

Anhang 2: Zusatzmaterial

Punkt A

I. Materialentwicklung

Eye-Tracking-Aufzeichnungen

EKG-Auswahl. Die diagnostischen Lernziele wurden aus einer früheren mehrstufigen Delphi-Studie abgeleitet (1), welche einen Expertenkonsens über die erwarteten EKG-Befundungskompetenz für Medizinstudierende im letzten klinischen Jahr ermittelte. Dementsprechend wurden 15 pathognomonische (anonymisierte) echte Patienten-EKGs, die typische elektrophysiologische Merkmale und kardiologische Diagnosen zeigten, als hochauflösende Bilder zusammengestellt. Im Einzelnen waren dies: normales (gesundes) EKG/ ventrikuläre Tachykardie/ Bradykardie, anteriorer/ anterolateraler/ posteriorer ST-Hebungsinfarkt, Schrittmacher-EKG mit supraventrikulärer/ ventrikulärer Stimulation, EKG mit supraventrikulären/ ventrikulären Extrasystolen, kompletter/ inkompletter Linksschenkelblock, inkompletter Rechtsschenkelblock, Erregungs-Rückbildungsstörung, Vorhofflimmern, AV-Block Grad I.



Abbildung 1 Der in dieser Studie verwendete Eye-Tracker (Ergoneers Dikablis Glasses 3, mit Genehmigung)




Abbildung 2 Linke Seite: EyeRecToo. Pfeile: violett = Erkennung des linken Auges; grün = ArUco-Marker; pink = Marker, der den Blick anzeigt. Rechte Seite: ERTViewer.

Eye-Tracking. Ein Kardiologieexperte, der einen mobilen Eye-Tracker (siehe Abb. 1) trug, wurde gebeten, alle EKGs still und nach eigenem Ermessen zu interpretieren und dann die Diagnosen verbal zu nennen (um zu signalisieren, dass er zu einem Ergebnis gekommen war). Die stille Befundung ermöglicht eine Betrachtung, die nicht durch geteilte Aufmerksamkeit beeinträchtigt wird, da eines das andere beeinträchtigen kann (2, 3). Jede der 15 Aufnahmen



Abbildung 3 Visualisierung von zwei Momentaufnahmen während der Eye-Tracking EKG-Befundung

Anhang 1 zu Scherff AD, Käab S, Fischer MR, Berndt M. *EYE-ECG: An RCT of the influence of student characteristics and expert eye-tracking videos with cued retrospective reporting on students' ECG interpretation skills*. GMS J Med Educ. 2024;41(4):Doc40. DOI: 10.3205/zma001695

begann und endete auf einem leeren Bildschirm mit einem zentralen Fixationskreuz. Nur während der ungestörten stillen visuellen Suche und des Befundungsprozesses wurden die EKGs gezeigt und Blickbewegungsmuster aufgezeichnet. Für die Aufzeichnung und Datenerfassung wurden Ergoneers Dikablis Glasses 3 Hardware und Open-Source-Software EyeRecToo (4) verwendet (siehe Abb. 2). Ein für diese Studie selbst entwickeltes Python-Skript (unter Verwendung von Python 3.8 in Spyder 5.4.3; verwendete Pakete waren numpy, pandas, matplotlib.pyplot, copy, scipy.stats, time) wurde für die Nachbearbeitung der Sensor-Rohdaten erstellt (z. B. Glättung des Blickverlaufs bei Augenblinzeln, Korrektur für die Kopfposition über ArUco (5) Marker, Extraktion von Augen- und Feldmarkern aus den Rohdaten und Projektion auf die hochauflösenden EKG-Bilder für eine anschließende hochwertige Präsentation für Teilnehmende). Eine Qualitätskontrolle wurde durchgeführt, indem die Originalaufnahmen frame-weise auf dem ERTViewer (6) mit den Python-Projektionen verglichen wurden und dies zeigte identische Positionen/ Pfade für die fokussierten EKG-Merkmale; die nach der Kalibrierung erreichte Genauigkeit des Eye-Trackings entsprach den derzeitigen technischen Grenzen bei einem Blickwinkel von 0,5-1,0° (7).

Cued Retrospective Reporting Aufnahmen

Videoclips. Zur Vorbereitung der CRR-Audiokommentar Aufnahmen wurden 15 kurze Videoclips erstellt, die das Blickmuster des Experten für die einzelnen EKGs zeigen; hierbei hing die Länge der Clips mit 8-27 Sekunden von der vorherigen Dauer der Blickaufzeichnung ab. Wie von Jarodzka und Kollegen vorgeschlagen (8), wurde der Blick des Experten (mit Python) als sich bewegendem roter Fokuspunkt mit einer 500 ms langen Spur visualisiert, welche die zuvor betrachteten Stellen markierte. Die Größe der Markierung variierte dynamisch mit der Blickintensität (Verweildauer, abgeleitet aus der zugrundeliegenden Gauß'schen Heatmap), sodass eine längere fokussierte Betrachtungszeit an größeren Kreisen erkennbar war. Im Unterschied zu den opaken Flecken von Jarodzka et al. wurde entschieden, die Flecken semi-transparent zu machen, damit die untersuchten EKG-Merkmale darunter leichter überprüfbar sind (siehe Abb. 3).

Audiokommentar. Die 15 Videos wurden dann demselben Experten als visuelle Cues präsentiert, verbunden mit der Aufforderung, das eigene Blickverhalten und die diagnostischen Prozesse während der Befundung der EKGs (z.B. Gedankengänge, Strategie,

diagnostische Informationen) retrospektiv verbal zu erklären (= CRR). Die einzelnen tonlosen Clips wurden in Echtzeit (d.h. in Originalgeschwindigkeit) in einer Dauerschleife abgespielt und die spontanen, ungeprobten Erläuterungen zu jedem EKG wurden so lange aufgezeichnet, bis der Experte signalisierte, alles zu dem jeweiligen Clip beigetragen zu haben. Zusammenfassend generierten die in Schleife abgespielten Videos sowohl verbale Erklärungen zu EKG-Merkmalen einerseits genau zu jenem Zeitpunkt, zu welchem sie hervorgehoben wurden, als auch andererseits längere Gedankengänge zu Betrachtungsmustern.

Punkt B


Statistische Analysen

Alle Analysen wurden mit R durchgeführt (RStudio Cherry Blossom, mit den Paketen readxl, plyr, stringr, car, tidyr, dplyr, reshape2, ggplot2, ggcorrplor, psych). Gruppenweise Vergleiche von INT vs. TAU wurden mit Welch's t-Tests durchgeführt (9); Prä-Post-Vergleiche wurden mit t-Tests für verbundene Stichproben durchgeführt. Die statistischen Grundannahmen wurden getestet und als ausreichend erfüllt angesehen. Die Modellbildung für die EKG-Befundungskompetenzen der Studierenden wurde empirisch (d. h. bottom-up) betrachtet, wobei untersucht wurde, welche Kombination von Studierendenmerkmalen die post-Test Scores am besten vorhersagte. Als Ausgangspunkt wurden alle 26 erhobenen Prädiktoren, einschließlich Teilnehmendenmerkmalen, objektiver und subjektiver Lernfaktoren, Motivation, klinischer Fälle, Prä-Test Scores und der Lernintervention jeweils in ein vollständiges Modell mit jedem der drei Ergebniswerte (BS, RS, CS) eingefügt. Dies ermöglichte eine Schätzung der maximalen Varianz, welche in der EKG-Befundungskompetenz der Studierenden erklärt wird, wenn umfangreiche Daten sowohl über die Studierenden als auch über ihre Antwortstrategie vorhanden sind. Anschließend wurde ein reduziertes Modell abgeleitet, indem schrittweise die am wenigsten prädiktiven Faktoren entfernt wurden, während gleichzeitig die größtmögliche Varianzaufklärung beibehalten wurde, bis eine finale Lösung erreicht war, was statistisch anhand des Akaike-Informationskriterium (AIC) bestimmt wurde. Diese finalen Modelle gaben einen Einblick, welches studentische Merkmal oder welche Lernkomponente in erster Linie angesprochen werden sollte, um die EKG-Befundungskompetenz von Medizinstudierenden auf die gewünschte spezifische Antwortstrategie hin zugeschnitten zu optimieren.


Punkt C

Bivariate Assoziationen der Modellvariablen:

TAU Gruppe: Korrelations-Matrix



INT Gruppe: Korrelations-Matrix



EYE-EKG/ "Interventionsgruppe" (INT): Die 38 dargestellten Variablen und ihre Reihenfolge entsprechen den in den Regressionsmodellen verwendeten. Die Effektgrößen sind Pearson-Korrelationen/Punkt-Biserial-Korrelationen. [] bezieht sich auf die Referenzkategorie. BS = Basis Score, RS = Relativer Score, CS = Conservativer Score. Frei skalierbare SVG-Grafik verfügbar via die Erstautorin.

Punkt D

Tabelle der Ergebnisse der Regressionsmodelle für die drei EKG-Befundungsscores:

Konzeptgruppe	Spezifischer EKG-Befundungsscore (Outcome) → ↓ Eingeschlossene Variablen (Prädiktoren)	I. Basis Score				II. Relativer Score				III. Conservativer Score			
		vollständiges Modell		finales Modell		vollständiges Modell		finales Modell		vollständiges Modell		finales Modell	
		beta	p-Wert	beta	p-Wert	beta	p-Wert	beta	p-Wert	beta	p-Wert	beta	p-Wert
Lernintervention	(Konstante)	20.05	.24	18.27	< .01	0.79	.97	2.91	.62	51.51	< .04*10 ⁻¹	50.94	.04*10 ⁻⁵
	Gruppe [INT]	2.09	.24			2.30	.27			1.00	.60		
Teilnehmenden- merkmale/ obj. Lerneigenschaften	Alter	0.12	.77			0.10	.83			-0.20	.66		
	Geschlecht [M]	-0.83	.68			-0.46	.85			0.08	.97		
	Bildungsjahre	-0.08	.88			0.16	.80			-0.29	.59	-0.52	.14
	vorherige Berufsausbildung [ja]	-0.69	.81			-3.30	.34			0.83	.79		
	Fachsemester	-0.24	.75			-0.77	.40			-0.22	.79		
	Anzahl vorheriger EKG-Kurse	-0.84	.55			-0.18	.91			-0.53	.73	0.02	.12
	PJ-Tertiale	-1.50	.53			-0.77	.79			0.84	.75		
	Kardiologiefamulatur [ja]	3.09	.11	3.23	< .05	4.15	.08	3.95	.05	2.08	.32		
subj. Lern- eigenschaften	Anzahl vorheriger EKG-Befundungen	0.01	.45			0.02	.20			0.02	.19		
	Interesse an EKGs	0.14	.03	0.14	< .01	0.20	< .01	0.20	< .02*10 ⁻¹	0.16	.02	0.19	< .06*10 ⁻²
	Vertrauen in die eigene Lernstrategie	-0.07	.29			-0.08	.34			-0.11	.12	-0.09	.16
	Zugänglichkeit des Materials	-0.17	.11	-0.18	.02	-0.17	.17	-0.18	.06	-0.17	.13	-0.13	.10
	Mentaler Flow-State	-0.01	.86			< 0.01	.92			-0.03	.74		
Involvement der Teilnehmenden	Selbst-Rating Nutzen des Trainings	0.04	.77			0.04	.76			0.10	.43		
	Ausgeruhtheit (Prä)	0.06	.43			0.06	.47			< 0.01	.92		
	Ausgeruhtheit (Mitte)	-0.03	.73			0.03	.82			-0.02	.83		
	Ausgeruhtheit (Post)	0.02	.78			-0.03	.73			0.05	.48		
	Motivation (Prä)	-0.05	.53			-0.05	.59			0.02	.83		
Lernhalt	Motivation (Mitte)	< -0.01	.93			-0.12	.21	-0.08	.17	0.03	.71		
	Motivation (Post)	0.03	.67			0.08	.30			< -0.01	.95		
	Prä-Test	0.23	.05	0.29	.07*10 ⁻²	0.23	.08	0.33	.01*10 ⁻¹	0.30	.01	0.34	.02*10 ⁻²
	klinischer Fall 1	0.35	< .01	0.34	.04*10 ⁻³	0.38	.03*10 ⁻¹	0.31	< .01*10 ⁻¹	0.04	.76		
	klinischer Fall 2	0.02	.87			0.10	.32	0.12	.12	0.07	.30		
	klinischer Fall 3	0.13	.28			0.14	.29			0.07	.43	0.12	.07
	klinischer Fall 4	-0.05	.66			-0.07	.57			0.04	.67		
Modellstatistiken: $R^2 = .57, R^2_{adj} = .39, F(26,63) = 3.19, p < .01*10^{-2}$ $R^2 = .50, R^2_{adj} = .47, F(5,84) = 17.03, p < .02*10^{-6}$ $R^2 = .63, R^2_{adj} = .47, F(26,63) = 4.04, p < .03*10^{-1}$ $R^2 = .57, R^2_{adj} = .53, F(7,82) = 15.39, p < .01*10^{-14}$ $R^2 = .49, R^2_{adj} = .28, F(26,63) = 2.35, p < .03*10^{-1}$ $R^2 = .44, R^2_{adj} = .39, F(7,82) = 9.15, p < .03*10^{-6}$													
Anmerkung: [] bezeichnet Referenzgruppe; die Berechnungen der Scores (s. Abschnitt statistische Analysen) für Prä-Test und klinische Fälle 1-4 entsprechen jeweils modellweise den spezifischen (BS, RS, CS) Strategien für die Regressionsoutcomes; Modelselektion schrittweise rückwärts via AIC; signifikante Prädiktoren in Fettschrift													

Referenzen Beilage

1. Höger A. Ein kompetenzorientierter Lernzielkatalog für die Elektrokardiogramm-Befundung. München: LMU München; 2016.
2. Jou J, Harris RJ. Die Wirkung von geteilter Aufmerksamkeit auf die Sprachproduktion. Bull Psychon Soc. 1992;30(4):301-304. DOI: 10.3758/BF03330471
3. Hutton S, Tegally D. The effects of dividing attention on smooth pursuit eye tracking. Expl Brain Res. 2005;163(3):306-313. DOI: 10.1007/s00221-004-2171-z
4. Santini T, Fuhl W, Geisler D, Kasneci E. EyeRecToo: Open-source Software for Real-time Pervasive Head-mounted Eye Tracking. in: Proceedings of the 12th International Joint Conferences on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2017). Setúbal, Portugal: SCITEPRESS - Science and Technology Publications; 2017. p.96-101. DOI: 10.5220/0006224700960101
5. Romero-Ramirez FJ, Muñoz-Salinas R, Medina-Carnicer R. Speeded up detection of squared fiducial markers. Image Vision Comp. 2018;76:38-47. DOI: 10.1016/j.imavis.2018.05.004
6. Universität Tübingen. EyeRecToo. Tübingen: Universität Tübingen; 2019. Zugänglich unter/available from: <https://www.hci.uni-tuebingen.de/research/Engagement%20&%20Interaction/eyerectoo.html>
7. Feit AM, Williams S, Toledo A, Paradiso A, Kulkarni H, Kane S, Morris MR. Toward everyday gaze input: Accuracy and precision of eye tracking and implications for design. in: CHI'17: Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems. 2017. p.1118-1130. DOI: 10.1145/3025453.3025599
8. Jarodzka H, Scheiter K, Gerjets P, Van Gog T. In the eyes of the beholder: Wie Experten und Neulinge dynamische Stimuli interpretieren. Learn Instruct. 2010;20(2):146-154. DOI: 10.1016/j.learninstruc.2009.02.019
9. Rasch D, Kubinger KD, Moder K. The two-sample t test: pre-testing its assumptions does not pay off. Stat Papers. 2011;52(1):219-231. DOI: 10.1007/s00362-009-0224-x