

Auswahl und Kontrolle von Drittvariablen bei der Bestimmung kausaler Zusammenhänge - illustriert mit Directed Acyclic Graphs (DAGs)

Hillmert, Steffen

Erstveröffentlichung / Primary Publication

Arbeitspapier / working paper

Empfohlene Zitierung / Suggested Citation:

Hillmert, S. (2019). *Auswahl und Kontrolle von Drittvariablen bei der Bestimmung kausaler Zusammenhänge - illustriert mit Directed Acyclic Graphs (DAGs)*. Tübingen. <https://doi.org/10.13140/RG.2.2.17802.82882/3>

Nutzungsbedingungen:

Dieser Text wird unter einer CC BY-SA Lizenz (Namensnennung-Weitergabe unter gleichen Bedingungen) zur Verfügung gestellt. Nähere Auskünfte zu den CC-Lizenzen finden Sie hier: <https://creativecommons.org/licenses/by-sa/4.0/deed.de>


Terms of use:

This document is made available under a CC BY-SA Licence (Attribution-ShareAlike). For more information see: <https://creativecommons.org/licenses/by-sa/4.0>



Auswahl und Kontrolle von Drittvariablen bei der Bestimmung kausaler Zusammenhänge – illustriert mit *Directed Acyclic Graphs* (DAGs)

Steffen Hillmert



2019

DOI: 10.13140/RG.2.2.17802.82882/3



Zusammenfassung:

Von einem korrelativen Zusammenhang zwischen zwei Variablen kann man nicht unmittelbar auf einen ursächlichen (kausalen) Zusammenhang zwischen ihnen schließen. Dieses Wissen hat sich in der Wissenschaft und inzwischen vermehrt auch im Alltag etabliert. Neben dem Problem der zeitlichen Abfolge von Ursache und Wirkung geht es hierbei insbesondere um das Problem von Drittvariablen. Die typische Strategie in der (nicht-experimentellen) Kausalanalyse besteht darin, diese in geeigneter Form zu „kontrollieren“, um den interessierenden Zusammenhang zu bestimmen. Allerdings bleibt häufig unklar, welche (zusätzlichen) Variablen genau zu kontrollieren sind und warum.

Ein sehr intuitives und anwendungsfreundliches Hilfsmittel gerade zur Unterstützung einer entsprechenden inhaltlichen Diskussion stellt die grafische Illustration kausaler Verhältnisse dar. Neben den häufig verwendeten (Adhoc-)Varianten gibt es inzwischen auch stärker formalisierte Konzepte. In jüngerer Zeit bekannt geworden sind insbesondere sogenannte *Directed Acyclic Graphs* (kurz DAGs) als grafische Repräsentationen kausaler Beziehungsgeflechte. Mit ihrer Hilfe lässt sich oft relativ einfach ablesen, welche Zusammenhänge im konkreten Anwendungsfall (auch indirekt) angenommen werden und welche Variablen demzufolge in der Datenanalyse zu berücksichtigen sind. Trotz ihrer Eingängigkeit haben solche grafischen Verfahren allerdings in der Praxis, zumindest im deutschen Sprachraum, nach wie vor eine vergleichsweise geringe Verbreitung, insbesondere jenseits des Fachgebiets der statistischen Kausalanalyse.

Diese Einführung zeigt exemplarisch die praktische Anwendung einer grafischen Darstellung von Kausalbeziehungen mittels DAGs. Der Schwerpunkt liegt dabei auf der Frage der korrekten Auswahl von Untersuchungsvariablen. Insbesondere wird dabei auch deutlich, dass nicht nur notwendige Kontrollen unterbleiben, sondern häufig auch „zu viele“ Variablen kontrolliert werden. Außerdem lassen sich damit die den unterschiedlichen Verfahren der Kausalanalyse zugrunde liegenden Strategien einfach veranschaulichen.

Schlüsselwörter:

Kausalanalyse; Directed Acyclic Graphs; DAGs; Variablenauswahl; grafische Veranschaulichung; Verfahrenswahl; confounder; collider; bias; bad control; overcontrol

Literaturangabe:

**Hillmert, Steffen (2019): Auswahl und Kontrolle von Drittvariablen bei der Bestimmung kausaler Zusammenhänge – illustriert mit *Directed Acyclic Graphs* (DAGs). Universität Tübingen: Institut für Soziologie.
DOI: 10.13140/RG.2.2.17802.82882/3**

Eine frühere Version wurde präsentiert auf der Herbsttagung der Sektion Modellbildung und Simulation der Deutschen Gesellschaft für Soziologie an der Technischen Universität Kaiserslautern im Oktober 2017.

Kontakt:

Prof. Dr. Steffen Hillmert
Universität Tübingen
Institut für Soziologie
Wilhelmstr. 36
72074 Tübingen
E-Mail: steffen.hillmert@uni-tuebingen.de

1. Einleitung und Überblick

Die Vorstellung von Ursache und Wirkung ist ein wesentlicher Aspekt modernen Denkens und damit auch in der Wissenschaft zentral. Es verwundert daher nicht, dass Probleme der Beschreibung und Identifikation kausaler Zusammenhänge in der Wissenschaft weit verbreitet sind. Sie sind somit keineswegs ein randständiges Phänomen, das sich auf ein Gebiet der expliziten „Kausalanalyse“ beschränken ließe, insbesondere auch nicht auf ein statistisches Spezialgebiet, sondern sie betreffen bereits die Struktur theoretischer Argumente.

Selbstverständlich sind nicht alle Fragen, die die Wissenschaft interessieren, Kausalfragen. Sie haben aber eine herausgehobene Position. Selbst bei der Diskussion von Themen im Alltag stößt man i.d.R. über kurz oder lang auf kausal orientierte Interessen, die sich auf die Zurechenbarkeit zu möglichen Ursachen beziehen. Dabei ist allerdings Alltagssprache bisweilen so unpräzise, dass die kausale Orientierung aus entsprechenden Formulierungen erst herausgelesen werden muss. So mag man sich beispielsweise dafür interessieren, ob eine bestimmte Krankheit „lediglich“ typischerweise im Zusammenhang mit dem Genuss eines bestimmten Lebensmittels auftritt oder ob dieses (bzw. eine seiner Eigenschaften) die Krankheit tatsächlich „auslöst“. Ist eine bestimmte Bevölkerungsgruppe in der Kriminalstatistik „nur“ überrepräsentiert oder verhalten sich Angehörige dieser Gruppe „wirklich“ häufiger kriminell? Solche Fragen lassen sich zumindest in Teilen als Kausalfragen interpretieren.¹

Systematische Probleme in solchen Diskussionen zeigen sich etwa darin, dass genaue Argumentationsketten häufig implizit bleiben und Widersprüche in der Gesamtargumentation nicht erkannt werden. Die zentrale Frage in der kausal orientierten empirischen Datenanalyse ist die nach der Identifizierbarkeit kausaler Zusammenhänge auf Basis empirischer Zusammenhänge. Schwierigkeiten, die sich dort stellen, betreffen insbesondere die richtige Auswahl von (Kontroll-)Variablen in Regressionsanalysen und anderen Modellen der Kausalanalyse. Allerdings bleibt die Diskussion solcher Probleme häufig entweder theoretisch-abstrakt oder methodisch-technisch.

Fragen der korrekten Modellspezifikation sind auch ein Dauerthema in der universitären Lehre. Die Frage nach der Verfügbarkeit anschaulicher Techniken der Variablenauswahl ist daher gerade auch unter didaktischen Gesichtspunkten relevant. Zudem taucht hier häufig die Frage auf, inwiefern Verfahren der Kausalanalyse (nicht nur in formal-statistischer Hinsicht) zusammenhängen bzw. sich unterscheiden.

Ein sehr intuitives und anwendungsfreundliches Hilfsmittel gerade zur Unterstützung einer inhaltlichen Diskussion stellt die grafische Illustration kausaler Verhältnisse dar. Neben den häufig verwendeten (Adhoc-)Varianten gibt es inzwischen auch stärker formalisierte Konzepte. In jüngerer Zeit bekannt geworden sind insbesondere sogenannte *Directed Acyclic Graphs* (kurz DAGs) als grafische Repräsentationen kausaler Beziehungsgeflechte (Pearl 2000). Mit ihrer Hilfe lässt sich oft relativ einfach ablesen, welche Zusammenhänge im konkreten Anwendungsfall (auch indirekt) angenommen werden und welche Variablen demzufolge in der Datenanalyse zu berücksichtigen sind und welche nicht. Insofern erleichtern sie sowohl die Klärung theoretischer Argumente als auch die notwendige Verbindung von Theorie und Empirie. Trotz ihrer Eingängigkeit haben sie allerdings in der

¹ „Kausalität“ ist im Übrigen nicht zu verwechseln mit Attributen wie „natürlich“ oder „schon immer“. In den Sozialwissenschaften handelt es sich bei Kausalfaktoren ja oft um soziale Tatsachen. Diese weisen typischerweise internationale oder regionale Variation auf, und sie unterliegen zumindest langfristig auch sozialem Wandel. Das schließt aber nicht aus, dass sie unter gegebenen Rahmenbedingungen klar zurechenbare, in ihrer Größenordnung benennbare und häufig auch für den Einzelnen existentielle Folgen haben können.

Praxis nach wie vor eine vergleichsweise geringe Verbreitung, insbesondere jenseits des Fachgebiets der statistischen Kausalanalyse. Dies gilt zumindest für den deutschen Sprachraum, was wohl auch daran liegt, dass Einführungsliteratur inzwischen zwar breit verfügbar, aber i.d.R. englischsprachig ist (vgl. etwa Elwert 2013; Pearl et al. 2016; Shalizi 2017; zum Hintergrund der Kausalanalyse siehe auch Pearl & Mackenzie 2018). Selbstverständlich ist deren Lektüre dennoch sehr zu empfehlen!

Die vorliegende Einführung zeigt exemplarisch praktische Anwendungen einer grafischen Veranschaulichung von Kausalbeziehungen mittels DAGs. Der Schwerpunkt liegt dabei auf Fragen der korrekten Auswahl von Untersuchungsvariablen. Insbesondere wird dabei deutlich, dass oft nicht nur notwendige Kontrollen unterbleiben, sondern häufig auch „zu viele“ Variablen kontrolliert werden. Außerdem lassen sich mit den entsprechenden Grafiken die den unterschiedlichen Verfahren der Kausalanalyse zugrunde liegenden Strategien einfach veranschaulichen. Grafische Darstellungen in der hier vorgestellten Form sind nicht unbedingt neu, aber ein sehr anschauliches und flexibles Hilfsmittel.

2. Grundprobleme der Kausalanalyse

Kausalität im Sinne von Ursache-Wirkungs-Zusammenhängen ist nicht direkt beobachtbar. Man kann nur aus beobachteten Zusammenhängen darauf schließen. In der Wissenschaft, und inzwischen vermehrt auch im Alltag, hat sich aber auch das Wissen etabliert, dass man von einem korrelativen Zusammenhang zwischen zwei Variablen nicht unmittelbar auf einen ursächlichen (kausalen) Zusammenhang schließen kann. Neben dem Problem der zeitlichen Abfolge von Ursache und Wirkung geht es hierbei insbesondere um den möglichen Einfluss von Drittvariablen.

Ein klassisches einschlägiges Beispiel ist das von Störchen und Kindern (vgl. etwa Diekmann 2005, S. 58): Vergleicht man Regionen untereinander, so stellt man (zumindest traditionell) fest, dass in Gebieten, in denen mehr Störche leben, auch relativ häufiger Kinder geboren werden. Es gibt also einen deskriptiven Zusammenhang zwischen den Variablen Storchendichte und Geburtenrate. Trotzdem glaubt man wohl nicht an einen direkten, kausalen Zusammenhang zwischen den beiden Variablen, etwa in dem Sinne, dass die Störche die Kinder bringen (oder vielleicht umgekehrt?). Vielmehr wird man schnell an Drittvariablen denken (etwa den Urbanisierungsgrad der Region), welche sowohl mit der Storchendichte als auch der Geburtenrate zusammenhängen und damit einen statistischen Zusammenhang zwischen den beiden Variablen produzieren. Man spricht in diesem Zusammenhang auch von „Scheinkausalität“.²

In der Regel liegen die Dinge aber nicht so klar wie in diesem Beispiel. Häufig ist es nicht einmal klar, ob Drittvariablen im konkreten Fall überhaupt nennenswerte Relevanz haben und welche Faktoren dies betrifft. Es verwundert daher nicht, dass sich wissenschaftliche Diskussionen und Kontroversen häufig um die Frage drehen, inwieweit ein gemessener Zusammenhang einen Kausalzusammenhang repräsentiert oder nicht doch auf nicht beachtete Drittvariablen („fehlende Variablen“) zurückgeht.

Während man in der experimentellen Forschung Drittvariableneffekte per Untersuchungsdesign auszuschließen versucht (etwa durch randomisierte Gruppenzuweisung), stellen sich in der empirischen Sozialforschung wiederholt Probleme der Identifizierung bzw. Messung von Kausaleffekten mit Beobachtungsdaten. Die typische Strategie der (nicht-experimentellen) Kausalanalyse besteht darin, die Drittvariablen in geeigneter Form zu „kontrollieren“. Die statistische Berücksichtigung von „Kontrollvariablen“ ist inzwischen Routine und mit der verfügbaren Statistiksoftware auch gut möglich. In der Praxis bleibt

² Noch häufiger ist von „Scheinkorrelation“ die Rede. Dies ist allerdings zumindest sehr missverständlich, denn die statistische Korrelation gibt es ja wirklich, nur eben die direkte Kausalität nicht.

allerdings die (theoretische) Begründung der Auswahl dieser Kontrollvariablen, also die Frage, welche Variablen kontrolliert werden sollen und warum, oft spärlich. Bisweilen liest man bei der Beschreibung multivariater Modelltabellen sogar Formulierungen wie „...außerdem wurden 20 weitere [nicht näher bezeichnete] Kovariablen kontrolliert...“. Der Verzicht auf eine explizite Nennung lässt die Frage nach dem Umfang und der genauen Zusammensetzung der Menge der Kovariablen unproblematisch erscheinen. Insbesondere scheint es so, als sei das Risiko, eventuell *zu viele* oder „falsche“ Variablen zu kontrollieren, zu vernachlässigen. Hierfür gibt es aber zahlreiche Gegenbeispiele (s.u.), d.h. man kann durchaus auch „zu viel“ kontrollieren!

Die sinnvolle Auswahl von Kovariablen stellt somit ein verbreitetes systematisches Problem in der Forschungspraxis dar, auch jenseits der üblichen praktischen, datentechnischen Beschränkungen, dass empirische Daten oft unvollständig sind und wichtige Faktoren nicht gemessen wurden. Welche Variablen sollten kontrolliert werden? Und welche nicht?

Die konkreten Antworten auf diese Fragen sind natürlich themenspezifisch. Wie sich aber bereits am oben zitierten Storchenbeispiel zeigen lässt, besteht das Hauptproblem typischerweise in bestimmten *strukturellen* Konfigurationen von Einflussfaktoren. Es scheint daher angebracht, kausaltheoretische Überlegungen zunächst unabhängig von faktisch vorliegenden Daten bzw. *vor* der eigentlichen Messung anzustellen. Dabei geht es nicht nur um den unmittelbar interessierenden Zusammenhang, sondern auch mittelbar beteiligte kausale Einflüsse. Es wäre gut, hierfür ein einfaches Hilfsmittel für die Entscheidung für oder gegen bestimmte Kovariablen zur Hand zu haben. Dabei geht es um Überlegungen über die zugrundeliegenden Kausalverhältnisse bzw. die prinzipielle Messbarkeit von Effekten einzelner Variablen. Erst auf dieser Basis wird dann begründet über Verfahren entschieden, und es werden konkrete Messmodelle spezifiziert. Das Ergebnis der Überlegungen kann dabei durchaus sein, dass – zumindest mit den vorliegenden Daten – eine Messung des interessierenden Kausaleffekts nicht möglich ist. Auch dies wäre dann aber eine wichtige Erkenntnis!

3. Grafische Repräsentationen

In der Praxis haben sich für solche theoretischen (Vor-)Überlegungen einfache grafische Darstellungen als hilfreich erwiesen. Kausalverhältnisse werden ja häufig auch im Alltag in Form von Pfeildiagrammen dargestellt, und vielen sind sie als Abbildungen von Ursache-Wirkungs-Zusammenhängen intuitiv verständlich.

Stärker formalisierte Konzepte zur Veranschaulichung von Kausalbeziehungen, wie sie in den letzten Jahren u.a. von Spirtes et al. (1993) und Pearl (2000) systematisiert dargestellt wurden, gehen aber noch deutlich darüber hinaus, indem sie etwa – auf Basis der mathematischen Graphentheorie – beweisbare Regeln über jeweils mögliche Schlussfolgerungen formulieren. Grafische Veranschaulichungen können damit nicht nur zur Klärung theoretischer Gedanken dienen, sondern auch Fragen nach der Möglichkeit der Identifikation kausaler Effekte mittels empirischer Beobachtungen beantworten helfen.

3.1 Directed Acyclic Graphs (DAGs)

Pearl (2000) verwendet das Konzept der *Directed Acyclic Graphs* (DAGs) zur Veranschaulichung von Kausalbeziehungen. DAGs können als nonparametrische Verallgemeinerung von (ansonsten linearen) Strukturgleichungsmodellen aufgefasst werden (Jo 2008). Graphen bestehen aus Variablen (als „Knotenpunkten“) und paarweisen Verbindungen (als „Kanten“) zwischen ihnen. Ein *Pfad* beschreibt dabei die kontinuierliche Folge der Verbindungen, mit denen man schrittweise von einem Knotenpunkt (einer Variable) zu einem anderen Knotenpunkt (einer anderen Variable) gelangt. Die Graphen

müssen bestimmte Eigenschaften haben, um die jeweiligen kausalen Schlussfolgerungen zu ermöglichen: *Directed* verweist dabei darauf, dass sich die Abbildungen aus gerichteten, einseitigen Kausalbeziehungen (repräsentiert durch einseitige Pfeile) zusammensetzen, die von der Ursache zur Wirkung laufen. *Acyclic* bedeutet, dass keine zirkulären Konfigurationen erlaubt sind, dass also nicht gerichtete Pfade, welche bei einer Variable beginnen, dann – auch ggf. über mehrere medierende Variablen – wieder auf die Ausgangsvariable zurückführen.³

Die Grundidee ist, dass die Darstellung *vollständig* ist, also alle relevanten Kausalbeziehungen (insbesondere bezüglich gemeinsamer Ursachen) dargestellt sind. Dies bedeutet umgekehrt, dass dort, wo keine Beziehungen eingezeichnet sind, auch keine kausalen Beziehungen angenommen werden. Vor allem aber handelt es sich um „theoretische“ Modelle über als „wahr“ angenommene Kausalverhältnisse, nicht einfach nur Zusammenstellungen deskriptiv vorgefundener Zusammenhänge oder um konkrete empirische Messmodelle. Grundlage hierfür können jeweils überzeugende theoretische Überlegungen sein oder auch kausale Erkenntnisse, die bereits als „gesichert“ gelten können, insbesondere wenn sie mittels eines Experiments gewonnen wurden. Zudem kann oft das Vorliegen von Zusammenhängen zwischen weiteren (beobachteten) Variablen überprüft werden. Ziel ist es, eine Vorstellung von den „wahren“ Kausalverhältnissen zu bekommen, um dann entscheiden zu können, inwieweit die verfügbaren Daten Rückschlüsse auf bestimmte Zusammenhänge erlauben. Die grafische Darstellung erleichtert es, die potenzielle Identifizierbarkeit von Effekten zu beurteilen und geeignete Variablen auszuwählen. Inzwischen gibt es auch einschlägige Software (z.B. *DAGitty*: vgl. <http://www.dagitty.net>). Im Folgenden wird aus Gründen der Vereinfachung auf die Diskussion besonderer grafischer Elemente verzichtet.

In Abbildung 1 sind gerichtete Kausalbeziehungen als Pfeile dargestellt. Ziel sei es, den Kausaleffekt einer Variablen auf eine abhängige Variable Y zu bestimmen. In Anlehnung an kausale Experimente, in denen Probanden kontrolliert selektiv „behandelt“ werden, wird die zentrale unabhängige Variable in der Kausalanalyse gerne auch „Treatmentvariable“ (hier entsprechend mit T bezeichnet) genannt. In Abbildung 1a) steht der interessierende Zusammenhang nicht in Verbindung mit anderen Variablen. In diesem Fall würde also der einfache empirische Zusammenhang den kausalen Effekt beschreiben. Abbildung 1b) zeigt eine einfache Abwandlung: Hier erfolgt der Effekt von T auf Y über unterschiedliche Wege, da es auch eine intervenierende Variable bzw. eine sogenannte „Mediatorvariable“ (hier mit V bezeichnet) gibt. Es wird also zumindest ein Teil des Effekts über V vermittelt („mediert“). Man kann sich solche Pfade auch als „Flüsse“ von Information vorstellen: Dann fließt nicht die (gesamte) Information zwischen T und Y direkt, und der empirische Blick allein auf den Zusammenhang T und Y liefert ein verzerrtes Bild. Die Kontrolle von Variablen auf einzelnen solchen Pfaden kann interessant sein, um – im Rahmen einer sogenannten Mediationsanalyse – unterschiedliche Wege und direkte und indirekte Pfade zu unterscheiden. Dies ist eher eine Frage des jeweiligen Erkenntnisinteresses. Eine Kontrolle der intervenierenden Variablen ist aber nicht nötig (und auch nicht sinnvoll), um den *Gesamteffekt* der Bildung korrekt zu bestimmen. Dieser wird hier weiterhin durch den Zusammenhang von T und Y wiedergegeben. In diesem Kontext wird auch von einem möglichen „overcontrol bias“ (Elwert & Winship 2014) durch unnötige Kontrollvariablen gesprochen.

Abbildung 1c) illustriert das im vorangegangenen Abschnitt angesprochene Problem der Hintergrundvariablen. Ein Problem kann dabei eben sein, dass es eine gemeinsame Ursache Z von sowohl T als auch Y gibt (Konfundierung; „Z wird auch als „confounder“ bezeichnet). Natürlich kann es auch weitere solche gemeinsamen Ursachen geben (hier exemplarisch mit Z' bezeichnet), und die kausalen Konfigurationen können durchaus komplexer sein und über mehrere Stationen laufen (s.a. die Beispiele unten).


³ Dies schließt Schleifen bzw. Schlingen ein, bei denen Kanten einen Knotenpunkt mit sich selbst verbinden.

Abbildung 1: Grafische Darstellung von Kausaleffekten


a) Interessierender Kausaleffekt



b) Direkter und indirekter Effekt



c) Kausaleffekt und mögliche(r) Hintergrundpfad(e)



Drittvariablen wie Z oder Z' im vorliegenden Beispiel verweisen auf sogenannte *Hintergrundpfade* zwischen T und Y, welche die Bestimmung des wahren Effekts von T auf Y verhindern können. Dabei muss es nicht so wie im obigen Storchenspiel sein, dass ein komplett falscher Kausalzusammenhang vorgespiegelt wird, wo es eigentlich keinen gibt. Es kann auch sein, dass die Messung eines zwischen T und Y tatsächlich existierenden Kausaleffekts dadurch *verzerrt* wird. So kann dieser auf Basis des einfachen empirischen Zusammenhangs aufgrund gegenläufiger Einflüsse im Hintergrund unterschätzt oder aufgrund gleichläufiger Einflüsse im Hintergrund überschätzt werden.

Wie geht nun die Kausalanalyse mit dem Problem der Hintergrundpfade um, und unter welchen Umständen ist dennoch eine Bestimmung des interessierenden Kausaleffekts möglich?

3.2. Strategien von „Back door“ und „Front door“

Vor diesem Hintergrund formuliert Pearl (2000) zwei fundamentale Strategien zur Identifizierung kausaler Effekte, die sich danach unterscheiden, ob man versucht, diese direkt zu messen oder dadurch, dass man mögliche Alternativen ausschließt. Letztere Strategie bedeutet, dass man quasi „keine Hintertür offenlässt“, deshalb wird auch gerne vom sogenannten „Back door“-Kriterium (Pearl 2000: 79) gesprochen. Der direkte Weg, gleichsam durch die „Vordertür“, wird auch als „Front door“-Kriterium (Pearl 2000: 81) bezeichnet. Zu den Identifikationsstrategien kann man auch die Strategie instrumenteller Variablen zählen (vgl. Morgan & Winship 2007: 26); vgl. auch den späteren Abschnitt 5.

Die folgenden Abbildungen veranschaulichen, welche Zusammenhänge im Sinne der Kriterien von „Back door“ und „Front door“ im konkreten Fall jeweils prinzipiell „identifizierbar“ in dem Sinne sind, dass ein beobachteter Zusammenhang zwischen Variablen auch auf einen entsprechenden kausalen Zusammenhang verweist.

(1) Das Schließen von Hintertüren: „Back door“-Kriterium


Das *Back door*-Kriterium besagt, dass die Kausalbeziehung von T nach Y durch den beobachteten Zusammenhang zwischen diesen Variablen identifiziert ist, **wenn es keinen ungeblockten Hintergrundpfad zwischen T und Y gibt**. Ein solcher Hintergrundpfad liegt in Abbildung 1c aber offensichtlich vor. Ungeblockt ist der Pfad, weil keine Pfeile direkt aufeinander zulaufen; Information kann also frei fließen. Üblicherweise wird diesem Drittvariablenproblem durch eine Konditionierung auf die gemeinsame Ursache Z begegnet. Bei korrekter Spezifikation wird dadurch der entsprechende Hintergrundpfad blockiert (Abbildung 2a), während eine unterbleibende Konditionierung zu einer verzerrten Schätzung des Effekts von T auf Y führt.

Anders liegt der Fall, wenn ein *bereits geblockter* Hintergrundpfad, eine sogenannte „Kollision“ vorliegt. Dies ist dann der Fall, wenn sich die Effekte von beiden Seiten – im Sinne eines „gemeinsamen Resultats“ – auf eine Variable richten (vgl. Abbildung 2b). Dies ist hier bei der Variablen Z gegeben; eine solche Variable wird deshalb auch als „Collider“-Variable bezeichnet. In diesem Fall *ist* also der Hintergrundpfad bereits durch die Struktur der Kausalverhältnisse geblockt! Eine zusätzliche Konditionierung auf Z im Rahmen der Analyse ist also nicht mehr nötig. Ganz im Gegenteil: Eine solche Konditionierung wäre in diesem Fall auch gar nicht sinnvoll. Vielmehr wird ein möglicher Zusammenhang (bzw. ein gegenläufiger Zusammenhang) zwischen T und Y erst induziert (Beispiel s.u.). Man könnte auch sagen, dass dadurch der eigentlich blockierte Hintergrundpfad erst „geöffnet“ wird. In Regressionsmodellen können fehlerhafterweise also auch zu viele Variablen kontrolliert werden („bad controls“: vgl. Angrist & Pischke 2009: S. 64f.)! Verschärft wird die Problematik noch dadurch, dass das Problem auch für sogenannte „Nachfahren“ der Kollisionsvariable, also von dieser abgeleitete Variablen, gilt.⁴


⁴ Ein besonders „unangenehmer“, aber wohl nicht seltener Fall ist übrigens einer der Stichproben-selektivität. Wenn es sich bei der Kollisionsvariable um Eigenschaften wie die „Bereitschaft zur Teilnahme an der Befragung“ handelt, dann gibt es bereits dadurch eine Verzerrung, dass man sich bei der Analyse auf die Fälle der „tendenziell Bereiten“, also jene in der vorliegenden Stichprobe beschränkt – und dies geschieht i.d.R. routinemäßig und ohne weiteres Nachdenken.

Abbildung 2: Sinnvolle und nicht sinnvolle Blockierung von Hintergrundpfaden

a)



b)



Auf Basis solcher Überlegungen lässt sich die in der Forschungspraxis regelmäßig auftauchende Frage nach der „richtigen Konditionierung“ bzw. möglichen „fehlenden Variablen“ erheblich spezifischer formulieren: Wird der Hintergrundpfad bzw. – allgemeiner formuliert – werden alle relevanten Hintergrundpfade geeignet unterbrochen? Wenn diese Frage bejaht werden kann, ist offensichtlich eine Identifizierung des interessierenden Kausal-effekts möglich.

Die Bezeichnung typischer Probleme in der Kausalanalyse verweist auf die Nicht-Berücksichtigung der entsprechenden Problematik. So spricht man von „confounding bias“ oder „omitted variable bias“, wenn relevante Hintergrundvariablen nicht berücksichtigt werden und von „collider bias“ oder „endogenous selection bias“ (Elwert & Winship 2014), wenn eine Kollisionsvariable fälschlicherweise kontrolliert wird und damit der wahre Wert des interessierenden Zusammenhangs verzerrt gemessen wird.


(2) Der direkte Weg: Das „Front door“-Kriterium

Allerdings gibt es noch ein weiteres Problem für die Identifizierung des interessierenden Kausaleffekts. Dies sind Hintergrundvariablen, die unter theoretischen Gesichtspunkten eigentlich relevant sind, die aber nicht *beobachtet* oder sogar nicht *beobachtbar* sind⁵ und auf die deshalb nicht konditioniert werden kann. In bestimmten Situationen ist aber auch dann die Identifizierung des interessierenden Kausaleffekts mittels empirischer Daten möglich.

In diesen Fällen wird die Messung des Kausaleffekts direkt angegangen. Das „Front door“-Kriterium besagt, dass die Kausalbeziehung von T nach Y identifiziert ist, **wenn sich der intervenierende Wirkungsmechanismus** (in Abbildung 3 mit M bezeichnet) **bestimmen lässt**. Diese Strategie lässt die Identifizierung der angenommenen Effekte zu, sofern die Kette der vorgeschlagenen Mechanismen vollständig ist. Bei Kausalverhältnissen wie in Abbildung 3 wäre also eine Bestimmung des Kausaleffekts möglich, sofern der Mechanismus M beobachtet werden kann, selbst wenn die relevante Hintergrundvariable Z latent ist und nicht auf sie konditioniert werden kann. Im Prinzip bedeutet diese Strategie, den relevanten Kausalprozess jeweils (nur) abschnittsweise zu schätzen. Auch diese Abschnitte sind allerdings – unter Anwendung des *Back door*-Kriteriums – auf mögliche Hintergrundpfade hin zu überprüfen.

Ein solches Vorgehen steht auch in der Tradition einer *mechanismenorientierten* Soziologie, die kausale Theorien durch die Modellierung der von ihnen spezifizierten Mechanismen zu prüfen (Hedström & Swedberg 1998).

Abbildung 3: Beobachten des „Wirkmechanismus“



In der Realität ist das für die Messung eines interessierenden Kausaleffekts relevante Geflecht von Kausalbeziehungen oft erheblich umfangreicher und komplexer und enthält Kombinationen der hier beschriebenen prototypischen Konstellationen (und anderer). So sind wichtige Hintergrundvariablen typischerweise über Mediatorvariablen mit den interessierenden unabhängigen und abhängigen Variablen verbunden. Damit können Hintergrundpfade ggf. auch bei ihnen unterbrochen werden. Ziel ist es daher, vor der

⁵ Zur besseren Unterscheidung kann man im Graphen die entsprechenden Knotenpunkte unausgefüllt und die mit ihr verbundenen Pfeile gestrichelt darstellen.

empirischen Analyse zunächst ein möglichst vollständiges Diagramm der relevanten Kausalbeziehungen zu erstellen, um dann auf dieser Basis über sinnvolle Analyse- und Kontrollstrategien zu entscheiden.

4. Probleme und Strategien der Datenanalyse an einem Beispiel

Das im Folgenden illustrierte Beispiel bezieht sich auf individuelle *Bildungsrenditen* im Sinne des Effekts von Bildung auf das persönliche Erwerbseinkommen bzw. den individuellen Stundenlohn. Dies ist ein populäres Thema wirtschafts- und sozialwissenschaftlicher Forschungen, und natürlich gibt es hier häufig auch ein klares kausalorientiertes Interesse: man möchte erfahren, ob und wie sich Bildung tatsächlich (kausal) auf das Einkommen auswirkt. Bildung wird dabei gerne in Form der metrischen Variablen „Bildungsjahre“ operationalisiert (vgl. etwa Mincer 1974; Card 1999; Harmon & Walker 2000; Ammermüller & Weber 2005). Die Operationalisierung der abhängigen Variablen in Form von Stundenlöhnen erspart u.a. die separate Berücksichtigung der Arbeitszeit als wichtige Einkommensdeterminante.


Abbildung 4a) zeigt den einfachsten Fall. Es gibt im theoretischen Modell keine Drittvariablen, die sowohl mit der unabhängigen Variablen (Bildung) als auch mit der abhängigen Variablen (Einkommen) in Verbindung stehen. In diesem Fall reicht also eine einfache Regressionsanalyse (bzw. Korrelation zwischen den beiden Variablen) aus, um den interessierenden Bildungseffekt empirisch zu bestimmen. Faktoren, die nur mit einer der beiden Variablen in Verbindung stehen, bilden keinen Pfad und sind nicht relevant. Dieses einfache Modell ohne Hintergrundvariablen ist aber offensichtlich unrealistisch.

Realistischer als die Annahme eines von anderen Variablen unbeeinflussten Zusammenhangs ist der in Abbildung 4b) exemplarisch repräsentierte Fall. Typische Hintergrundfaktoren sind hier beispielsweise Geschlecht und Alter bzw. Geburtskohorte (die beiden letztgenannten Variablen sind hier zusammen aufgeführt, da sie im Fall eines Querschnittsdatensatzes eindeutig zusammenhängen). Daneben gibt es wohl noch eine ganze Reihe von weiteren Faktoren, bei denen es plausibel ist, dass sie sowohl die erworbene Bildung als auch das Einkommen eines Individuums beeinflussen. Dies bedeutet, dass zunächst ungeblockte Hintergrundpfade zwischen Lohn und Bildung existieren; der einfache statistische Zusammenhang zwischen Bildung und Einkommen spiegelt den kausalen Effekt von Bildung auf Lohn also offensichtlich nur verzerrt wider.


Das Problem der Hintergrundvariablen ist nicht zu verwechseln mit der Frage *intervenierender* oder *mediierender* Variablen (vgl. Abbildung 4c). In diesem Fall geht es nicht um Konfundierung, sondern die unterschiedlichen Wege, über die Bildungseffekte auf das Einkommen zustande kommen. Ein Weg, auf dem sich Bildung in Einkommen übersetzt, könnte beispielsweise die individuelle Arbeitssituation darstellen. Die Kontrolle einzelner solcher Wege kann interessant sein, um unterschiedliche Wege und direkte und indirekte Pfade zu unterscheiden. Eine *Kontrolle* der intervenierenden Variablen ist aber nicht nötig (und auch nicht sinnvoll), um den Gesamteffekt der Bildung korrekt zu bestimmen. Im vorliegenden Beispiel sehen wir von intermediären Einflüssen erst einmal ab und interessieren uns weiterhin für den (gesamten) Effekt von Bildung auf Einkommen.

Abbildung 4: Kausalverhältnisse an einem Beispiel (monetäre Bildungsrenditen)


a) Isolierter Zusammenhang




b) Beteiligung von Hintergrundvariablen (*confounders*)



c) *Intervenierende Variablen*



d) *Bereits geblockte Hintergrundpfade (colliders)*



Wir ergänzen das Kausalmodell nun weiter, um noch ein Beispiel für eine weitere fehlerhafte Verwendung von Drittvariablen bzw. „zu viele“ Kontrollvariablen zu erhalten (Abbildung 4d). Dieses Problem bezieht sich auf die Kontrolle in bereits geblockten Hintergrundpfaden. Diese Blockade besteht in Variablen, die eine *Konsequenz* sowohl von Bildung als auch von Einkommen sind. Typischerweise kann dies subjektive Merkmale betreffen wie etwa Zufriedenheit oder auch politische Einstellungen (von möglichen Verbindungen zwischen den Hintergrundvariablen wird hier abgesehen). Derartige Variablen, durch welche ein Hintergrundpfad bereits geblockt wird, sollten also *nicht* kontrolliert werden! Ansonsten werden fälschlicherweise Zusammenhänge induziert. Ein Beispiel: Wenn – wie in der Abbildung dargestellt – Zufriedenheit eine Folge von sowohl Bildung als auch Einkommen ist, dann sind viele Hochgebildete Teil der Gruppe der Zufriedenen, und zwar sowohl solche mit hohem als auch solche mit niedrigem Einkommen. Natürlich können auch Niedriggebildete zufrieden sein, diese benötigen hierfür dann aber tendenziell einen anderen „Zufriedenheitsfaktor“ als die Bildung, im vorliegenden Fall also ein hohes Einkommen. *In der Gruppe der Zufriedenen* gibt es also – ohne Berücksichtigung eines direkten Kausaleffekts von Bildung auf Einkommen – tendenziell einen *negativen* Zusammenhang zwischen Bildung und Einkommen. Mit Berücksichtigung des direkten Effekts wird dieser zumindest abgeschwächt.

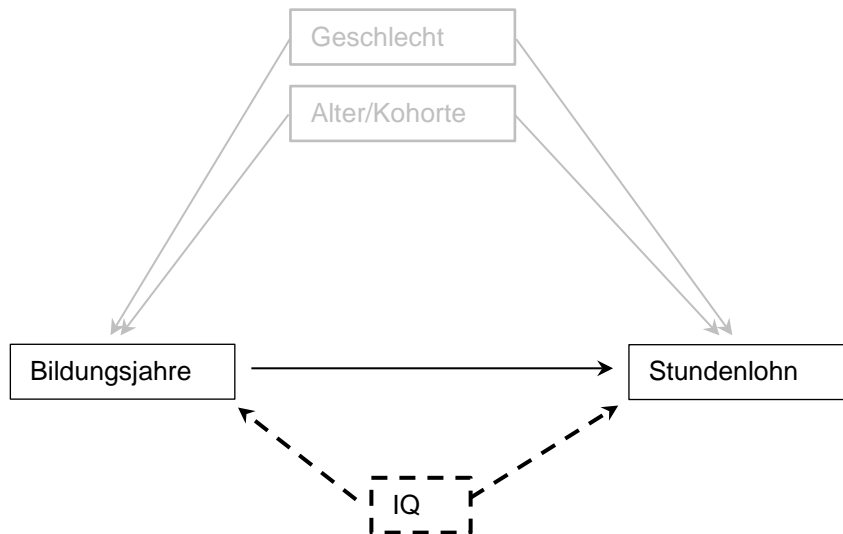
In jedem Fall entspricht dies aber offensichtlich nicht den realen Kausalverhältnissen. Der Fokus auf eine Gruppe (die Zufriedenen) stellt ja eine Form der „Kontrolle“ der Variablen Zufriedenheit dar. Somit wird klar, dass es im Gegensatz zur oben dargestellten Behandlung von echten Hintergrundfaktoren falsch wäre, bei der Analyse von Bildungsrenditen *nachgelagerte* Variablen wie die individuelle Zufriedenheit zu kontrollieren.

Ein weiteres Problem kommt hinzu, wenn Variablen zwar den theoretischen Überlegungen nach wichtige Hintergrundvariablen sind, sie aber nicht beobachtet worden sind. Eine explizite Kontrolle dieser Drittvariablen scheidet damit aus. Im vorliegenden Beispiel könnte ein solcher Faktor etwa die kognitive Leistungsfähigkeit („IQ“) sein (Abbildung 5a). Über individuelle kognitive Fähigkeiten sind in vielen sozialwissenschaftlichen Datensätzen keine Informationen verfügbar; sie dürften aber sowohl die Bildung als auch das Einkommen beeinflussen. Die Nichtberücksichtigung bzw. das Nichtvorhandensein von Informationen über individuelle Fähigkeiten und Leistung sind ein bekanntes Problem bei der Bestimmung von Bildungsrenditen („ability bias“: Card 1999).


Die hier gewählte Vorgehensweise schließt an das *Front door*-Kriterium an. Hierbei wird versucht, den relevanten Mechanismus direkt (und vollständig) zu messen (Abbildung 5b). So könnte man argumentieren, dass Bildungseffekte auf das Einkommen im Wesentlichen auf zwei Wegen zustande kommen. Einerseits entsteht der Effekt dadurch, dass unterschiedlich Gebildete unterschiedliche berufliche Tätigkeiten ausüben, welche unterschiedlich bewertet und daher unterschiedlich entlohnt werden. Der andere Aspekt spiegelt die Tatsache wider, dass sie betriebliche Arbeitsplätze mit unterschiedlichen Merkmalen haben, die ebenfalls unterschiedlich bewertet und entlohnt werden. Beide Aspekte würden (allein) aufgrund der erworbenen Bildung zugewiesen. Dies sind natürlich starke Annahmen, insbesondere was fehlende (zusätzliche) Einflüsse des IQ auf Berufs- und Arbeitsplatzzugehörigkeit betrifft; das Beispiel dient hier aber ja auch nur zur Veranschaulichung.

Abbildung 5: Latente Hintergrundvariablen

a) Problem unbeobachteter Variablen



b) Praktische Anwendung des *Front door*-Kriteriums



Im entsprechenden Messmodell könnte der Aspekt der beruflichen Tätigkeit dann vereinfachend etwa durch beruflichen Status und der Aspekt der Arbeitsplatzmerkmale durch die Betriebsgröße(nklasse) repräsentiert werden. Empirisch umgesetzt werden kann dies in einem einfachen Strukturgleichungsmodell (SEM), mit dem die Größe der beiden Mechanismen jeweils abschnittsweise (an den Stellen 1 und 2) geschätzt wird. Der geschätzte Gesamteffekt ergibt sich als Summe aller Pfade. Dabei muss allerdings wieder auf mögliche Hintergrundpfade geachtet werden. Diese könnten aber hier durch Konditionieren auf Bildungsjahre oder die anderen sozialstrukturellen Merkmale unterbrochen werden.

5. Ein Vergleich unterschiedlicher Analyseverfahren

Grafische Illustrationen erlauben auch die Systematisierung üblicher statistischer Verfahren der Kausalanalyse. Dies kann insbesondere auch für die Veranschaulichung im Rahmen der universitären Methodenausbildung hilfreich sein.

Verschiedene Analyseverfahren entsprechen dabei unterschiedlichen Strategien der Konditionierung bzw. Behandlung von Hintergrundpfaden. Dies basiert auf der wichtigen Eigenschaft, dass bei der Anwendung des *Back door*-Kriteriums ein Hintergrundpfad prinzipiell an *jeder* Stelle unterbrochen werden kann, und Hintergrundpfade können prinzipiell über viele Stationen laufen. Im vorliegenden Fall läuft ein ungeblockter Hintergrundpfad über die Variablen Z, U und V.

Den Standard stellt die im Rahmen eines multivariaten Regressionsmodells verfolgte Strategie der Konditionierung dar, bei der „Kontrollvariablen“ i.e.S. zum Einsatz kommen. Die Hintergrundvariablen sollten im Regressionsmodell kontrolliert werden, wenn der kausale Effekt der Bildung bestimmt werden soll. Konditioniert wird dabei unmittelbar auf die Determinanten der abhängigen Variable (Y), hier mit Z bezeichnet (vgl. Abbildung 6a). Durch die Eliminierung von Z wird an dieser Stelle der Hintergrundpfad blockiert. Die entsprechende Regressionsanalyse enthält dann also neben T auch die Determinante(n) Z als unabhängige Variable(n), und bei deren erfolgreicher Kontrolle lässt sich der Regressionskoeffizient für T als kausaler Effekt interpretieren.⁶

In besonderen Fällen – insbesondere Verfahren zur Erfassung von Veränderungen über die Zeit – ist hierfür sogar nicht einmal eine explizite Messung dieser Determinanten erforderlich. Es reicht das Wissen um bestimmte Eigenschaften der betreffenden Variablen, etwa wenn im Rahmen von Fixed-Effects-Panelmodellen *zeitinvariante* Faktoren (grundsätzlich) kontrolliert werden.

Im Kontrast dazu stellt Abbildung 6b) die in einem quasi-experimentellen bzw. balancierenden Ansatz verfolgte Strategie dar. Hier bestimmen die Hintergrundvariablen die Zuordnung zur „Treatmentgruppe“.⁷ Die unmittelbaren Determinanten sind hier mit V bezeichnet. Diese müssen also nicht die gleichen sein wie die Kontrollvariablen der entsprechenden multivariaten Regression an einer anderen Stelle des Pfades. Der Hintergrundpfad wird in diesem Fall durch Konditionieren auf diese unmittelbaren Determinanten blockiert („Kontrolle/Ausbalancieren der Gruppenzuordnung“). Einen Spezialfall stellt die Kontrolle bzw. das Ausbalancieren der Gruppen mittels Propensity Score (vgl. Rosenbaum & Rubin 1983; Gangl & DiPrete 2004; Thoemmes & Kim 2011) dar. In diesem Fall würde der Propensity Score, welcher die individuelle Treatmentwahrscheinlichkeit angibt, als zusätzliche, unmittelbar die Gruppenzuordnung determinierende Variable in die Kausalkette aufgenommen. Die Messung des kausalen Effekts von T erfolgt über einen einfachen Vergleich der Werte für Treatment- und Nicht-Treatment-Gruppe.


Beide genannten Kontrollstrategien erfordern i.d.R. ausreichende empirische Informationen über die jeweils relevanten Drittvariablen.

⁶ Wie bei allen anderen Beispielen auch, gilt dies selbstverständlich nur unter dem Vorbehalt „idealer Daten“, welche weder Stichproben- noch Messfehler enthalten.


⁷ Eine einfache quasi-experimentelle Treatmentanalyse mit diskreter Gruppeneinteilung ist dabei allerdings nur bedingt vergleichbar mit einer Regressionsanalyse, in der T als kontinuierliche Variable eingeht.

Abbildung 6: Grafische Illustration unterschiedlicher Verfahren der Kausalanalyse (I)

a) *Back door*-Kriterium: Strategie Regressionsmodell (Kontrollieren/Konditionieren)



b) *Back door*-Kriterium: Strategie Quasi-Experiment/Balancieren/Matching




Die folgenden Strategien hingegen kommen insbesondere bei nicht gemessenen („latent“), aber als relevant erachteten Hintergrundfaktoren zum Einsatz. Bei der in der Ökonometrie beliebten Strategie der Instrumentalvariablen (vgl. etwa Wooldridge 2005) wird eine alternative Variable für T gesucht, die zwar die unabhängige Variable determiniert, von der aber angenommen werden kann, dass sie nicht mit dem Fehler (der fehlenden Hintergrundvariable Z) zusammenhängt (Abbildung 7a). Man könnte auch davon sprechen, dass eine „gefilterte“, also um den Fehler bereinigte Version der unabhängigen Variablen zum Einsatz kommt. Die Annahme ist aber nicht direkt überprüfbar, sodass man auch hier auf theoretische Überlegungen angewiesen ist.

Bei der mechanismenorientierten Strategie des *Front door*-Kriteriums schließlich wird versucht, den Kausaleffekt direkt (abschnittsweise) zu erfassen (vgl. Abbildung 7b). Beide Strategien ähneln sich insofern, als sie das Problem ungeblockter Hintergrundpfade eher umgehen als direkt kontrollieren.

Abbildung 7: Grafische Illustration unterschiedlicher Verfahren der Kausalanalyse (II)

a) Instrumentalvariablen



b) Mechanismus im Sinne des *Front door*-Kriteriums




Tabelle 1 stellt noch einmal die unterschiedlichen Strategien gegenüber.

Tabelle 1: Systematisierung von Verfahren der Kausalanalyse entsprechend der jeweiligen Behandlung von Hintergrundpfaden

<p>Hintergrundpfade an unterschiedlichen Stellen blockieren</p> <p>(Back door-Kriterium)</p>	<p>Kontrolle der (sonstigen) Determinanten der abhängigen Variablen (<i>Regression</i>)</p> <p>[vgl. Abb. 6a]</p>	<p>Kontrolle der Determinanten der <i>Treatment</i>-Variable (<i>Balancieren/Matching</i>)</p> <p>[vgl. Abb. 6b]</p>
<p>Hintergrundpfade „umgehen“ (mehrstufige Verfahren)</p>	<p>„Bereinigung“ der UV (<i>Instrumentalvariablen</i>)</p> <p>[vgl. Abb. 7a]</p>	<p>Wirkmechanismus direkt erfassen</p> <p>(Front door-Kriterium)</p> <p>[vgl. Abb. 7b]</p>

6. Praktische Konsequenzen und Fazit

In der Praxis kommt erfahrungsgemäß eine Reihe typischer Missverständnisse bei der Verwendung grafischer Verfahren vor.

Ein häufiger Fehler ist, dass Kausaldiagramme als Assoziations- bzw. Prädiktionsmodelle aufgefasst werden, welche *empirisch beobachtete* Zusammenhänge abbilden. Außerdem beschränkt man sich häufig auf *selbst gemessene* (oder prinzipiell messbare) Faktoren. Das besondere Potenzial von Kausaldiagrammen liegt aber gerade darin, dass sie zunächst rein „gedankliche“, theoretische Modelle sind, aus denen erst in einem späteren Schritt konkrete Messmodelle abgeleitet werden. Das Ziel ist, die „wahren“ Kausalverhältnisse möglichst *vollständig* abzubilden, um dann Rückschlüsse auf die Identifizierbarkeit einzelner Zusammenhänge auf Basis empirischer Beobachtungen zu ziehen. Das Modell über den „datengenerierenden Prozess“ schließt oft Variablen ein, über die keine empirischen Informationen vorliegen. Dies ist aber auch nicht in jedem Fall erforderlich, um Schlussfolgerungen über die Identifizierbarkeit eines bestimmten Effekts abzuleiten, da dies ja zunächst nur auf Basis der *strukturellen* Konstellation der Variablen geschieht.

Der Anspruch der Vollständigkeit ist oft unrealistisch hoch. Zudem ist eine Konsequenz, dass ein Modell, das diesen Anspruch erhebt, häufig übermäßig groß und komplex wird. Die gute Nachricht ist allerdings, dass viele Entscheidungen bereits auf der Basis reduzierter Modelle getroffen werden können und insbesondere viele Fehler bereits erkennbar sind. Außerdem ist es natürlich immer auch eine Gradfrage: Hintergrundpfade, die auf – relativ zum interessierenden Effekt – schwachen Zusammenhängen basieren (und deshalb nur sehr „schmale Informationsströme“ darstellen) induzieren, auch wenn sie unberücksichtigt bleiben, tendenziell auch nur geringe Verzerrungen.

Grafische Illustrationen kausaler Beziehungsgeflechte in Form von DAGs repräsentieren also Theoriemodelle, welche die Auswahl von Kovariablen in empirischen Modellen der Kausalanalyse deutlich erleichtern. Sie helfen bei der Entscheidung, welche Variablen (an welcher Stelle) kontrolliert werden sollen – und vor allem welche *nicht*. Diese Entscheidung ist aber i.d.R. in Bezug auf die Frage nach der Identifizierbarkeit eines *ganz bestimmten* Effekts zu treffen, und wenn andere Zusammenhänge aus dem Modell im Fokus stehen, wird die Entscheidung typischerweise anders ausfallen. Für die Praxis der empirischen Datenanalyse hat dies eine entscheidende Konsequenz. Auch wenn es nur *ein* „wahres“ Kausalmodell der

Beziehungen zwischen den betreffenden Variablen gibt, ist prinzipiell für jeden interessierenden Zusammenhang darin (insbesondere auch für jede interessierende unabhängige Variable) jeweils ein *spezifisches* passendes empirisches Analysemodell nötig, das typischerweise eine ganz spezifische Auswahl von Kontrollvariablen enthält. Daher sollten auch Effektkoeffizienten „reiner Kontrollvariablen“ nicht interpretiert werden, da das jeweilige Analysemodell ja gar nicht auf sie hin spezifiziert wurde! Demgegenüber erscheinen in der Praxis der empirischen Sozialforschung häufig vorzufindende Vorgehensweisen unangemessen, etwa wenn in einer langen Liste von (Kontroll-)Variablen nach irgendwie auffälligen Werten gesucht und dann über substanzielle Erklärungen für diese spekuliert wird. In aller Regel wurden diese Werte aber gar nicht kausaltheoretisch auf mögliche Verzerrungen hin überprüft, und folglich erübrigt sich auch die Suche nach substanziellen Erklärungen für sie.

Auch sollte die genaue Spezifikation nicht nur von Untersuchungs-, sondern auch von Kontrollvariablen mehr Aufmerksamkeit erhalten. In der Logik der DAGs wird ein Hintergrundpfad (nur) von Kontrollvariablen in jeweils korrekter Form vollständig geblockt, andernfalls „fließt ein Teil der Information“ noch durch die entsprechende „Barriere“. Die einfache Aufnahme einer Variablen in ein Standard-Regressionsmodell entspricht (im metrischen Fall) einem linearen Zusammenhang und ist nur dann die richtige Wahl, wenn es sich bei dem betreffenden substanziellen Zusammenhang tatsächlich um einen linearen Zusammenhang handelt.

Insgesamt ermöglichen grafische Illustrationen einen intuitiven Zugang zu Fragen der Kausalanalyse. Für Spezialisten sind viele der damit auffindbaren Probleme und Erkenntnisse wohl gut bekannt, und natürlich liefern auch grafische Verfahren nicht unmittelbar eine valide Messung von Kausaleffekten – letztlich bleiben ja auch sie Hypothesen. DAGs können aber gerade bei der allgemeinen Aufklärung über Probleme bei der Kausalanalyse helfen, nicht zuletzt in der Lehre und auch bereits im Hinblick auf theoretische Argumentationen. Insofern sollten sie öfter in Veröffentlichungen der empirischen Sozialforschung auftauchen – gerne auch außerhalb des technischen „Methodenteils“.

Literatur

Angrist, Joshua D. & Pischke, Jörn-Steffen (2009): *Mostly harmless econometrics: An empiricist's companion*. Princeton NJ: Princeton Univ. Press.

Ammermüller, Andreas & Weber, Andrea Maria (2005): *Educational attainment and returns to education in Germany. An analysis by subject of degree, gender and region*. Discussion paper No. 05-17. Mannheim: ZEW.

Card, David (1999): *The causal effect of education on earnings*. In: Ashenfelter, Orley & Card, David (Hg.), *Handbook of labor economics*, Volume 3. Amsterdam: Elsevier, S. 1801–1863.

Diekmann, Andreas (2005): *Empirische Sozialforschung. Grundlagen, Methoden, Anwendungen*. Reinbek: Rowohlt.

Elwert, Felix (2013): *Graphical causal models*. In Morgan, Stephen L. (Hg.), *Handbook of causal analysis for social research*. Dordrecht: Springer, S. 245–273.

Elwert, Felix & Winship, Christopher (2014): *Endogenous selection bias: The problem of conditioning on a collider variable*. *Annual Review of Sociology* 40, S. 31–53.

- Gangl, Markus & DiPrete, Thomas A. (2004): Kausalanalyse durch Matchingverfahren. In: Diekmann, Andreas (Hg.), Methoden der empirischen Sozialforschung. *Kölner Zeitschrift für Soziologie und Sozialpsychologie*, Sonderheft 44. Wiesbaden: VS, S. 396–420.
- Harmon, Colm & Walker, Ian (2000): The returns to the quantity and quality of education. Evidence for men in England and Wales. *Economica* 67(265), S. 19–35.
- Hedström, Peter & Swedberg, Richard (1998): Social mechanisms: An analytical approach to social theory. Cambridge: Cambridge Univ. Press.
- Jo, Booil (2008): Causal inference in randomized experiments with mediational processes. *Psychological Methods* 13 (4), S. 314–336.
- Mincer, Jacob (1974): Schooling, experience and earnings. New York: Columbia Univ. Press.
- Morgan, Stephen L. & Winship, Christopher (2007): Counterfactuals and causal inference: Methods and principles for social research. Cambridge: Cambridge Univ. Press.
- Pearl, Judea (2000): Causality: Models, reasoning, and inference. Cambridge: Cambridge Univ. Press.
- Pearl, Judea, Glymour, Madelyn, & Jewell, Nicholas P. (2016): Causal inference in statistics: A primer. Chichester: John Wiley.
- Pearl, Judea & Mackenzie, Dana (2018): The book of why: The new science of cause and effect. New York: Basic Books.
- Rosenbaum, Paul R. & Rubin, Donald B. (1983): The central role of the propensity score in observational studies for causal effects. *Biometrika* 70, S. 41-55.
- Shalizi, Cosma Rohilla (2017): Advanced data analysis from an elementary point of view. Ch. 21: Graphical causal models. www.stat.cmu.edu/~cshalizi/ADAfaEPoV/ADAfaEPoV.pdf
- Spirites, Peter, Glymour, Clark & Scheines, Richard (1993): Causation, prediction, and search. Cambridge MA: The MIT Press.
- Thoemmes, Felix J. & Kim, Eun Sook (2011): A systematic review of propensity score methods in the social sciences. *Multivariate Behavioral Research* 46 (1): 90–118.
- Wooldridge, Jeffrey M. (2005): Introductory econometrics: A modern approach. Mason, OH: Thomson South-Western.