

Daten aus zweiter Hand

Datenreanalyse zur Überprüfung explorativer Hypothesen in der psychologischen Forschung

Martin J. Binsler, Matthias Spörrle und Friedrich Försterling

kumulierter Zeitaufwand

Abstract
Zielsetzung
 Eignungsprüfung der Methode:
Knowledge Discovery in Databases (KDD)
 für die psychologische Forschung

Definition KDD
 Identifizierung von Mustern in großen Datensätzen
Methode
 Vergleich der Befunde von KDD mit klinischer Studie bzgl. Depression nach fötalem Verlust
Ergebnis
 Relatives Risiko: KDD = 2.1; klinische Studie = 2.9
Diskussion
 • Ökonomie bei Passung des Primärdatensatzes
 • zur Testung explorativer Hypothesen geeignet


Einleitung
Ausgangslage
 Zunehmende Verfügbarkeit „psychologischer“ Primärdaten (z.B. Primärdatenbanken, Datenverarbeitung einer Krankenkasse)
Fragestellung
 KDD als valide, reliable, objektive und ökonomische Methode in der psychologischen Forschung?
Hypothese
 KDD kann ein erhöhtes relatives Risiko für Depression nach fötalem Verlust nachweisen.

Methode
 (Fayyad et al., 1996)
N = 49.063
 (Stand 1999)

N = 1.865

N = 1.249

Relatives Risiko (RR)
 2.1 KDD
 2.9 Klinisch



Daten(bank)auswahl
Medical Expenditure Panel Survey (MEPS; Cohen, 1997)
 • frei verfügbare medizinische Langzeitstudie der amerikanischen Gesundheitsbehörde
 • repräsentativer Durchschnitt der USA
 • reliable Messung durch CAPI und Daten der Versicherungsträger
 • Angaben über Fehlgeburten (Befragung & ICD-9)
 • Angaben über die Behandlung psychischer Erkrankungen (ICD-9)

Datenaufbereitung
Einschlusskriterium (N = 1.865)
 nur Frauen mit Schwangerschaftsereignis (Fehlgeburt, Totgeburt, Geburt)
Problem
 • Informationen in über 100 Datenfiles verteilt (verschiedene Jahre, medizinische Information nach Ort der Behandlung, etc.)

MEPS: überlappendes Paneldesign in fünf Runden über 2 Jahre hinweg

MEPS Panel	Kalenderjahr				
	1996	1997	1998	1999	
1 (A)	Runde				
	1A	2A	3A	4A	5A
2 (B)	Runde				
	1B 2B 3B		4B 5B		
3 (C)	Runde				
	1C 2C 3C		4C 5C		
	22.598 Personen	20.866 Pers.		11.439 Pers.	10.439 Pers.

Lösung
 • Bündelung der Info in einem Arbeitsfile
 • Variablenberechnung in div. Originalfiles

Daten-vorverarbeitung
Probleme
 • starke Heterogenität der Daten, z.B. Geburtsereignisse: taggenau (74%) bis 5 Monate
 • Informationen zum Schwangerschaftsstatus z.T. inkonsistent (AHRQ, 2003)
 • unklare zeitliche Assoziation von Depression und Schwangerschaftsereignis
Lösung (=> N = 1.249)
 • Reliabilitätsindex für Schwangerschaftsereig. Ausschluss: Vertrauensintervalle > 3 Monate
 • Validitätsindex für Schwangerschaftsereig. Ausschluss z.B. berichtete Geburt ohne Kind
 • Reduktion des Auswertungsniveaus: Dichotomisierung, da keine zeitliche Validierung der Depression möglich
 => **Resultierende Variablen:**
Depression (dichotom)
 • mindestens ein Depressionsereignis (ICD-9) in 2 J. (gesamter Beobachtungszeitraum)
Fötaler Verlust (dichotom)
 • mindestens eine Fehl- oder Totgeburt in 2 Jahren

Muster (Ergebnis)
Absolute Häufigkeiten
 • 17,7% aller Schwangerschaften fötale Verluste (incl. 1,1% Totgeburten)
 • 4,4% depressive Erkrankung (6,9% insgesamt psychische Erkrankungen)
Auswahl klinische Studie Neugebauer et al. (1992)
 • größte klinische Studie zum Thema
 • Schwangere als Kontrollgruppe
 • Maß CES-D als Schätzung für die Häufigkeit depressiver Erkrankungen
KKD (N = 1249) vs. klinische Studie (N = 515)

	Relatives Risiko	Abs. Häufig. föt. Verlust	Abs. Häufig. Geburt	Abs. Häufig. χ^2
KDD	2.1	7.7%	3.7%	6.79**
Klinische Studie	2.9	24.1%	8.3%	23.82***

**p < .01, zweiseitig
 ***p < .001, zweiseitig

Wissen (Diskussion)
Validität
 + KDD guter Schätzer für Verhältnisse (RR)
 – Sicherung der Validität (Depression) führt zu Verlust des Datenniveaus
 – keine Kausalitätsaussage möglich (Depression, Folge oder Auslöser?)
Reliabilität
 + nach Ausschlüssen hohe Reliabilität
 – aber unter Verringerung der Stichprobe
Ökonomie
 + Zeitaufwand Eigenerhebung > KDD
 – Datenauswahl, -aufbereitung und Datenvorverarbeitung verursacht hohen Zeitaufwand!
Objektivität
 + möglich bei Reduktion auf geringes Datenniveau (hier Dichotomisierung)
 – aufwendig z.B. bei Bestimmung präziser zeitlicher Assoziationen von Ereignissen
Fazit
 • wenn Primärdatensatz mit hoher Passung zur Hypothese vorhanden
 • geeignete Methode zur Exploration psychologischer Hypothesen

Primärdatenbanken im Internet

www.nsd.uib.no/cessda

Council Of European Social Science Data Archives

www.psychdata.zpid.de (im Aufbau)

Zentrum für Psychologische Information und Dokumentation

www.gesis.org/za

Zentralarchiv für Empirische Sozialforschung der Universität Köln

Literatur
 • Agency for Healthcare Research and Quality. (2003). *MEPS HC-046 1996-2000 Pregnancy Files*. Retrieved 25-03, 2002, from www.meps.ahrq.gov available on demand
 • Cohen, S. (1997). Sample design of the 1996 Medical Expenditure Panel Survey Household. *MEPS Methodology Report*, 2, Pub. No. 97-0027.
 • Fayyad, U.-M., Piatetsky-Shapiro, G., Smyth, P., & Uthurusamy, R. (Eds.). (1996). *Advances in knowledge discovery and data mining*. Menlo Park.
 • Neugebauer, R., Kline, J., O'Connor, P., Shrout, P., Johnson, J., Skodol, A., et al. (1992). Depressive symptoms in women in the six months after miscarriage. *American Journal of Obstetrics and Gynecology*, 166(1 Pt 1), 104-109.
PDF dieses Posters unter www.binsler.de