

# DIRECTED ACYCLIC GRAPHS ODER WAS IST EIN CONFOUNDER?

30. März 2023


Prof. Dr. Thomas Neusius



# KAUSALITÄT IST ÜBERALL...

- ▶ Epidemiologische insb. ätiologische Studien
- ▶ Bildungsforschung
- ▶ Wirtschaftswissenschaften
- ▶ Sozialwissenschaften
- ▶ Biologie

## TOY MODEL: TABLETS IM UNTERRICHT



Regression:


$$Y = \beta T + \alpha$$

```
In [6]: import statsmodels.formula.api as smf
        model_1 = smf.ols('enem_score ~ Tablet', data=tablets).fit()
        model_1.summary().tables[1]
```


```
Out[6]:
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	351.7070	24.511	14.349	0.000	303.066	400.348
Tablet[T.True]	105.3081	36.140	2.914	0.004	33.590	177.026

# TOY MODEL: TABLETS IM UNTERRICHT




# TOY MODEL: TABLETS IM UNTERRICHT




- ▶ Tablet-Klassen erreichen höheren Test-Score

# TOY MODEL: TABLETS IM UNTERRICHT




- ▶ Tablet-Klassen erreichen höheren Test-Score
- ▶ Steckt dahinter ein Kausalzusammenhang?

# TOY MODEL: TABLETS IM UNTERRICHT



- ▶ Tablet-Klassen erreichen höheren Test-Score
- ▶ Steckt dahinter ein Kausalzusammenhang?
- ▶ Zentrale Problemstellung für Kausalstudien: Kontrafaktische Ergebnisse sind nicht zugänglich

# TOY MODEL: TABLETS IM UNTERRICHT



- ▶ Tablet-Klassen erreichen höheren Test-Score
- ▶ Steckt dahinter ein Kausalzusammenhang?
- ▶ Zentrale Problemstellung für Kausalstudien: Kontrafaktische Ergebnisse sind nicht zugänglich
- ▶ Ausweg: Randomized Control Trial (RCT) - aber oft keine Option!



# TOY MODEL: TABLETS IM UNTERRICHT UND STÖRVARIALE

# TOY MODEL: TABLETS IM UNTERRICHT UND STÖRVARIALE


- ▶ Mögliche Störvariable?

# TOY MODEL: TABLETS IM UNTERRICHT UND STÖRVARIALE

- ▶ Mögliche Störvariable?
- ▶ Hier: Könnte es sein, dass die finanzielle Ausstattung bei den Tablet-Klassen besser ist? Könnte dies auch direkt für bessere Leistungen sorgen?

# TOY MODEL: TABLETS IM UNTERRICHT UND STÖR VARIABLE

- ▶ Mögliche Störvariable?
- ▶ Hier: Könnte es sein, dass die finanzielle Ausstattung bei den Tablet-Klassen besser ist? Könnte dies auch direkt für bessere Leistungen sorgen?
- ▶ Hilfsvariable: Schulgeld (Tuition)



## TOY MODEL: HERAUSRECHNEN DES STÖREINFLUSSES

```
In [5]: model_1 = smf.ols('enem_score ~ Tablet + Tuition', data=tablets).fit()  
model_1.summary().tables[1]
```

```
Out[5]:
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	-36.3671	37.114	-0.980	0.330	-110.028	37.294
Tablet[T.True]	-22.5389	25.992	-0.867	0.388	-74.126	29.049
Tuition	0.4433	0.038	11.582	0.000	0.367	0.519

# TOY MODEL: HERAUSRECHNEN DES STÖREINFLUSSES

- Kontrolle des Einflusses einer Störvariablen  $X$  (Hier: Tuition)

```
In [5]: model_1 = smf.ols('enem_score ~ Tablet + Tuition', data=tablets).fit()  
model_1.summary().tables[1]
```

```
Out[5]:
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	-36.3671	37.114	-0.980	0.330	-110.028	37.294
Tablet[T.True]	-22.5389	25.992	-0.867	0.388	-74.126	29.049
Tuition	0.4433	0.038	11.582	0.000	0.367	0.519

# TOY MODEL: HERAUSRECHNEN DES STÖREINFLUSSES

- ▶ Kontrolle des Einflusses einer Störvariablen  $X$  (Hier: Tuition)
- ▶ Regression

$$Y = \beta T + \beta_1 X + \alpha_1$$

```
In [5]: model_1 = smf.ols('enem_score ~ Tablet + Tuition', data=tablets).fit()  
model_1.summary().tables[1]
```

```
Out[5]:
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	-36.3671	37.114	-0.980	0.330	-110.028	37.294
Tablet[T.True]	-22.5389	25.992	-0.867	0.388	-74.126	29.049
Tuition	0.4433	0.038	11.582	0.000	0.367	0.519

# TOY MODEL: HERAUSRECHNEN DES STÖREINFLUSSES

- ▶ Kontrolle des Einflusses einer Störvariablen  $X$  (Hier: Tuition)
- ▶ Regression

$$Y = \beta T + \beta_1 X + \alpha_1$$

- ▶ Ergebnis: Der Einfluss der Tablets ist negativ, wenn man die Bedeutung der *tuition fee* herausrechnet.

```
In [5]: model_1 = smf.ols('enem_score ~ Tablet + Tuition', data=tablets).fit()  
model_1.summary().tables[1]
```

```
Out[5]:
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	-36.3671	37.114	-0.980	0.330	-110.028	37.294
Tablet[T.True]	-22.5389	25.992	-0.867	0.388	-74.126	29.049
Tuition	0.4433	0.038	11.582	0.000	0.367	0.519



# WAS IST EIN CONFOUNDER?

# WAS IST EIN CONFOUNDER?

- ▶ Problem der Störvariablen/Confounder ist lange bekannt

## Greenland und Robins, 1986

``While confounding is widely recognized as one of the central problems in epidemiological research, a review of the literature will reveal little consistency among the definitions of confounding or confounder."``

# WAS IST EIN CONFOUNDER?

- ▶ Problem der Störvariablen/Confounder ist lange bekannt

## Greenland und Robins, 1986

``While confounding is widely recognized as one of the central problems in epidemiological research, a review of the literature will reveal little consistency among the definitions of confounding or confounder."``

- ▶ Definitionen waren lange uneinheitlich und tlw. widersprüchlich

# WAS IST EIN CONFOUNDER?

- ▶ Problem der Störvariablen/Confounder ist lange bekannt

## Greenland und Robins, 1986

“While confounding is widely recognized as one of the central problems in epidemiological research, a review of the literature will reveal little consistency among the definitions of confounding or confounder.”

- ▶ Definitionen waren lange uneinheitlich und tlw. widersprüchlich
- ▶ Praktisches Problem: Ohne begriffliche Klarheit werden Einflüsse zu vieler Variablen herausgerechnet. Es kann zu Artefakten kommen...

# KLASSISCHER ANSATZ

Bei einer Kausalanalyse von

$$T \rightarrow Y$$

ist die Größe  $X$  **ein Confounder**

1. wenn die Verteilung von  $X$  von  $T$  abhängt,
2. und  $X$  in der Gruppe der Unbehandelten mit  $Y$  korreliert.

# DIRECTED ACYCLIC GRAPH (DAG)

Mediator:

$$T \longrightarrow X \longrightarrow Y$$

# DIRECTED ACYCLIC GRAPH (DAG)

Mediator:

$$T \longrightarrow X \longrightarrow Y$$

► Erfüllt 1 und 2.

# DIRECTED ACYCLIC GRAPH (DAG)

Mediator:

$$T \longrightarrow X \longrightarrow Y$$

- ▶ Erfüllt 1 und 2.
- ▶ Ist  $X$  ein Confounder?



# DIRECTED ACYCLIC GRAPH (DAG)

Mediator:

$$T \longrightarrow X \longrightarrow Y$$

- ▶ Erfüllt 1 und 2.
- ▶ Ist  $X$  ein Confounder?
- ▶  $X$  ist Teil der Kausalkette von  $T$  nach  $Y$ .

# DIRECTED ACYCLIC GRAPH (DAG)

Mediator:

$$T \longrightarrow X \longrightarrow Y$$

- ▶ Erfüllt 1 und 2.
- ▶ Ist  $X$  ein Confounder?
- ▶  $X$  ist Teil der Kausalkette von  $T$  nach  $Y$ .
- ▶ Würde man den Einfluss von  $X$  herausrechnen, kann es keinen Einfluss von  $T$  auf  $Y$  geben.

# DIRECTED ACYCLIC GRAPH (DAG)

Mediator:

$$T \longrightarrow X \longrightarrow Y$$

- ▶ Erfüllt 1 und 2.
- ▶ Ist  $X$  ein Confounder?
- ▶  $X$  ist Teil der Kausalkette von  $T$  nach  $Y$ .
- ▶ Würde man den Einfluss von  $X$  herausrechnen, kann es keinen Einfluss von  $T$  auf  $Y$  geben.
- ▶  **$X$  ist hier kein Confounder** und sein Einfluss darf nicht herausgerechnet werden!

# KLASSISCHER ANSATZ (ERGÄNZT)

Bei einer Kausalanalyse von


$$T \rightarrow Y$$

ist die Größe  $X$  **ein Confounder**

1. wenn die Verteilung von  $X$  von  $T$  abhängt,
2. und  $X$  in der Gruppe der Unbehandelten mit  $Y$  korreliert,
3.  $X$  ist nicht Teil einer Kausalkette von  $T \rightarrow \dots \rightarrow Y$ .


# KAUSALGRAPHEN (CAUSAL GRAPHS)

Mediator und Ersatzgröße (Proxy):



# KAUSALGRAPHEN (CAUSAL GRAPHS)


Mediator und Ersatzgröße (Proxy):



- ▶ X erfüllt 1, 2 und 3

# KAUSALGRAPHEN (CAUSAL GRAPHS)


Mediator und Ersatzgröße (Proxy):



- ▶ X erfüllt 1, 2 und 3
- ▶ Ist X ein Confounder?

# KAUSALGRAPHEN (CAUSAL GRAPHS)

Mediator und Ersatzgröße (Proxy):




- ▶  $X$  erfüllt 1, 2 und 3
- ▶ Ist  $X$  ein Confounder?
- ▶ Würde man den Einfluss von  $X$  herausrechnen, wird der Einfluss von  $T$  auf  $Y$  reduziert - man unterschätzt den Effekt von  $T$  auf  $Y$ .



# KAUSALGRAPHEN (CAUSAL GRAPHS)


Mediator und Ersatzgröße (Proxy):



- ▶  $X$  erfüllt 1, 2 und 3
- ▶ Ist  $X$  ein Confounder?
- ▶ Würde man den Einfluss von  $X$  herausrechnen, wird der Einfluss von  $T$  auf  $Y$  reduziert - man unterschätzt den Effekt von  $T$  auf  $Y$ .
- ▶  $X$  ist hier kein Confounder und sein Einfluss darf nicht herausgerechnet werden.


# KAUSALGRAPHEN (CAUSAL GRAPHS)

Normaler Fall für Confounder:



# KAUSALGRAPHEN (CAUSAL GRAPHS)


Normaler Fall für Confounder:



**Back-Door-Kriterium**

# KAUSALGRAPHEN (CAUSAL GRAPHS)

Normaler Fall für Confounder:




## Back-Door-Kriterium

- ▶ Ein Confounder eröffnet einen Pfad, der  $T$  rückwärts verlässt und zum Ergebnis  $Y$  führt (back-door path).

# KAUSALGRAPHEN (CAUSAL GRAPHS)

Normaler Fall für Confounder:




## Back-Door-Kriterium

- ▶ Ein Confounder eröffnet einen Pfad, der  $T$  rückwärts verlässt und zum Ergebnis  $Y$  führt (back-door path).
- ▶ RCT beseitigen alle auf  $T$  zulaufenden Pfade

# KAUSALGRAPHEN (CAUSAL GRAPHS)

Normaler Fall für Confounder:



## Back-Door-Kriterium

- ▶ Ein Confounder eröffnet einen Pfad, der  $T$  rückwärts verlässt und zum Ergebnis  $Y$  führt (back-door path).
- ▶ RCT beseitigen alle auf  $T$  zulaufenden Pfade
- ▶ Es muss bei der Berücksichtigung von Confoundern jeder back-door path geschlossen werden.

# BEISPIEL: MEDIKAMENTENTEST

```
In [2]: hospital = pd.read_csv("./data/hospital_treatment.csv")  
hospital.head()
```

Out[2]:

	hospital	treatment	severity	days
0	1	1	29.686618	82
1	1	1	20.050340	57
2	1	1	20.302399	49
3	0	0	10.603118	44
4	0	0	8.332793	15

# BEISPIEL: MEDIKAMENTENTEST

- ▶ Test wird in zwei Kliniken durchgeführt

```
In [2]: hospital = pd.read_csv("./data/hospital_treatment.csv")  
hospital.head()
```

```
Out[2]:
```

	hospital	treatment	severity	days
0	1	1	29.686618	82
1	1	1	20.050340	57
2	1	1	20.302399	49
3	0	0	10.603118	44
4	0	0	8.332793	15



# BEISPIEL: MEDIKAMENTENTEST

- ▶ Test wird in zwei Kliniken durchgeführt
- ▶ Die Ergebnisgröße ist die Verweildauer in Tagen

```
In [2]: hospital = pd.read_csv("./data/hospital_treatment.csv")  
hospital.head()
```

```
Out[2]:
```

	hospital	treatment	severity	days
0	1	1	29.686618	82
1	1	1	20.050340	57
2	1	1	20.302399	49
3	0	0	10.603118	44
4	0	0	8.332793	15

# BEISPIEL: MEDIKAMENTENTEST

- ▶ Test wird in zwei Kliniken durchgeführt
- ▶ Die Ergebnisgröße ist die Verweildauer in Tagen
- ▶ Klinik 0 gibt 7% der Patienten das echte Präparat, 93% erhalten ein Placebo

```
In [2]: hospital = pd.read_csv("./data/hospital_treatment.csv")  
hospital.head()
```

```
Out[2]:
```

	hospital	treatment	severity	days
0	1	1	29.686618	82
1	1	1	20.050340	57
2	1	1	20.302399	49
3	0	0	10.603118	44
4	0	0	8.332793	15

# BEISPIEL: MEDIKAMENTENTEST

- ▶ Test wird in zwei Kliniken durchgeführt
- ▶ Die Ergebnisgröße ist die Verweildauer in Tagen
- ▶ Klinik 0 gibt 7% der Patienten das echte Präparat, 93% erhalten ein Placebo
- ▶ Klinik 1 gibt 94% der Patienten das echte Präparat, 6% erhalten ein Placebo

```
In [2]: hospital = pd.read_csv("./data/hospital_treatment.csv")  
hospital.head()
```

```
Out[2]:
```

	hospital	treatment	severity	days
0	1	1	29.686618	82
1	1	1	20.050340	57
2	1	1	20.302399	49
3	0	0	10.603118	44
4	0	0	8.332793	15

# BEISPIEL: MEDIKAMENTENTEST

- ▶ Test wird in zwei Kliniken durchgeführt
- ▶ Die Ergebnisgröße ist die Verweildauer in Tagen
- ▶ Klinik 0 gibt 7% der Patienten das echte Präparat, 93% erhalten ein Placebo
- ▶ Klinik 1 gibt 94% der Patienten das echte Präparat, 6% erhalten ein Placebo
- ▶ Klinik 1 hat typischerweise Patienten mit höherem Schweregrad

Beispiel aus Facur (2022)

```
In [2]: hospital = pd.read_csv("./data/hospital_treatment.csv")  
hospital.head()
```

```
Out[2]:
```

	hospital	treatment	severity	days
0	1	1	29.686618	82
1	1	1	20.050340	57
2	1	1	20.302399	49
3	0	0	10.603118	44
4	0	0	8.332793	15

## BEISPIEL: MEDIKAMENTENTEST


```
In [73]: (hospital
          .groupby("hospital")
          ["severity", 'days', 'treatment']
          .mean())
```

```
/tmp/ipykernel_15980/20373629.py:1:
Warning: GroupBy.mean(..., axis=0) will be deprecated, use a list
(hospital
```

```
Out[73]:
```

	severity	days	treatment
hospital			
0	7.944987	29.620690	0.068966
1	19.757954	49.215686	0.941176

## BEISPIEL: MEDIKAMENTENTEST



# BEISPIEL: MEDIKAMENTENTEST

```
In [36]: # simplistic regression
hosp_1 = smf.ols('days ~ treatment', data=hospital).fit()
hosp_1.summary().tables[1]
```

```
Out[36]:
```

	coef	std err	t	P> t	[0.025	0.975]
<b>Intercept</b>	33.2667	2.662	12.498	0.000	27.968	38.566
<b>treatment</b>	14.1533	3.367	4.204	0.000	7.451	20.856

Die einfache Regression würde dem Präparat eine kontraproduktive Wirkung zuschreiben...

# BEISPIEL: MEDIKAMENTENTEST

Getrennt nach den beiden Kliniken:

```
In [37]: hosp_2 = smf.ols('days ~ treatment', data=hospital.query("hospital==0")).fit()
hosp_2.summary().tables[1]
```

```
Out[37]:
```

	coef	std err	t	P> t	[0.025	0.975]
<b>Intercept</b>	30.4074	2.868	10.602	0.000	24.523	36.292
<b>treatment</b>	-11.4074	10.921	-1.045	0.306	-33.816	11.001

```
In [38]: hosp_2 = smf.ols('days ~ treatment', data=hospital.query("hospital==1")).fit()
hosp_2.summary().tables[1]
```

```
Out[38]:
```

	coef	std err	t	P> t	[0.025	0.975]
<b>Intercept</b>	59.0000	6.747	8.745	0.000	45.442	72.558
<b>treatment</b>	-10.3958	6.955	-1.495	0.141	-24.371	3.580

Das Präparat scheint doch seine Wirkung zu haben...



# BEISPIEL: MEDIKAMENTENTEST

Wir können auch den Schweregrad berücksichtigen:

```
In [39]: hosp_4 = smf.ols('days ~ treatment + severity', data=hospital).fit()  
hosp_4.summary().tables[1]
```

```
Out[39]:
```

	coef	std err	t	P> t	[0.025	0.975]
<b>Intercept</b>	11.6641	2.000	5.832	0.000	7.681	15.647
<b>treatment</b>	-7.5912	2.269	-3.345	0.001	-12.110	-3.073
<b>severity</b>	2.2741	0.154	14.793	0.000	1.968	2.580

## MEDIKAMENTENTEST: VIEL HILFT VIEL?

Sollten wir sicherheitshalber nicht Schweregrad und Klinik im Modell mit einbeziehen?

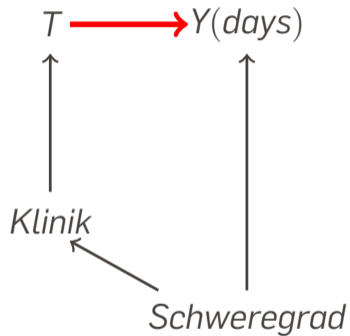
```
In [40]: hosp_5 = smf.ols('days ~ treatment + severity + hospital', data=hospital).fit()  
hosp_5.summary().tables[1]
```

```
Out[40]:
```

	coef	std err	t	P> t	[0.025	0.975]
<b>Intercept</b>	11.0111	2.118	5.198	0.000	6.792	15.230
<b>treatment</b>	-5.0945	3.492	-1.459	0.149	-12.049	1.861
<b>severity</b>	2.3865	0.195	12.251	0.000	1.999	2.774
<b>hospital</b>	-4.1535	4.413	-0.941	0.350	-12.943	4.636

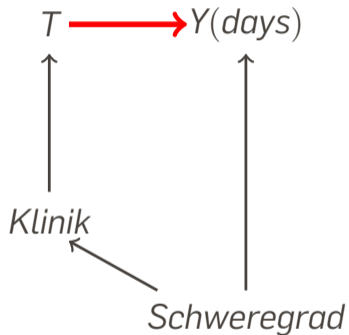
Aber das ist nicht sinnvoll...

## KAUSALGRAPH ZUM MEDIKAMENTENTEST



Back-Door-Kriterium:


## KAUSALGRAPH ZUM MEDIKAMENTENTEST



Back-Door-Kriterium:

- ▶ Der Schweregrad wirkt direkt auf die Behandlungsdauer.


## KAUSALGRAPH ZUM MEDIKAMENTENTEST



Back-Door-Kriterium:

- ▶ Der Schweregrad wirkt direkt auf die Behandlungsdauer.
- ▶ Er wirkt indirekt über die Klinikwahl auch auf die Behandlung  $T$

## KAUSALGRAPH ZUM MEDIKAMENTENTEST









Back-Door-Kriterium:

- ▶ Der Schweregrad wirkt direkt auf die Behandlungsdauer.
- ▶ Er wirkt indirekt über die Klinikwahl auch auf die Behandlung  $T$
- ▶ Wird jedoch der Schweregrad im Modell berücksichtigt, hat die Wahl der Klinik keinen zusätzlichen Einfluss auf  $T$

Vielen Dank für Ihre  
Aufmerksamkeit!

`thomas.neusius@hs-rm.de`

# WO GIBT'S MEHR DAVON?

-  Facure, M. (2022). *Causal Inference for The Brave and True*. URL: <https://matheusfacure.github.io/python-causality-handbook/landing-page.html> (besucht am 15.02.2023).
-  Greenland, S. und J. M. Robins (1986). "Identifiability, Exchangeability, and Epidemiological Confounding". In: *International Journal of Epidemiology* 15.3, S. 413–419. DOI: 10.1093/ije/15.3.413.
-  Greenland, S. und H. Morgenstern (2001). "Confounding in health research". In: *Annu Rev Public Health* 22, S. 189–212. DOI: 10.1146/annurev.publhealth.22.1.189.
-  McNamee, R (2003). "Confounding and confounders". In: *Occupational and Environmental Medicine* 60.3, S. 227–234. DOI: 10.1136/oem.60.3.227.
-  Morabia, A. (2011). "History of the modern epidemiological concept of confounding". In: *J Epidemiol Community Health* 65.4, S. 297–300. DOI: 10.1136/jech.2010.112565.
-  Pearl, J. und D. Mackenzie (2018). *The Book of Why*. Penguin.