



Maschinelles Lernen zur Klassifizierung von Antwortverhalten in psychologischen Messverfahren: Kann ML helfen Verfälschungsverhalten zu detektieren?

Vortrag im Forschungskolloquium des Lehrstuhls Fakultät Wirtschaftsinformatik und Angewandte Informatik, Professur für Angewandte Informatik, insbes. Kognitive Systeme, Otto-Friedrich-Universität Bamberg
Vorsitz: Prof. Dr. Ute Schmid
Referentin: Dr. Jessica Röhner

Agenda

- **Theoretischer Hintergrund und Relevanz**
- **Forschungsfragen**
- **Methode**
- **Ergebnisse**
- **Interpretation**
- **Zeit für Diskussion**

Theoretischer Hintergrund und Relevanz



Die Arbeit von Psycholog*innen und die Forderung nach Unverfälschbarkeit

- Psycholog*innen testen Hypothesen, erforschen Verhalten und stellen Diagnosen (z. B. Röhner & Schütz, 2022)
- Hierfür notwendig: Gütekriterium der Unverfälschbarkeit psychologischer Verfahren (Moosbrugger & Kelava, 2020)
 - Unverfälschbarkeit: Das Verfahren ist so konstruiert, dass die untersuchten Personen ihre Testwerte durch gezieltes Verhalten nicht steuern können.
- Jedoch konnten zahlreiche Studien nachweisen, dass psychologische Verfahren verfälschbar sind (z. B. Birkeland et al., 2006; Viswesvaran & Ones, 1999)
- Selbst Verfahren, denen Unverfälschbarkeit quasi ungeprüft attestiert wurde, (z. B. Implizite Assoziationstests; IATs) zeigten Verfälschbarkeit (z. B. Röhner & Ewers, 2016a, 2016b; Röhner & Lai, 2021)

Was ist Verfälschungsverhalten?

„Faking represents a response set aimed at providing a portrayal of the self that helps a person to achieve personal goals. Faking occurs when this response set is activated by situational demands and person characteristics to produce systematic differences in test scores that are not due to the attribute of interest.“ (Ziegler et al., 2012)

„Verfälschung ist ein soziales Phänomen, welches intentionales und täuschendes Verhalten von Personen gegenüber anderen Personen beschreibt. Es spielt in verschiedenen diagnostischen Kontexten eine Rolle (z. B. Eignung, Forensik, etc.) - vor allem in Situationen, welche für die betreffenden Personen Anreize zur Verfälschung bieten. Relevant sind dabei die jeweiligen Ziele der untersuchten Personen. Es wird als Verhalten und nicht als Persönlichkeitsmerkmal verstanden. Art und Intensität des [verfälschten Antwortverhaltens] werden durch ein Zusammenspiel von Merkmalen der Person und Merkmalen der Situation beeinflusst. Verfälschung birgt Risiken für die Diagnostik, da es zu Fehleinschätzungen kommen kann. Neben den Ursachen sind auch die Folgen von Verfälschungsversuchen abhängig von mehreren Faktoren [...].“ (Röhner & Schütz, 2020)

Konsequenzen von Verfälschungsverhalten

- Verfälschungsverhalten ist jedoch nicht nur möglich, sondern für diagnostisch arbeitende Psycholog*innen auch ein Problem, da es u. a. Testwerte der Personen oder Rangreihen für Selektionsentscheidungen verändert und sogar verändert, was das Verfahren misst (z. B. Salgado et al., 2016; see Ziegler et al., 2012, for an overview)
- Entsprechend ist man seit über 100 Jahren auf der Suche nach sicheren Detektoren für Verfälschungsverhalten (z. B. Sackett et al., 2017)

Die Suche nach dem heiligen Gral...der Wunsch nach Verfälschungsdetektoren

- Für die wenigsten Verfahren gibt es valide Detektoren für Verfälschungsverhalten (z. B. Röhner & Schütz, 2019; Ziegler et al., 2012)
- Funktionstüchtigkeit tw. an Rahmenbedingungen der Erhebung gebunden (z. B. Röhner & Holden, 2022)
- Selbst Expert*innen können Verfälschungsverhalten nicht über Zufallsniveau korrekt erkennen (z. B. Fiedler & Bluemke, 2005)
- Maschinelles Lernen (ML) könnte bei diesem komplexen Unterfangen hilfreich sein (Boldt et al., 2018; Calanna et al., 2020)
 - Korrekte Zuordnung von Verfälschenden und Nichtverfälschenden hängt vom angewandten Algorithmus ab (Logistische Regression vs. Random Forest vs. XGBoost; Calanna et al., 2020)
 - Korrekte Zuweisung von Verfälschenden und Nichtverfälschenden hängt auch von der Art der Inputdaten ab (Response patterns vs. Scores; Calanna et al., 2020)
- Jedoch hängt Verfälschungsverhalten selbst von einer Reihe von Faktoren ab => bisher nicht berücksichtigt (z. B. Röhner et al., 2011)


Die Problematik: Verfälschungsverhalten ist ein komplexes Geschehen

Faktoren, die Verfälschungsverhalten beeinflussen:

- Zu verfälschendes Messinstrument (Röhner et al., 2011; Ziegler et al., 2007)
- Zu verfälschendes Konstrukt (z. B. Steffens, 2004)
- Richtung des Verfälschens (z. B. Bensch et al., 2019; Röhner et al., 2023)
- Vorwissen der Proband*innen über Verfälschungsstrategien (informed faking vs. naïve faking; Röhner et al., 2013)
- Übung im Verfälschen (Röhner et al., 2011)

=> ML sucht nach Unterschieden zwischen den Gruppen (hier: Verfälschende und Nichtverfälschende) und daher sollte Verfälschungsverhalten dann besonders gut entdeckt werden können, wenn Unterschiede zwischen den Gruppen besonders groß sind (d. h. bei starkem Verfälschungsverhalten).

Forschungsfragen



Forschungsfragen

1. Kann ML Verfälschungsverhalten besser im Fragebogen, als im IAT detektieren?
2. Kann ML Verfälschungsverhalten vergleichbar gut in verschiedenen Konstrukten detektieren (Extraversion, Gewissenhaftigkeit, Need for Cognition und Selbstwert)?
3. Kann ML Verfälschungsverhalten besser entdecken, wenn niedrige Werte als wenn hohe Werte simuliert werden sollen?
4. Kann ML Verfälschungsverhalten besser detektieren, wenn Proband*innen über Strategien informiert wurden (informed faking) als wenn sie ohne empfohlene Strategien verfälschen sollten (naive faking)?

Forschungsfragen

5. Kann ML Verfälschungsverhalten bei Proband*innen, die Übung im Verfälschen hatten besser entdecken, als bei Proband*innen, die keine Übung hatten?
6. Fragebögen: Können wir replizieren, dass das Nutzen des gesamten Antwortmusters als Input in ML im Hinblick auf die Detektion von Verfälschung besser ist als das Nutzen der Testscores? IAT: Können wir bisherige Befunde erweitern und nachweisen, dass empirisch validierte Faking-Indices als Input in ML die Detektion sogar noch weiter verbessern?
7. Können wir replizieren, dass XGBoost der geeignetste Ansatz für Detektion von Verfälschungsverhalten im Fragebogen ist?

Methodik



Adobe Stock | #386325982

Method

- **Versuchspersonen und Datensets:**

- Set 1: $N = 84$ (28 faking low, 28 faking high, 28 control; 74 students; 64 women; average age: 22.37 years, $SD = 4.45$)
- Set 2: $N = 197$ (66 faking low, 67 faking high, 64 control; 196 students, 1 no response; 165 women; average age: 21.44 years, $SD = 2.95$)
- Set 3: $N = 260$ (88 faking low, 86 faking high, 86 control; 257 students; 191 women; average age: 21.22 years, $SD = 4.74$)
- Set 4: $N = 293$ (104 faking low, 94 faking high, 95 control; 293 students; 220 women; average age: 22.31 years, $SD = 4.09$)
- Set 5: $N = 199$ (67 faking low, 65 faking high, 67 control; 199 students; 163 women; average age: 21.53 years, $SD = 3.18$)
- Set 6: $N = 299$ (105 faking low, 97 faking high, 97 control; 299 students; 225 women; average age: 22.06 years, $SD = 4.07$)
- Set 7: $N = 84$ (28 faking low, 28 faking high, 28 control; 74 students; 64 women; average age: 22.37 years, $SD = 4.45$)

Methode

Prozedur:

- Versuchsteilnehmende absolvierten eine Baseline-Messung und wurden im Anschluss randomisiert auf eine der Bedingungen: Verfälschung hoher Werte, Verfälschung niedriger Werte oder Kontrollgruppe zugewiesen
- Ob Proband*innen Übung oder nicht im Verfälschen hatten und ob sie naiv oder mit Hilfe empfohlener Strategien verfälschen sollten, variierte zwischen den Studien
- 4 Cluster:
 1. Naives Verfälschen ohne Übung
 2. Naives Verfälschen mit Übung
 3. Informiertes Verfälschen ohne Übung
 4. Informiertes Verfälschen mit Übung

Methode

Messinstrumente:

A) Fragebögen

1. Extraversion-Skala aus dem NEO-Five Factor Inventory (Borkenau & Ostendorf, 2008)
2. Gewissenhaftigkeit-Skala NEO-Five Factor Inventory (Borkenau & Ostendorf, 2008)
3. Need for Cognition-Skala (Bless et al., 1994)
4. Rosenbergs Selbstwert-Skala (von Collani & Herzberg, 2003)

B) IATs

- Extraversion-IAT (Back et al., 2009)
- Gewissenhaftigkeit-IAT (Steffens & Schulze-König, 2006)
- Need for Cognition IAT (Fleischhauer et al., 2013)
- Selbstwert-IAT (Greenwald & Farnham, 2000; Rudolph et al., 2006)

Exkurs: Implizite Assoziationstests (IATs)

- Bestes Instrument, um Implizite Assoziationen zu messen (Bar-Anan & Nosek, 2014)
- Computergestützte Zuordnungsaufgabe, bei der Proband*innen Stimuli zu Kategorien zuordnen sollen
- Aufforderung = so schnell und möglichst fehlerfrei zu arbeiten
- Messung von Reaktionszeiten (und Fehlern) bei der Zuordnung
- Berechnung des IAT-Effektes (*D* score; Greenwald et al., 2003a, 2003b; Röhner & Thoss, 2019)
- IAT-Effekt gibt u. a. Assoziationsstärke zwischen den präsentierten Kategorien wieder



IAT-Prozedur
(Schema
adaptiert von
Röhner, 2014)

Phase	Linke Taste (<i>D</i>)	Beispielstimuli	Rechte Taste (<i>K</i>)
Übung			
Übung		Drücken Sie „D“ für ANGENEHM oder ICH	Drücken Sie „K“ für UNANGENHEM oder NICHT ICH
Test Kompatible Bedingung		GLÜCK	
Übung			
Test Inkompatible Bedingung			

Faking the Implicit Association Test (IAT): Success, Detection,
and Processes

Phase	Linke Taste (<i>D</i>)	Beispielstimuli	Rechte Taste (<i>K</i>)
Übung			
Übung		Drücken Sie „D“ für ANGENEHM oder NICHT ICH	Drücken Sie „K“ für UNANGENEHM oder ICH
Test Kompatible Bedingung		MIR	
Übung			
Test Inkompatible Bedingung		D	K
			© J. Röhner

Data set	Measurement occasion	Self-reports			IATs		
		<i>M</i>	(<i>SD</i>)	Cronbach's α	<i>M</i>	(<i>SD</i>)	Split-half reliabilities
<i>Extraversion</i>							
1	Baseline	30.02	6.26	.75	0.24	0.44	.86
	Naive faking without practice	25.16	13.47	.94	0.16	0.57	.91
	Informed faking without practice	26.57	12.34	.95	0.19	0.86	.97
2	Baseline	29.77	6.27	.77	0.35	0.35	.73
	Naive faking without practice	26.41	13.68	.95	0.24	0.48	.81
	Naive faking with one practice trial	26.64	14.62	.96	0.20	0.47	.79
	Naive faking with two practice trials	27.06	14.77	.96	0.20	0.46	.70
	Naive faking with three practice trials	26.69	15.36	.97	0.20	0.47	.79
3	Baseline	28.00	6.26	.80	0.21	0.41	.84
	Naive faking without practice	26.03	14.34	.96	0.14	0.61	.88
4	Baseline	27.70	7.20	.85	0.12	0.43	.83
	Naive faking without practice	25.94	14.84	.97	0.13	0.56	.81
<i>Conscientiousness</i>							
5	Baseline	32.53	7.04	.86	0.56	0.30	.71
	Naive faking without practice	28.05	14.46	.97	0.45	0.43	.80
	Naive faking with one practice trial	27.73	15.65	.98	0.39	0.47	.80
	Naive faking with two practice trials	27.75	16.57	.98	0.37	0.44	.75
	Naive faking with three practice trials	27.39	16.59	.98	0.38	0.45	.79
<i>Need for Cognition</i>							
6	Baseline	16.02	11.88	.87	-0.04	0.44	.78
	Naive faking without practice	5.76	31.76	.98	0.00	0.57	.84
<i>Self-Esteem</i>							
7	Baseline	23.10	4.98	.87	0.70	0.28	.78
	Naive faking without practice	19.11	10.62	.98	0.47	0.48	.86
	Informed faking without practice	20.23	9.21	.97	0.30	0.93	.96
	Informed faking with one practice trial	20.01	9.54	.97	0.36	0.87	.93
	Informed faking with two practice trials	19.81	9.08	.97	0.37	0.78	.96

Methode

Input Data

- **Response Pattern** (d. h. alle IAT-trials bzw. Antworten auf alle Items)
- **Scores** (d. h. D_2 und IAT_V in IATs; Test Scores in Fragebögen)
- **Faking Indices** (d. h. CTS, IAT_a , IAT_{t_0} , Ratio 150-10000, Slow_Co, IncErr_Co für naives und informiertes Verfälschen in Richtung niedriger Werte; CTS, IAT_a , Ratio 150-10000, Accel_Co für naives Verfälschen in Richtung hoher Werte; CTS, IAT_a , IAT_{t_0} , Ratio 150-10000, Slow_Co bzw. Slow_In für informiertes Verfälschen niedriger und hoher Werte) (Cvencek et al., 2010; Röhner & Thoss, 2018; Agosta et al., 2011; Röhner et al., 2013)

Method

Maschinelles Lernen

- Drei Arten von Klassifizierern wurden gegeneinander getestet: Logistische Regression vs. Random Forest vs. XGBoost (Boldt et al., 2018; Calanna et al., 2020)
- Tuning: 5-fold cross-validation (Cawley & Talbot, 2010)
- Performanzschätzung: 10-fold cross-validation (Cawley & Talbot, 2010)
- Optimierung im Hinblick auf F1 Score (Calanna et al., 2020)

Ergebnisse



Adobe Stock | #392513199

Ergebnisse im Überblick

- Manipulations-Check: Mittels ANOVAs überprüft, ob Proband*innen in der Lage waren alle Messinstrumente zu verfälschen=> Ja.
- Verfälschungsverhalten konnte meist überzufällig korrekt entdeckt werden, aber *F1* Score variierte beträchtlich zwischen Bedingungen (von .44 bis .98)
- Beispiel:

Model: IAT_C_H_NF_0_S_RF (faking condition: naïve faking of high scores on the conscientiousness IAT without practice; classifier: random forest; input data: scores)

- $F1 = .44$ (Precision = .45; Recall = .44)
- Nur 45 % der Personen, die als Fälscher*innen klassifiziert wurden, waren auch tatsächlich Fälscher*innen (55% waren Nichtfälscher*innen)
- Nur 44 % der Fälscher*innen, die es gab, wurden gefunden (56% wurden übersehen)

Model: IAT_SE_L_IF_0_FI_LR (faking condition: informed faking of low scores on the self-esteem IAT without practice; classifier: logistic regression; input data: faking indices)

- $F1 = .98$ (Precision = .97; Recall = 1.00)
- 97 % Personen, die als Fälscher*innen klassifiziert wurden, waren tatsächlich Fälscher*innen (nur 3% waren Nichtfälscher*innen)
- 100 % der Fälscher*innen, die es gab, wurden gefunden (0 % wurden übersehen)


Ergebnisse: Naives Verfälschen ohne Übung

X-Achse: Performanz-Indices

Y-Achse: Performanzbewertung (0 bis 1)

Geometrische Formen indizieren den Klassifizierer (d. h. logist. Regression = Kreis; Random Forest = Dreieck, XGBoost = Quadrat).

Farben kodieren Art der Input Data (Response Pattern = gelb, Scores = rot, Faking Indices = blau)




Ergebnisse: Naives Verfälschen mit Übung

X-Achse: Performanz-Indices

Y-Achse: Performanzbewertung (0 bis 1)

Geometrische Formen indizieren den Klassifizierer (d. h. logist. Regression = Kreis; Random Forest = Dreieck, XGBoost = Quadrat).

Farben kodieren Art der Input Data (Response Pattern = gelb, Scores = rot, Faking Indices = blau)




Ergebnisse: Informiertes Verfälschen ohne und mit Übung

X-Achse: Performanz-Indices


Y-Achse: Performanzbewertung (0 bis 1)

Geometrische Formen indizieren den
Klassifizierer (d. h. logist. Regression = Kreis;
Random Forest = Dreieck, XGBoost =
Quadrat).

Farben kodieren Art der Input Data (Response
Pattern = gelb, Scores = rot, Faking Indices =
blau)



Interpretation



Interpretation

1. Fragebogen vs. IAT

- Verfälschende, die ohne empfohlene Verfälschungsstrategien verfälschten (naive faking), konnten mit Hilfe von ML *besser* (ohne Übung: d und 95% CI = -1.03 [-1.42, -0.65]; mit Übung: d und 95% CI = -1.00 [-1.32, -0.68]; unabhängig von Übung) *im Fragebogen, als im IAT* detektiert werden.
- Dies galt *weniger stark oder* sogar *nicht wenn* verfälscht wurde und *Proband*innen über Verfälschungsstrategien informiert* wurden (informed faking; ohne Übung: d und 95% CI = -0.55 [-1.08, -0.03]; mit Übung: -0.43 [-0.95, 0.10]).

=> Messinstrument macht einen Unterschied, besonders wenn Proband*innen keine Testknacker-Strategien haben.

Interpretation

2. Einfluss vom Konstrukt?

- Wenn Proband*innen *ohne empfohlene Verfälschungsstrategien verfälschten und keine Übung hatten*, war die *Detektion besser für die Konstrukte Extraversion und Need for Cognition und schlechter für Selbstwert und Gewissenhaftigkeit*.
- Extraversion und Need for Cognition ungefähr gleich (d and 95% CI = -0.09 [-0.59, 0.42])
- Beides etwas besser als Selbstwert (d s and 95% CIs = need for cognition versus self-esteem: -0.61 [-1.12, -0.10]; extraversion versus self-esteem: -0.56 [-1.07, -0.04])
- Beides viel besser als Gewissenhaftigkeit (d s and 95% CIs = need for cognition versus conscientiousness: -0.80 [-1.33, -0.27]; extraversion versus conscientiousness: 0.75 [-1.27, -0.22])

Interpretation

2. Einfluss vom Konstrukt?

- Wenn Proband*innen *ohne empfohlene Verfälschungsstrategien verfälschten und Übung hatten*, war die *Detektion vergleichbar* (d and 95% CI = -0.08 [-0.37, 0.21])
- Wenn Proband*innen *empfohlene Verfälschungsstrategien hatten und verfälschten*, war die *Detektion vergleichbar* (d and 95% CI = -0.09 [-0.60, 0.42])

=> Konstrukt macht einen Unterschied, besonders dann wenn Proband*innen keine Testknacker-Strategien haben und auch keine Übung.

Interpretation

3. Verfälschung in Richtung hoher vs. in Richtung niedriger Werte

- *Verfälschung in Richtung niedriger Werte* (faking low) konnte *besser* (*ds* and 95% CIs = naïve faking ohne Übung: -1.25 [-1.64, -0.86], naïve faking mit Übung: -1.79 [-2.13, -1.44], informed faking ohne Übung: -1.10 [-1.64, -0.56], informed faking mit Übung: -1.58 [-2.16, -1.00]) *detektiert* werden *als Verfälschung in Richtung hoher Werte* (faking high).

=> Die Richtung des Verfälschens beeinflusst die Detektion von Fälscher*innen.
Verschiedene Prozesse?

Interpretation

4. Naive Faking vs. informed Faking

- Verfälschung von Proband*innen *mit Informationen über Verfälschungsstrategien* (informed faking) *konnte besser* (d and 95% CI = -0.40 [-0.61, -0.18]) *detektiert werden als* Verfälschung von Proband*innen *ohne Informationen über Verfälschungsstrategien* (naive faking).

=> Personen, die sich an Testknackerstrategien orientieren, können besser identifiziert werden, als „individuell“ Verfälschende.

Interpretation

5. Verfälschung ohne Übung versus mit Übung

- Verfälschung konnte *mit verschiedenen Übungslevels vergleichbar gut detektiert* werden (naive faking: d s and 95% CIs = without practice versus one practice trial: -0.08 [-0.39, 0.23], without practice versus two practice trials: -.24 [-0.55, 0.07], and without practice versus three practice trials: -0.15 [-0.46, 0.16]; informed faking, d s and 95% CIs = without practice versus one practice trial: -0.08 [-0.58, 0.43], and without practice versus two practice trials: 0.00 [-0.51, 0.51]).

=> Information über Testknacker-Strategien ist wichtiger als Übung.

Interpretation

6. Input Data

- Verfälschung *im Fragebogen* konnte *mittels Response Patterns und Scores etwa gleich gut detektiert werden* (d and 95% CI = -0.19 [-0.49, 0.11])
- Verfälschung *im IAT* konnte *am besten mit Faking Indices detektiert* werden. *Scores* waren *am wenigsten geeignet* (d s and 95% CIs faking indices versus response patterns: -0.24 [-0.54, 0.06], response patterns versus scores: -0.40 [-0.71, -0.09], and faking indices versus scores: -0.62 [-0.93, -0.31])

=> Offensichtlich spielt die Länge des Messinstrumentes eine Rolle, ob das Response Pattern einen Mehrwert zum Score hat.

Interpretation

7 . Logistische Regression versus Random Forest versus XGBoost

- Verfälschung konnte *mittels Logistischer Regression und Random Forest etwa gleich gut detektiert werden* (d and 95% CI = -0.08 [-0.31, 0.16])
- *Logistische Regression, aber nicht Random Forest, war besser als XGBoost* in der Detektion von Verfälschung (d s and 95% CIs = logistic regression versus XGBoost: -0.25 [-0.48, -0.01]; random forest versus XGBoost: -0.17 [-0.40, 0.07])

=> Der Klassifizierer muss überlegt gewählt werden.

Implikation

1. Maschinelles Lernen kann dabei helfen Verfälschende aufzuspüren.
2. Wie gut die Detektion gelingt, variiert jedoch beträchtlich.
3. Eine Reihe von Faktoren (z. B. die Umstände unter denen Verfälschungsverhalten zu Stande kam) muss bedacht werden, da sie das Ergebnis massiv beeinflussen können.
4. Verfälschungsverhalten spiegelt sich in unterschiedlichen Input-Daten wider, was die Qualität der Detektion maßgeblich beeinflusst.
5. Der Klassifizierer selbst beeinflusst die Detektionsqualität (z. B. Random Forest vs. logist. Regression).

Zeit für Fragen und Anmerkungen...

www.Blickreflex.de / pixelio.de



Vielen Dank für Ihre
Aufmerksamkeit!

Vielen Dank an meine/n
Coautor*in für die fruchtbare
Zusammenarbeit!

Referenzen

Agosta, S., Ghirardi, V., Zogmaister, C., Castiello, U., & Sartori, G. (2011). Detecting fakers of the autobiographical, *IAT. Applied Cognitive Psychology*, *25*, 299–306.

<https://doi.org/10.1002/acp.1691>

Back, M. D., Schmukle, S. C., & Egloff, B. (2009). Predicting actual behavior from the explicit and implicit self-concept of personality. *Journal of Personality and*

Social Psychology, *97*, 533–548. <https://doi.org/10.1037/a0016229>

Bar-Anan, Y., & Nosek, B. A. (2014). A comparative investigation of seven indirect attitude measures. *Behavior research methods*, *46*(3), 668–688.

<https://doi.org/10.3758/s13428-013-0410-6>

Bensch, D., Maaß, U., Greiff, S., Horstmann, K. T., & Ziegler, M. (2019). The nature of faking: A homogeneous and predictable construct? *Psychological Assessment*,

31, 532–544. <https://doi.org/10.1037/pas0000619>

Birkeland, S. A., Manson, T. M., Kisamore, J. L., Brannick, M. T., & Smith, M. A. (2006). A meta-analytic investigation of job applicant faking on personality measures.

International Journal of Selection and Assessment, *14*, 317–335. <https://doi.org/10.1111/j.1468-2389.2006.00354.x>

Referenzen

- Bless, H., Wänke, M., Bohner, G., Fellhauer, R. F., & Schwarz, N. (1994). Need for Cognition: Eine Skala zur Erfassung von Engagement und Freude bei Denkaufgaben. *Zeitschrift für Sozialpsychologie*, 25, 147–154.
- Boldt, B.J., While, Z., & Breimer, E. (2018). Detecting compromised Implicit Association Test results using supervised learning, *17th IEEE International Conference on Machine Learning and Applications (ICMLA)*., Orlando FL, 2018.
- Borkenau, P., & Ostendorf, F. (2008). *NEO-Fünf-Faktoren Inventar nach Costa und McCrae (NEO-FFI)* (Manual 2. Aufl.) [NEOFFI. Neo-Five-Factor inventory according to Costa and McCrae_ Manual. 2nd Edition]. Hogrefe.
- Calanna, P., Lauriola, M., Saggino, A., Tommasi, M., Furlan, S. (2020). Using a supervised machine learning algorithm for detecting faking good in a personality self-report. *International Journal Select Assessment*, 28, 176–185. <https://doi.org/10.1111/ijsa.12279>
- Cawley, G., & Talbot, N. (2010). On over-fitting in model selection and subsequent selection bias in performance evaluation. *Journal of Machine Learning Research*, 11, 2079–2107.

Referenzen

- Cvencek, D., Greenwald, A. G., Brown, A. S., Gray, N. S., & Snowden, R. J. (2010). Faking of the Implicit Association Test is statistically detectable and partly correctable. *Basic and Applied Social Psychology*, 32, 302–314. <https://doi.org/10.1080/01973533.2010.519236>
- Fiedler, K., & Bluemke, M. (2005). Faking the IAT: Aided and unaided response control on the Implicit Association Tests. *Basic and Applied Social Psychology*, 27, 307–316. https://doi.org/10.1207/s15324834basp2704_3
- Fleischhauer, M., Strobel, A., Enge, S., & Strobel, A. (2013). Assessing implicit cognitive motivation: Developing and testing an implicit association test to measure need for cognition. *European Journal of Personality*, 27, 15–29. <https://doi.org/10.1002/per.1841>
- Greenwald, A., & Farnham, S. (2000). Using the Implicit Association Test to measure self-esteem and self-concept. *Journal of Personality and Social Psychology*, 79, 1022–1038. <https://doi.org/10.1037/00223514.79.6.1022>
- Greenwald, A., Nosek, B., & Banaji, M. (2003a). Understanding and using the Implicit Association Test: I. An improved scoring algorithm. *Journal of Personality and Social Psychology*, 85, 197–216. <https://doi.org/10.1037/0022-3514.85.2.197>

Referenzen

- Greenwald, A., Nosek, B., & Banaji, M. (2003b). 'Understanding and using the Implicit Association Test: I. An improved scoring algorithm': Correction to Greenwald et al. (2003). *Journal of Personality and Social Psychology*, 85, 481. <https://doi.org/10.1037/h0087889>
- Moosbrugger, H., & Kelava, A. (2020). Qualitätsanforderungen an Tests und Fragebogen (“Gütekriterien”). In H. Moosbrugger, & A. Kelava (Hrsg.), *Testtheorie und Fragebogenkonstruktion* (S.13–38). Springer-Verlag.
- Röhner, J. (2014). Faking the Implicit Association Test (IAT): Predictors, processes, and detection. Dissertation. TU Chemnitz. <https://nbn-resolving.org/urn:nbn:de:bsz:ch1-qucosa-133049>
- Röhner, J., & Ewers, T. (2016a). How to analyze (faked) Implicit Association Test data by applying diffusion model analyses with the fast-dm software: A companion to Röhner & Ewers (2016). *The Quantitative Methods for Psychology*, 12(3), 220–231. <https://doi.org/10.20982/tqmp.12.3.p220>
- Röhner, J., & Ewers, T. (2016b). Trying to separate the wheat from the chaff: Construct- and faking-related variance on the Implicit Association Test (IAT). *Behavior Research Methods*, 48(1), 243–258. <https://doi.org/10.3758/s13428-015-0568-1>

Referenzen

- Röhner, J., & Holden, R. R. (2022). Challenging response latencies in faking detection: The case of few items and no warnings. *Behavior Research Methods*, *54*(1), 324–333. <https://doi.org/10.3758/s13428-021-01636-z>
- Röhner, J., Holden, R. R., & Schütz, A. (2023). IAT faking indices revisited: Aspects of replicability and differential validity. *Behavior Research Methods*, *55*(2), 670–693. <https://doi.org/10.3758/s13428-022-01845-0>
- Röhner, J., & Lai, C. K. (2021). A diffusion model approach for understanding the impact of 17 interventions on the race Implicit Association Test. *Personality and Social Psychology Bulletin*, *47*(9), 1374–1389. <https://doi.org/10.1177/0146167220974489>
- Röhner, J., Schröder-Abé, M., & Schütz, A. (2011). Exaggeration is harder than understatement, but practice makes perfect! Faking success in the IAT. *Experimental Psychology*, *58*(6), 464–472. <https://doi.org/10.1027/1618-3169/a000114>
- Röhner, J., Schröder-Abé, M., & Schütz, A. (2013). What do fakers actually do to fake the IAT? An investigation of faking strategies under different faking conditions. *Journal of Research in Personality*, *47*(4), 330–338. <https://doi.org/10.1016/j.jrp.2013.02.009>

Referenzen

- Röhner, J., & Schütz, A. (2019). Faking behavior. In V. Zeigler-Hill and T. K. Shackelford (Eds.), *Encyclopedia of Personality and Individual Differences* (S. 1553–1558). Springer. https://doi.org/10.1007/978-3-319-28099-8_2341-1
- Röhner, J., & Schütz, A. (2020). Verfälschungsverhalten in Psychologischer Diagnostik. *Report Psychologie*, 45(9), 16–23.
- Röhner, J., & Schütz, A. (2022). Psychologische Diagnostik. In A. Schütz, M. Brand, H. Selg, & S. Lautenbacher (Hrsg.), *Psychologie: Eine Einführung in ihre Grundlagen und Anwendungsfelder* (6. Aufl., S. 199–218). Kohlhammer.
- Röhner, J., & Thoss, P. J. (2018). EZ: An easy way to conduct a more fine-grained analysis of faked and nonfaked Implicit Association Test (IAT) data. *The Quantitative Methods for Psychology*, 14(1), 17–37. <https://doi.org/10.20982/tqmp.14.1.p017>
- Röhner, J., & Thoss, P. J. (2019). A tutorial on how to compute traditional IAT effects with R. *The Quantitative Methods for Psychology*, 15(2), 134–147. <https://doi.org/10.20982/tqmp.15.2.p134>

Referenzen

Röhner, J., Thoss, P. J., & Schütz, A. (2022). Lying on the dissection table: Anatomizing faked responses. *Behavior Research Methods*, 54(6), 2878–2904.

<https://doi.org/10.3758/s13428-021-01770-8>

Rudolph, A., Schröder, M. & Schütz, A. (2006). Ein Impliziter Assoziationstest zur Erfassung von Selbstwertschätzung [An Implicit Association Test of self-esteem]. In

T. M. Ortner, R. T. Proyer & K. D. Kubinger (Hrsg.), *Theorie und Praxis Objektiver Persönlichkeitstests* (S. 153–163). Huber.

Sackett, P. R., Lievens, F., Van Iddekinge, C. H., & Kuncel, N. R. (2017). Individual differences and their measurement: A review of 100 years of research. *Journal of*

Applied Psychology, 102, 254–273. <https://doi.org/10.1037/apl0000151>

Salgado, J. F. (2016). A theoretical model of psychometric effects of faking on assessment procedures: Empirical findings and implications for personality at work.

International Journal of Selection and Assessment, 24, 209–228. <https://doi.org/10.1111/ijsa.12142>

Steffens, M. C. (2004). Is the Implicit Association Test Immune to Faking? *Experimental Psychology*, 51(3), 165–179. <https://doi.org/10.1027/1618-3169.51.3.165>

Referenzen

- Steffens, M. C., & König, S. S. (2006). Predicting spontaneous big five behavior with implicit association tests. *European Journal of Psychological Assessment*, 22(1), 13–20. <https://doi.org/10.1027/1015-5759.22.1.13>
- Viswesvaran, C., & Ones, D. S. (1999). Meta-analyses of fakability estimates: Implications for personality measurement. *Educational and Psychological Measurement*, 59, 197–210. <https://doi.org/10.1177/00131649921969802>
- Von Collani, G., & Herzberg, P. (2003). Eine revidierte Fassung der deutschsprachigen Skala zum Selbstwertgefühl von Rosenberg [A revised version of the German Rosenberg Self-Esteem Scale]. *Zeitschrift für Differentielle und Diagnostische Psychologie*, 24, 3–7. <https://doi.org/10.1024//0170-1789.24.1.3>
- Ziegler, M., MacCann, C., & Roberts, R. D. (2012). Faking: Knowns, unknowns, and points of contention. In M. Ziegler, C. MacCann & R. D. Roberts (Eds.), *New perspectives on faking in personality assessment* (pp. 3-16). Oxford University Press.
- Ziegler, M., Schmidt-Atzert, L., Bühner, M., & Krumm, S. (2007). Fakability of different measurement methods for achievement motivation: Questionnaire, semi-projective, and objective. *Psychology Science*, 49, 291–307.