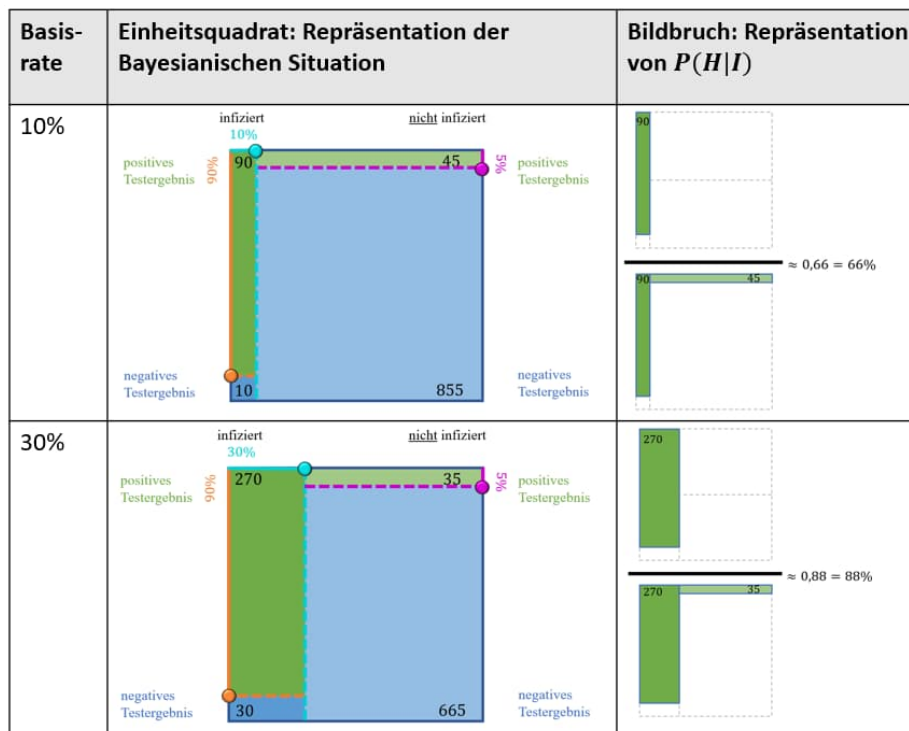


Abb. 1: Darstellung einer Bayesianischen Situation in einem Einheitsquadrat (links) und von $P(H|I)$ in einem Bildbruch (rechts) zu einer Basisrate von 10% bzw. 30%.

Ergebnisse

Die Erhebung wurde vor kurzem abgeschlossen und die Datenanalyse hat somit erst begonnen. Daher geben wir im Folgenden einige erste qualitative Einblicke in die Daten.

Abbildung 2 zeigt die Aufgabebearbeitung einer Person nach dem Training zur Kovariation. Sie betrachtet, wie sich Änderungen der drei gegebenen Wahrscheinlichkeiten zunächst auf die Seitenverhältnisse und somit auf die Flächen im Einheitsquadrat auswirken und überprüft, wie sich diese Änderungen auf den Zähler und Nenner des positiv prädiktiven Wertes auswirken.

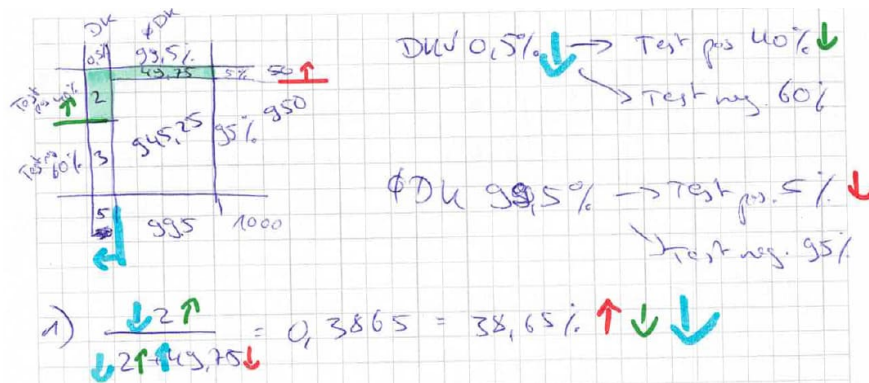


Abb. 2: Notizen eines*r Teilnehmer*in nach dem Training.

Erste Blicke in die Daten verraten, dass die Beurteilung der Veränderung der Basisrate am schwierigsten war. Zugleich vermittelt sich der Eindruck, dass die Teilnehmenden von den Trainings profitieren und beispielsweise die Folgen von Basisratenänderungen nach dem Training besser abschätzen konnten. Den informellen Rückmeldungen der Teilnehmenden zufolge stieß das Training auf große Akzeptanz.

Literatur

- Binder, K., Krauss, S., Schmidmaier, R. & Braun, L. T. (2021). Natural frequency trees improve diagnostic efficiency in Bayesian reasoning. *Advances in Health Sciences Education, 26*(3), 847–863. <https://doi.org/10.1007/s10459-020-10025-8>
- Böcherer-Linder, K., Eichler, A. & Vogel, M. (2017). The impact of visualization on flexible Bayesian reasoning. *Avances de Investigación en Educación Matemática, 11*, 25–46. <https://doi.org/10.35763/aiem.v1i11.169>
- Borovcnik, M. (2012). Multiple Perspectives on the Concept of Conditional Probability. *Avances de Investigación en Educación Matemática, 2*, 5–27. <https://doi.org/10.35763/aiem.v1i2.32>
- Brase, G. L. (2009). Pictorial representations in statistical reasoning. *Applied Cognitive Psychology, 23*(3), 369–381. <https://doi.org/10.1002/acp.1460>
- Gigerenzer, G. & Hoffrage, U. (1995). How to improve Bayesian reasoning without instruction: Frequency formats. *Psychological Review, 102*(4), 684–704. <https://doi.org/10.1037/0033-295X.102.4.684>
- Malle, G. (2000). Zwei Aspekte von Funktionen: Zuordnung und Kovariation. *Mathematik lehren, 103*, 8–11.
- Mayer, R. E. (Hrsg.). (2014). *Cambridge handbooks in psychology. The Cambridge handbook of multimedia learning*. Cambridge University Press. <https://doi.org/10.1017/CBO9781139547369>
- McDowell, M. & Jacobs, P. (2017). Meta-analysis of the effect of natural frequencies on Bayesian reasoning. *Psychological bulletin, 143*(12), 1273–1312. <https://doi.org/10.1037/bul0000126>
- Zhu, L. & Gigerenzer, G. (2006). Children can solve Bayesian problems: the role of representation in mental computation. *Cognition, 98*(3), 287–308. <https://doi.org/10.1016/j.cognition.2004.12.003>