

Causal diagrams

(directed acyclic graphs, DAGs)

Eine qualitative Methode, um u.a. zu entscheiden, nach
welchen Variablen man adjustieren muss

Vortrag beim OSIP-Treffen am 15.1.2020

Michael Höfler


Klinische Psychologie und Behaviorale Neurowissenschaft
Institut für Klinische Psychologie und Psychotherapie
Fakultät für Psychologie
TU Dresden

Korrigierte Version vom 11.2.2021

Inhalte

1. Kausale Schlüsse **gehen immer über die Daten** hinaus.
2. **Qualitative Annahmen** lassen sich mit causal diagrams ausdrücken
3. Die **Regeln** von causal diagrams = DAGs (directed acyclic graphs)
4. Wie kann man damit **kausale Effekte schätzen**?
5. DAGs für andere Probleme der Datenauswertung (nichtspezifisch für kausale Inferenz)
6. Diskussion

Konzepte dieses Vortrags
sind leicht verständlich hier
nachzulesen:



Quelle: //bayes.cs.ucla.edu

Thinking Clearly About Correlations and Causation: Graphical Causal Models for Observational Data

Advances in Methods and
Practices in Psychological Science
2018, Vol. 1(1) 27–42
© The Author(s) 2018
Reprints and permissions:
sagepub.com/journalsPermissions.nav
DOI: 10.1177/2515245917745629
www.psychologicalscience.org/AMPPS

SAGE

Julia M. Rohrer

International Max Planck Research School on the Life Course, Max Planck Institute for Human Development,
Berlin, Germany; Department of Psychology, University of Leipzig; and German Institute for Economic Research,
Berlin, Germany

[Annu Rev Sociol.](#) Author manuscript; available in PMC 2018 Aug 13.

PMCID: PMC6089543

Published in final edited form as:

NIHMSID: NIHMS979472

[Annu Rev Sociol.](#) 2014 Jul; 40: 31–53.



PMID: [30111904](#)

Published online 2014 Jun 2. doi: [10.1146/annurev-soc-071913-043455](#)

Endogenous Selection Bias: The Problem of Conditioning on a Collider Variable


[Felix Elwert](#)¹ and [Christopher Winship](#)²

Technischer:



Kausale Schlüsse gehen immer über die Daten hinaus

Für eine Assoziation zwischen X und Y gibt es mindestens fünf mögliche Erklärungen:



Die zeitliche Richtung eines Zusammenhangs ((a)-(c)) lässt sich in Längsschnittstudien bestimmen. Längsschnittstudien sind aber **nicht hinreichend** für kausale Schlüsse. (Streng genommen noch nicht mal notwendig, falls man eine zeitliche Richtung aus inhaltlichen Überlegungen annehmen kann.)

Z = gemeinsame Ursache,
 ϵ = Messfehler

Annahmen
jenseits der Daten

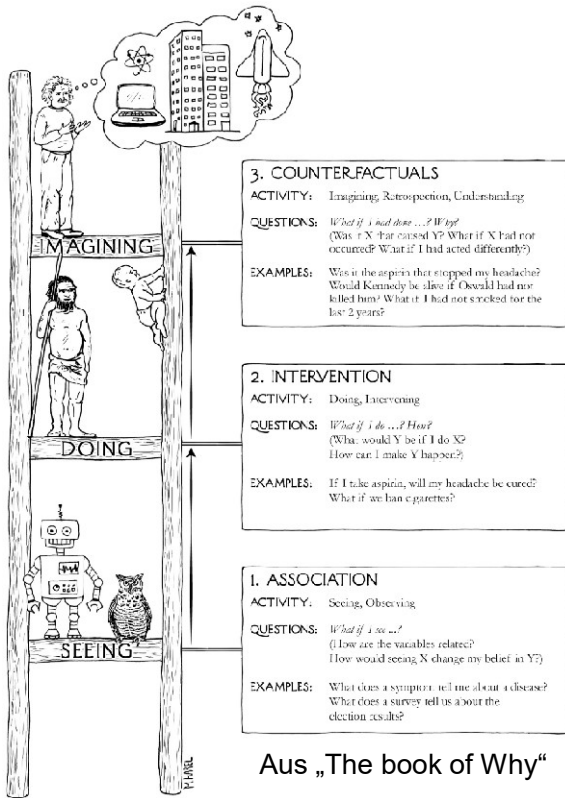
Schlussfolgerung

(a)
(b)
(c)
(d)
(e)

Randomisierte Experimente/klinische Studien sind nicht das sine qua non des kausalen Schließens.

Judea Pearls „ladder of causation“

Mehr Kognition




Solch kausales Denken ist evolutionär tief in uns Menschen angelegt: Was würde passieren, wenn ...?

Exogenes **X** = **Effekt**. Was passiert mit **Y**, wenn ich **X** verändere?

Endogenes **X** = **Assoziation**. Was passiert mit **Y**, wenn ich **X** nur **beobachte** (**X** verändert sich durch seine natürlichen Bedingungsfaktoren)?



exlibris.net



Kreativität:
 „turning all the knobs“: verändere imaginär alle Faktoren, bis etwas interessantes Neues entsteht

Achtung mit dem „Mantra“ (Pearl) „correlation is not causation“

Gemeint: Mit nichtrandomisierten/nichtexperimentellen Studien (Beobachtungsstudien) kann man **nur Korrelationen** (Assoziationen) untersuchen, keine Effekte.

Aber: Manche Korrelationen enthalten einen **kausalen Anteil**.




Lungenkrebs

Effekt wurde jahrzehntelang mit diesem Totschlagsargument bestritten: Da man den Effekt nicht experimentell und randomisiert untersuchen kann, gibt es keinen Nachweis dafür. Also gehen wir davon aus, dass es ihn nicht gibt.

Das spezifische Problem kausaler Inferenz:
gemeinsame Ursachen von **X** und **Y**

Randomisierung



Kopple **X** von seinen natürlichen Ursachen, **Z**, ab!

Bias (systematischer Fehler) in der Schätzung des Einflusses von **X** auf **Y** (β) durch **Z** = $\alpha_1 * \alpha_2$

Randomisierung: $\alpha_1 = 0$, **kein Bias**

Man kann einen kausalen Schluss nicht allein aus den Daten ziehen

Bias = 0 nur garantiert, falls:

- **Randomisierte** Gruppeneinteilung ($x = 0, x = 1$)
- **Repräsentative Stichprobe aus der Zielpopulation** (+ 100% Teilnahme, 0% Dropout)
- **Perfekte Compliance** in beiden Gruppen, bei allen Probanden
- **0 Messfehler** in Outcome y bei allen Probanden
- **Korrektes Modell** zur Analyse der Daten

Die Annahme, dass dies alles zuträfe (mit 100% Wahrscheinlichkeit), liegt **außerhalb** der Daten!

In: **Computation, Causation, and Discovery**. Eds. P Glymour and G. Cooper. Menlo Park, CA, Cambridge, MA: AAAI Press / The MIT Press. 1999. pp. 305-321.

CHAPTER EIGHT

On the Impossibility of Inferring
Causation from Association without
Background Knowledge

James M. Robins and Larry Wasserman

J. R. Statist. Soc. A (2005)
168, Part 2, pp. 267–306


Multiple-bias modelling for analysis of observational data

Sander Greenland
University of California, Los Angeles, USA

"Solving statistical problems without context is like boxing while blindfolded. You might hit your opponent in the nose, or you might break your hand on the ring post."

<https://towardsdatascience.com/>

Methodiker




Fragen über nötige **Annahmen über Prozesse jenseits der Daten**, von denen kausale Schlussfolgerung abhängt.

z.B. Psychologe



Inhaltliche Antworten darauf



Gemeinsamer kausaler Schluss

BMC Medical Research Methodology

Home About Articles Submission Guidelines In Review

Debate | [Open Access](#) | [Open Peer Review](#) | Published: 17 April 2018

Writing a discussion section: how to integrate substantive and statistical expertise

[Michael Höfler](#) | [John Venz](#), [Sebastian Trautmann](#) & [Robert Miller](#)

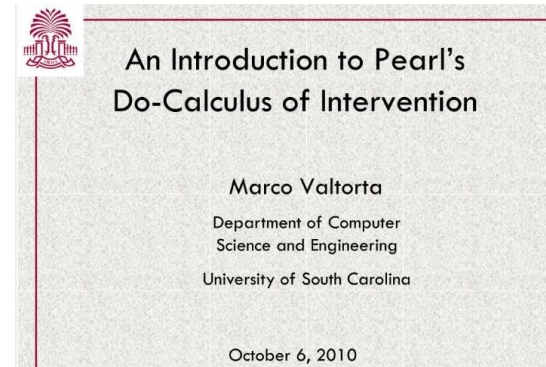
[BMC Medical Research Methodology](#) 18, Article number: 34 (2018) | [Cite this article](#)

3869 Accesses | 1 Citations | 18 Altmetric | [Metrics](#)

Big data/machine learning kann das Modell hinter den Daten nicht ersetzen

Denn diese Verfahren unterscheiden nicht:
Was passiert mit \mathbf{Y}

- ... wenn ich Änderungen in \mathbf{x} **beobachte**?
- ... wenn ich \mathbf{x} **verändere**? („do(X)“)



<https://www.slideserve.com/jileen>

Annahmen jenseits der Daten lassen sich mit **causal diagrams** ausdrücken

Der Verwendung **komplizierter quantitativer Methoden** gehen **einfachere qualitative Überlegungen** voraus.

Diese münden in ein **quantitatives Modell** (zeigen, ob und wie sich ein Effekt quantitativ und ohne Bias schätzen lässt).

	DR ₁	DR ₀
General form	$\frac{Y_{X=1} \times X}{PS}$	$\frac{\hat{Y}_1(X-PS)}{PS} + \frac{Y_{X=0}(1-X)}{1-PS} + \frac{\hat{Y}_0(X-PS)}{1-PS}$
Among X = 1	$\frac{Y_{X=1}}{PS}$	$\frac{\hat{Y}_1(1-PS)}{PS}$
Among X = 0	\hat{Y}_1	$\frac{Y_{X=0}}{1-PS} - \frac{\hat{Y}_0 \times PS}{1-PS}$

Abbreviations: DR, doubly robust; PS, propensity score.
^a PS = $p(X = 1|Z)$; X = exposure; $Y_{X=0}$ and $Y_{X=1}$ = observed outcome among individuals with X = 0 and X = 1, respectively; $\hat{Y}_0 = E(Y|X = 0, Z)$ = predicted outcome given X = 0; $\hat{Y}_1 = E(Y|X = 1, Z)$ = predicted outcome given X = 1.


semanticscholar.org

Causal diagrams sind non-parametrisch

Es ist egal wie die Variablen skaliert und verteilt sind, und wie sie aufeinander wirken.

→ visualisiert kausalen Effekt

Beispiel:



Gleichbedeutend zu:

$$\mathbf{RS} = f_{\mathbf{RS}}(\mathbf{SE}, \boldsymbol{\epsilon}_{\mathbf{RS}})$$

$f_{\mathbf{RS}}$ = beliebige Funktion, die man nicht kennen muss.
 $\boldsymbol{\epsilon}_{\mathbf{RS}}$ = alle anderen Faktoren, die **RS** auch beeinflussen,
aus Sparsamkeit nicht visualisiert.


In **Strukturgleichungsmodellen** hingegen bezeichnet → i.d.R. einen **linearen, additiven** Effekt.

= Directed acyclic graphs (DAGs)


allgemeinere mathematische Methode, um Annahmen über Beziehungen auszudrücken. Hier: **kausale** Beziehungen (sonst bedingte Zusammenhänge → “Bayesian networks”, “Netzwerkmodelle”)

„**Directed**“ = gerichtet, hier → = kausale Richtung (impliziert zeitliche Richtung)

„**Acyclic**“: Graph darf keine Zirkel enthalten. Nicht erlaubt z.B.:




Stattdessen mehrere Variablen für mehrere Zeitpunkte, z.B.:



Direkte und indirekte Effekte

Pfeile sind **direkte** Effekte — im Sinne der im Diagramm dargestellten Variablen:

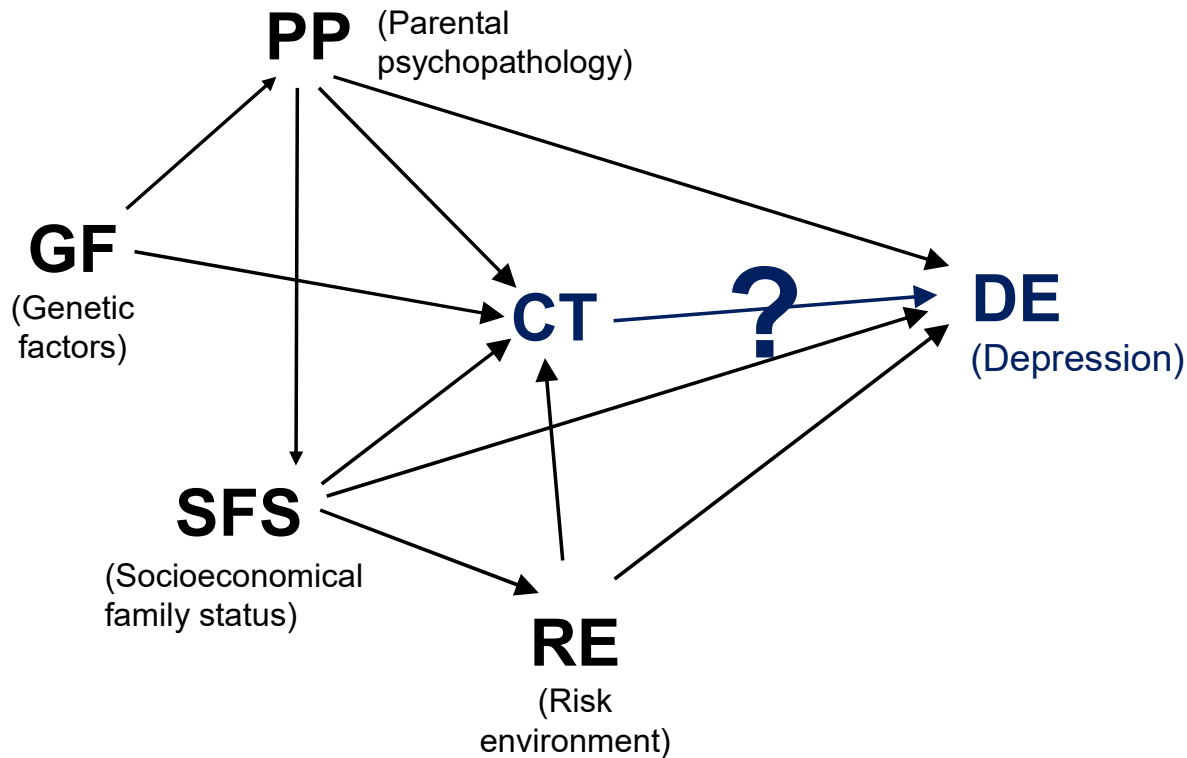


Hier wirkt z.B. SE_1 sowohl direkt auf SE_2 , aber auch indirekt über den **Pfad** $SE_1 \rightarrow RE_1 \rightarrow SE_2$

$SE_1 \rightarrow SE_2$ muss nicht im absoluten Sinne ein direkter Effekt sein, könnte auch über andere, nicht dargestellte Variablen vermittelt sein, z.B. $SE_1 \rightarrow Z \rightarrow SE_2$

Vollständigkeit: Welche Variablen muss ein DAG enthalten?

- Soll der Effekt eines x auf ein y geschätzt werden, muss das Modell nur vollständig hinsichtlich **gemeinsamer Ursachen** von x und y sein
- Beispiel: Modell für Einfluss von **childhood trauma (CT)** auf **depression (DE)**:



Beispiel aus eingereichtem Artikel:

Causal comparisons in non-randomized studies:
concepts, modelling, study design and analysis

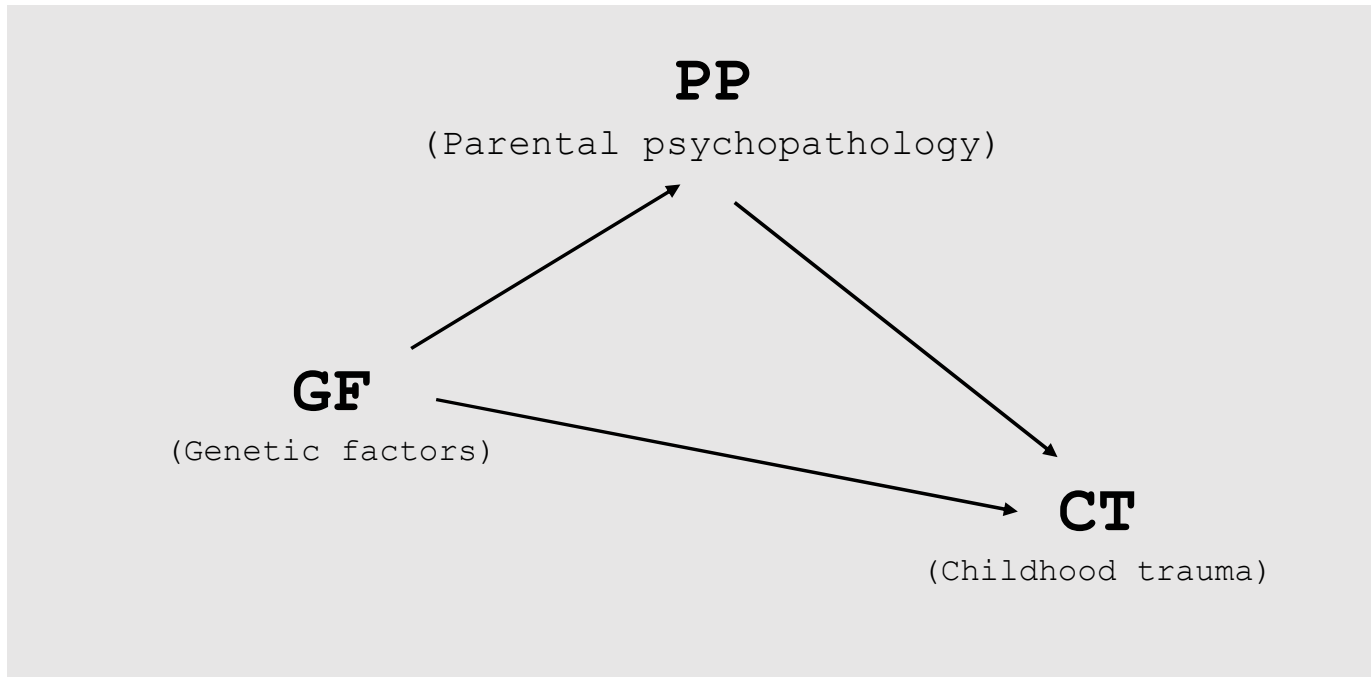
Running title: Causal comparisons in non-randomized studies

Die Visualisierung erzeugt sofort
Gedanken über die Richtigkeit des
Modells, nicht wahr?

Zusammenfassung von Variablen

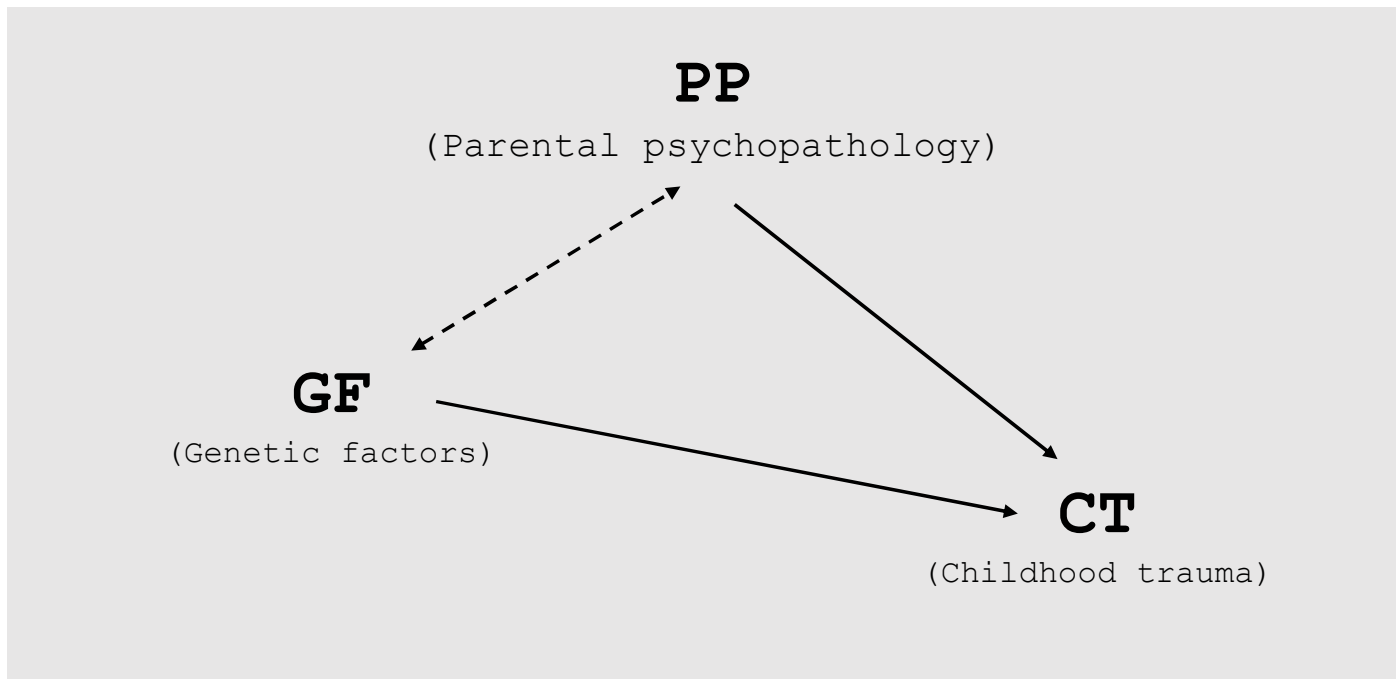
Möglich, falls sie **gleiche kausale Beziehungen** haben.

Beispiel: Mehrere genetische Faktoren (**GF**) beeinflussen **PP** und **CT**
(aber nicht notwendigerweise im gleichen Maße).




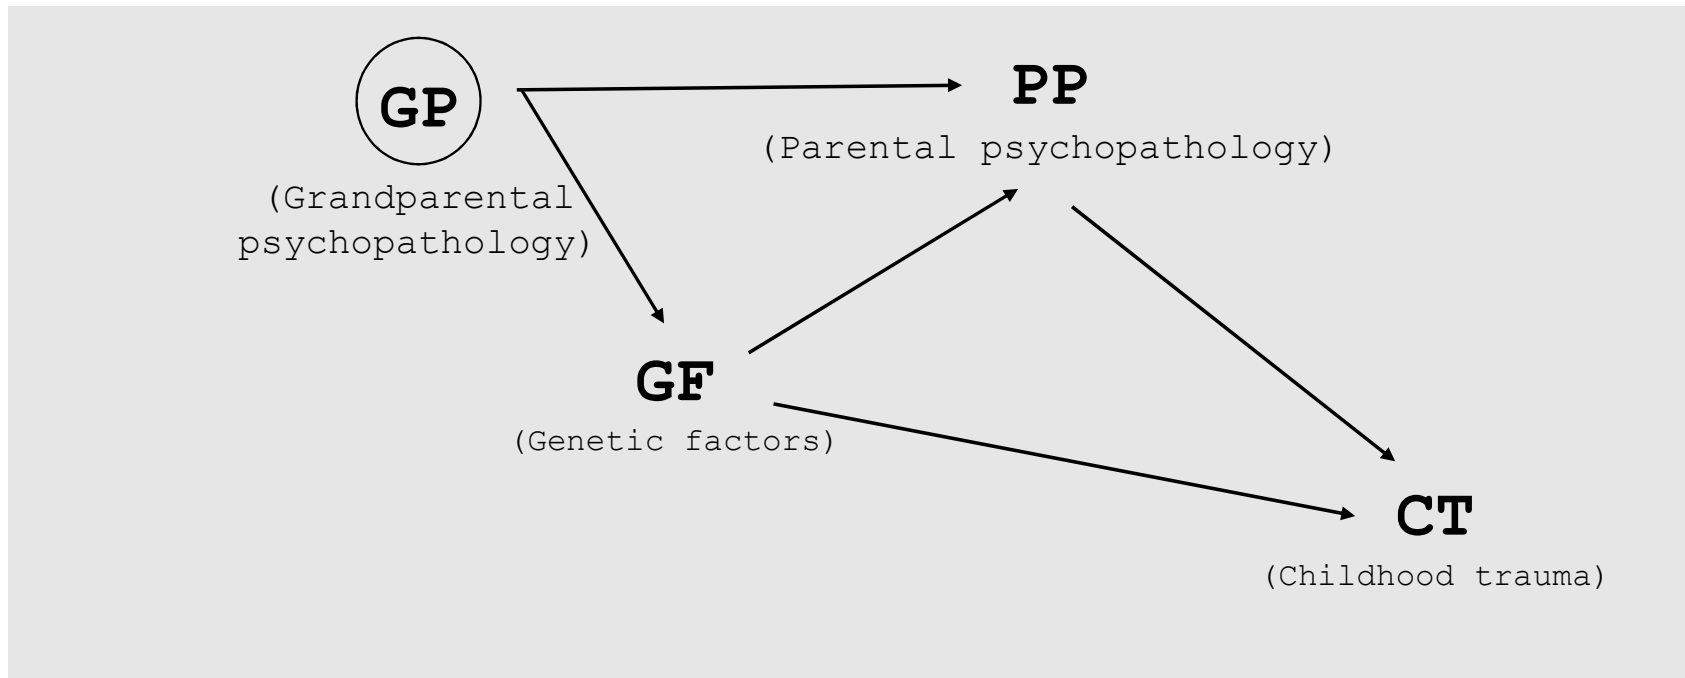
Zusammenhänge unbekannter Ursache

Alternativ könnte man annehmen, dass **GF** und **PP** nicht kausal zusammenhängen, aber assoziiert sind — aufgrund **unbekannter gemeinsamer Ursachen**. Dies drückt man mittels $\langle \text{---} \rangle$ aus.



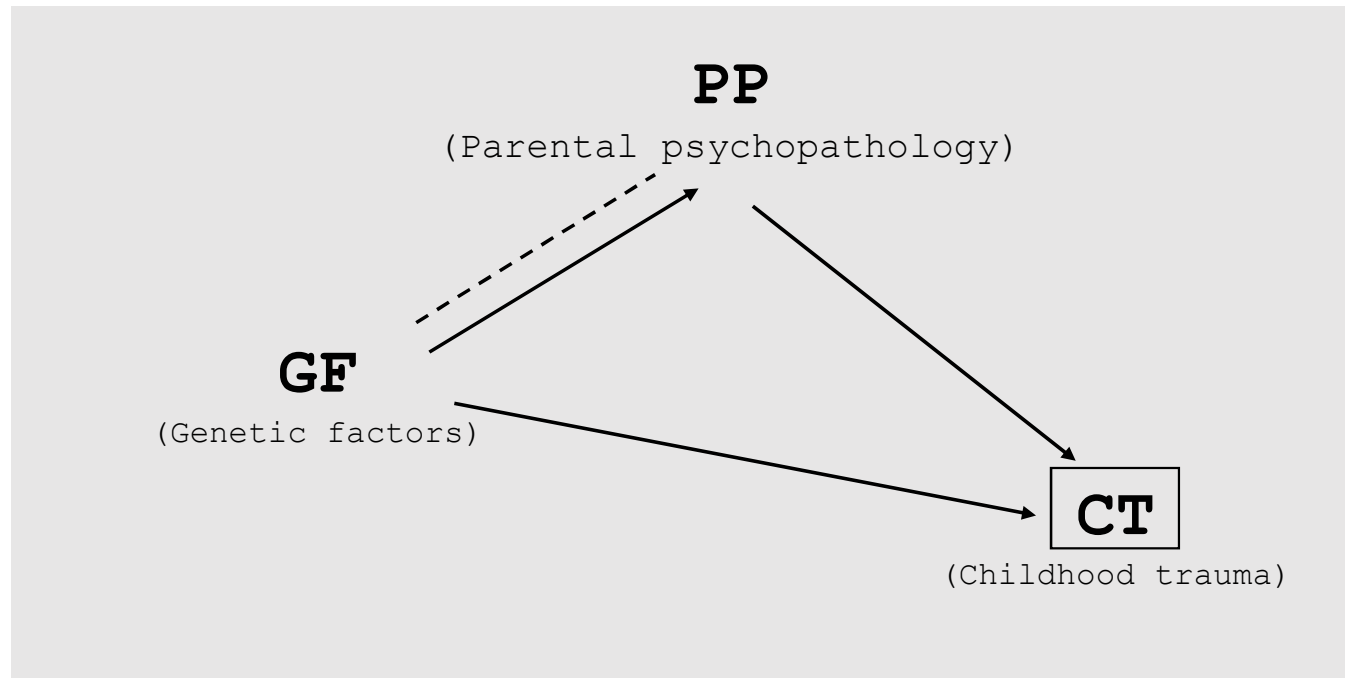
Latente Variablen

lassen sich mittels  darstellen. Zweck: Ist es problematisch, wenn man eine Variable nicht erheben kann/nicht erhoben hat?




Variablen, nach denen adjustiert wurde

Beispiel: nur Stichprobe traumatisierter Kinder gezogen (ist wie statistisches Adjustieren). Lässt sich mittels darstellen. Z.B. adjustieren nach gemeinsamer Folge zweier Variablen, erzeugt nichtkausalen Zusammenhang ----. „collider bias“, „Berkson's bias“.



Ist ein DAG empirisch überprüfbar?

Ja — insofern als er vorhersagt, welche Assoziationen man in Daten finden sollte und welche nicht → Modifikation des DAGs.



Vorhergesagt

$SE_1 - SE_2$


$RE_1 - SE_2$

Nicht vorhergesagt:


$SE_1 - RE_1$

Was lässt sich jetzt damit anfangen?
Z.B. die wichtige Frage beantworten, welche
gemeinsamen Ursachen man beachten muss

→ **Design:** diese erheben
(möglichst ohne Messfehler)



bookdepository.com



springer.com

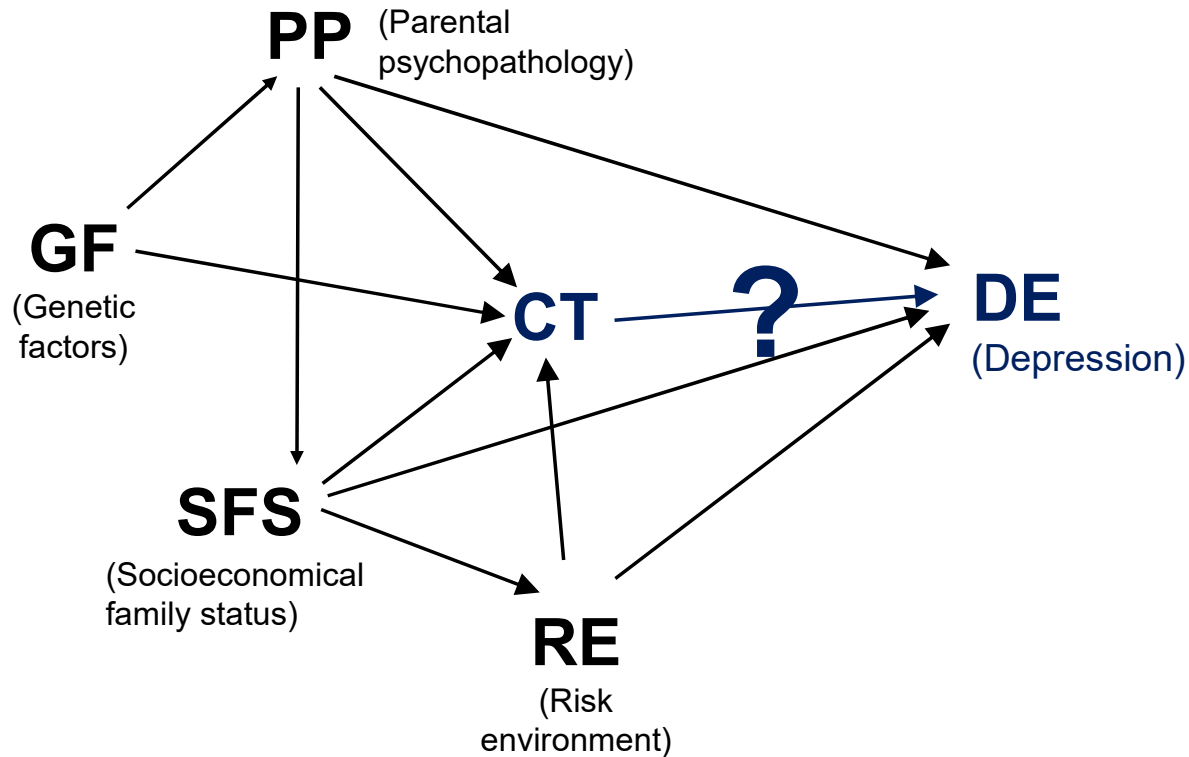
→ **Auswertung:** nach ihnen statistisch adjustieren, s.u.

Generelles Ziel: eliminiere alle nichtkausalen Anteile in der beobachteten x - y -Assoziation

Antwort durch das „backdoor criterion“

- Man muss **nicht alle** gemeinsamen Ursachen beachten
- Eine Auswahl solcher Variablen ist hinreichend, wenn sie alle „backdoor paths“ zwischen \mathbf{X} und \mathbf{Y} „blockiert“ = eliminiert
- = Pfade, die **nichtkausale Anteile** in einer Assoziation erzeugen
- Diese zeigen einerseits auf $\rightarrow \mathbf{X}$ (Einfluss auf \mathbf{x})
- und andererseits auf $\rightarrow \mathbf{Y}$
- dürfen außerdem keine „collider“ enthalten (weil dies keine Assoziation erzeugt, sondern im Gegenteil: erst das Adjustieren erzeugt eine nichtkausale Assoziation, s.u.)
- Bei einem backdoor path ist es egal, welche Variable man verwendet, um diesen zu blockieren. Im Beispiel $CT \leftarrow PP \leftarrow GF \rightarrow DE$ kann man PP nehmen oder GF nehmen (oder beide).

Im Beispiel für den Effekt $CT \rightarrow DE$




Hier gibt es die backdoor paths

- (1) $CT \leftarrow PP \rightarrow DE$
- (2) $CT \leftarrow PP \leftarrow GF \rightarrow DE$
- (3) $CT \leftarrow SFS \rightarrow DE$
- (4) $CT \leftarrow RE \rightarrow DE$
- (5) $CT \leftarrow SFS \rightarrow RE \rightarrow DE$
- (6) $CT \leftarrow PP \rightarrow SFS \rightarrow DE$
- (7) $CT \leftarrow PP \rightarrow SFS \rightarrow RE \rightarrow DE$

Es reicht, nach PP , SFS und RE zu adjustieren, weil diese Variablen alle nichtkausalen Pfade 1-7 "blockieren".

Man braucht GF nicht zu beachten, also keine (aufwendige) genetische Studie durchzuführen.

Adjustieren kann aber auch Bias erst erzeugen




Hier gibt es keinen backdoor path. Denn in $X \leftarrow U_1 \rightarrow Z \leftarrow U_2 \rightarrow Y$ ist Z ein **Collider**: Die gemeinsame Ursache, Z , von U_1 und U_2 erzeugt keine Assoziation zwischen U_1 und U_2 . Diese entsteht erst, wenn man nach Z adjustiert, und damit auch eine nichtkausale Assoziation zwischen X und Y .

Wegen der Form des graphs spricht man auch von “**M-Bias**”, “**overcontrol bias**”.


Causal Inference in the Presence of Causally Connected Units: A Semiparametric Hierarchical Structural Equation Model Approach

Thesis (PDF Available) · Aug 2017 · with 202 Reads · ©


„Fork“: Z ist **gemeinsame Ursache** von X und Y , es **muss** nach Z adjustiert werden.



„Inverted fork“: Z ist **gemeinsame Folge** („collider“) von X und Y , es **darf nicht** nach Z adjustiert werden.




Nicht nach **Mediatoren** adjustieren



Adjustieren nach Z würde hier einen Teil des interessierenden Effekts von X auf Y eliminieren.

Manches Adjustieren reduziert Bias nur („causal effect unidentified“)



Schätze Effekt von s auf w .

Adjustieren nach \bar{W} (anstatt nach U)
reduziert Bias nur – in dem Maße wie Q
kausale Folge von U ist → **quantitatives
Modell nötig.**

[Annu Rev Sociol](#). Author manuscript; available in PMC 2018 Aug 13.

PMCID: PMC6089543

Published in final edited form as:

NIHMSID: NIHMS979472

[Annu Rev Sociol](#). 2014 Jul; 40: 31–53.


PMID: 30111904

Published online 2014 Jun 2. doi: [10.1146/annurev-soc-071913-043455](#)

Endogenous Selection Bias: The Problem of Conditioning on a Collider Variable

Felix Elwert¹ and Christopher Winship²

Manchmal ist unklar, ob Adjustieren Bias reduziert oder erhöht



Schätze Effekt von s auf w .

Adjustieren nach Q würde auch hier Bias durch die gemeinsame Ursache U **verringern**. Gleichzeitig entstünde aber eine **nichtkausale, zusätzliche Assoziation** zwischen U und S (----) und damit overadjustment bias

→ **quantitatives Modell nötig.**

[Annu Rev Sociol](#). Author manuscript; available in PMC 2018 Aug 13.

PMCID: PMC6089543

Published in final edited form as:

NIHMSID: NIHMS979472

[Annu Rev Sociol](#). 2014 Jul; 40: 31–53.

PMID: 30111904


Published online 2014 Jun 2. doi: [10.1146/annurev-soc-071913-043455](https://doi.org/10.1146/annurev-soc-071913-043455)

Endogenous Selection Bias: The Problem of Conditioning on a Collider Variable

[Felix Elwert](#)¹ and [Christopher Winship](#)²

Mehr Beispiele: [A crash course in good and bad control](#)

Es gibt sogar **drei Möglichkeiten**, einen Effekt basierend auf einem DAG zu schätzen:



Falls dieses Modell zutrifft, ist Effekt von **D** auf **Y** schätzbar durch:

1. **Adjustieren** nach **F** oder (**A** und **B**)
2. **“instrumental variables“**, $C \rightarrow D \rightarrow Y$ (Effekte $c \rightarrow Y$ und $D \rightarrow Y$ haben keine gemeinsamen Ursachen); siehe unten
3. **“mechanism-based“**: Effekt von **D** auf **Y** in die indirekten Effekte
 $D \rightarrow M \rightarrow Y$ und
 $D \rightarrow N \rightarrow Y$
zerlegen („frontdoor criterion“) ...

Quantitative Methoden im Anschluss


(nach Auswahl von **z**-Variablen adjustieren)

Bei **Between-Designs** (Gruppenvergleichen):

- **Regressionsmethoden:** Modell für \mathbf{y} mit Prädiktoren \mathbf{x} und den ausgewählten **z**-Variablen. Am einfachsten, aber am größten
- **Propensity-Score-Verfahren:** Modell für $P(\mathbf{x} = 1 \mid \mathbf{z}) = \text{propensity score}$, adjustiere danach („mache \mathbf{x} von \mathbf{z} unabhängig“).
- **Statistisches Matching** – oder Gewichtungsmethoden, die auf Prop.-Score basieren
- **Doubly robust estimation:**
 1. best. Modell 1. zur Vorhersage von \mathbf{y} („mache \mathbf{y} von \mathbf{z} unabhängig“),
 2. Modell für Propensity Score.Es genügt, wenn Modell 1. oder 2. stimmt (2 Chancen für richtiges Modell, das eine Modell ist jeweils robust gegenüber einem falschen anderen Modell, „doubly robust“)

Bei Within-Designs:

Kapitel 11 in:




Wofür man DAGs noch benutzen kann

(nichtspezifische Probleme der kausalen Inferenz, auch relevant für Assoziationen)

A. Externe Validität = Selektionsbias = „transportability“

Wann ist ein Selektionsprozess, Variable s , problematisch bei der Schätzung eines Effekts? (nur in D kann man Effekt nicht schätzen)



Selection diagrams depicting differences between source and target populations. In A, the two populations differ in age (Z) distributions (so S points to Z). In B, the populations differ in how reading skills (Z) depend on age (an unmeasured variable, represented by the open circle) and the age distributions are the same. In C, the populations differ in how Z depends on X . In D, the unmeasured confounder (bidirected arrow) between Z and Y precludes transportability.

Löst sogar das allgemeinere „**data fusion problem**“: Kann man die Ergebnisse aus k verschiedenen Studien (mit evtl. untersch. kausalen Effekten) kombinieren, um den Effekt in einer Zielpopulation ohne Bias zu schätzen?

PNAS Proceedings of the National Academy of Sciences of the United States of America

Home Articles Front Matter News Podcasts Authors

NEW RESEARCH IN Physical Sciences Social Sciences

COLLOQUIUM PAPER

Causal inference and the data-fusion problem

Elias Bareinboim and Judea Pearl

PNAS July 5, 2016 113 (27) 7345-7352; first published July 5, 2016 <https://doi.org/10.1073/pnas.1510507113>

[Annu. Rev. Sociol.](#) Author manuscript, available in PMC 2018 Aug 13. PMID: PMC6089543
Published in final edited form as:
[Annu. Rev. Sociol.](#) 2014 Jul; 40: 31-53. NIHMSID: NIHMS979472
Published online 2014 Jun 2. doi: [10.1146/annurev-soc-071913-043455](https://doi.org/10.1146/annurev-soc-071913-043455) PMID: 30111904

Endogenous Selection Bias: The Problem of Conditioning on a Collider Variable

Felix Elwert¹ and Christopher Winship²

B. Messfehler

INVITED COMMENTARY

Invited Commentary: Causal Diagrams and Measurement Bias FREE


Miguel A. Hernán, Stephen R. Cole

American Journal of Epidemiology, Volume 170, Issue 8, 15 October 2009, Pages 959–962,

<https://doi.org/10.1093/aje/kwp293>

Published: 15 September 2009 **Article history** ▾

Figure 2.



Y^* : fehlerhafte Messung von Y

C. Non-compliance

Emerg Themes Epidemiol. 2018; 15: 1.

PMCID: PMC5776781

Published online 2018 Jan 22. doi: [10.1186/s12982-018-0069-7](https://doi.org/10.1186/s12982-018-0069-7)


PMID: [29387137](https://pubmed.ncbi.nlm.nih.gov/29387137/)

An introduction to instrumental variable assumptions, validation and estimation


[Mette Lise Lousdal](#)

[Author information](#) [Article notes](#) [Copyright and License information](#) [Disclaimer](#)

Kapitel 9 in:



1. The *relevance* assumption: The instrument Z has a causal effect on X .
2. The *exclusion* restriction: Z affects the outcome Y only through X .
3. The *exchangeability* assumption: Z does not share common causes with the outcome Y [19]. This assumption has also been termed the *independence* assumption [15, 18], *ignorable treatment assignment* [14], or described as *no confounding for the effect of Z on Y* [16].




z : beabsichtigte Intervention

x : tatsächliche Intervention (mit Non-Compliance behaftet)

Grundidee von „Instrumental variables“:
Der konfundierte Effekt von x auf y kann aus den unkonfundierten $z \rightarrow x$ und $z \rightarrow y$ bestimmt werden.

D. Fehlende Werte




Structural Equation Modeling: A Multidisciplinary Journal

ISSN: 1070-5511 (Print) 1532-8007 (Online) Journal homepage: <http://www.tandfonline.com/loi/hsem20>

Graphical Representation of Missing Data Problems

Felix Thoemmes & Karthika Mohan



Y^* : kodiert, ob Y -Wert fehlt

FIGURE 2 A simple missing at random model (a) without auxiliary variables and (b) with auxiliary variables.

6. Diskussion

- Kausale Fragestellungen können nicht vermieden werden
- Die Methode der DAGs zwingt Wissenschaftlerinnen zur Modellbildung
- ... weil (kausales) Schließen davon abhängt
- Ein DAG dokumentiert sich selbst
- Rezipientin ist eingeladen, ein Modell zu modifizieren
- → Diskurs über Annahmen

6. Diskussion

- Bei **mehreren plausiblen Modellen**: → jede entsprechende quantitative Analyse durchführen.
- **Sensitivitätsanalyse**: Hängt Ergebnis von Modellwahl ab?
- Falls ja, sieht man welches Modell zu welchem Schluss führt

- Limitation: Manchmal benötigt man ein **quantitatives Modell**, um zu entscheiden, wonach man adjustiert

Kritik an DAGs, u.a.:

- benutzen viel zu simple Modelle
- Dies ist jedoch nur eine Kritik ihrer Anwendung
- Die Methode funktioniert, egal wie komplex ein Modell ist
(Aussagen wie backdoor criterion gelten immer)

Generell gilt:

- Keine Methode ist vollständig
- Jede hat ihre Grenzen
- Keine kann alles

[Eur J Epidemiol](#). 2017 Jan;32(1):3-20. doi: 10.1007/s10654-017-0230-6. Epub 2017 Feb 20.

For and Against Methodologies: Some Perspectives on Recent Causal and Statistical Inference Debates.

[Greenland S](#)¹.