



Counterfactual-Analyse

*Masterseminar WT 2020 an der Professur für
Wandel und Nachhaltigkeit*



Vorläufiger Zeitplan

Sitzung Nr.	Datum	Uhrzeit	Thema	Raum
1	14.01.2020	09:00-10:30	Theorie	36 / 1114
2	21.01.2020	09:00-10:30	Praxis	104 / 0117 PC-Pool 4
3	28.01.2020	09:00-10:30	Praxis	104 / 0117 PC-Pool 4
4	04.02.2020	09:00-10:30	Praxis	104 / 0117 PC-Pool 4
5	03.03.2020	09:00-10:30	Zwischenstand Probleme, Einzeltermine?	36 / 1117
6	31.03.2020	-	Abgabe Seminararbeit	36 / 1117



Ziele und Inhalte

- Vertiefung der bisher im Studium erworbenen theoretischen und praktischen Kenntnisse
- Praktische Anwendung (Analyse mithilfe von Daten)
- Umgang mit der Statistiksoftware STATA
- Theorie- und Praxisstunden
- Seminararbeit in 2er Gruppe (Umfang: 8-10 Seiten)
- Anwesenheit: sehr zu empfehlen!



Prüfungsleistung Seminararbeit

- Umfang: 8-10 Seiten (exklusive Referenzen)
 - Aufbau
 - Einleitung/Motivation
 - Forschungsfrage(n)- und ziele
 - Methode
 - Ergebnisse
 - Fazit
 - (Literaturverzeichnis)
- } ca. 50% der Arbeit



Counterfactual-Analyse – Theorie - Einleitung

Bennett (1987): Event Causation: The Counterfactual Analysis, S. 368:

The counterfactual analysis of event causation is one of the two offered by Hume. In its roughest, strongest form it says that

c caused e,

where c and e are individual events, means that e depended counterfactually on c, that is, that

If c had not occurred, e would not have occurred.



Counterfactual-Analyse – Theorie - Einleitung

- Idee: Identifizierung des kausalen Effekts eines *Treatments*:

Medikament → Blutdruck

Berufstraining → Arbeitslosigkeit

Werbekampagne → Umsatz

- Datenproblem: Es ist unmöglich beide Zustände bei einem Individuum zu beobachten. Wieso?



Counterfactual-Analyse – Theorie - Einleitung

- Mögliche Lösung: Experiment → **zufällige** Zuordnung des Treatments
- D.h. einziger Unterschied: Anwesenheit oder Abwesenheit des Treatments
- Isolierung des Treatment-Effekts theoretisch möglich
- Problem: hohe Kosten oder unethisch. Wieso?



Counterfactual-Analyse – Treatment-Effekt

- „Potential Outcome Model“ oder „Counterfactual Model“ → Rubin (1974), Holland (1986), etc.
- $y_i(1)$: Zustand von Individuum i mit Treatment
- $y_i(0)$: Zustand von Individuum i ohne Treatment
- (z.B. Jobtraining; unmöglich beide Zustände zu beobachten!)
- Differenz beider potentieller Zustände liefert den Treatment-Effekt (TE_i)
- $TE_i = y_i(1) - y_i(0)$



Counterfactual-Analyse – Treatment-Effekt

- Average Treatment Effect (ATE): durchschnittlicher Treatment-Effekt über die Gesamtmenge
- $ATE = E[TE_i] = E[y_i(1) - y_i(0)] = E[y_i(1)] - E[y_i(0)]$
- (Average Treatment Effect on the Treated: $ATET = E[y_i(1) - y_i(0) \mid t = 1]$; $t = 1$: treatment, $t = 0$: no treatment)
- (Potential Outcome Mean: $POM_t = E[y(t)]$)



Counterfactual-Analyse – Treatment-Effekt

- Wie lässt sich ATE schätzen? → Bezug zu OLS-Regression ($y_i = \alpha_0 + \beta_1 x_i + u_i$)
- $y_i = (1-x_i) y_i(0) + x_i y_i(1)$, x_i : Teilnahmestatus (1 oder 0)
- $y_i = y_i(0) + [y_i(1) - y_i(0)]x_i$
- Annahme: Konstanter TE für alle Individuen: $TE = y_i(1) - y_i(0)$
- $y_i = y_i(0) + TE x_i$



Counterfactual-Analyse – Treatment-Effekt


- $y_i = y_i(0) + TE x_i$
- Annahme: $y_i(0) = \alpha_0 + u_i(0)$ (und definitionsgemäß: $\alpha_0 = E[y_i(0)]$ und $E[u_i(0)] = 0$)
- $y_i = \alpha_0 + TE x_i + u_i(0)$
- Definition: $\alpha_0 = \beta_0$, $TE = \beta_1$ und $u_i(0) = u_i$
- $y_i = \alpha_0 + \beta_1 x_i + u_i$



Counterfactual-Analyse – Treatment-Effekt

- $y_i = \alpha_0 + \beta_1 x_i + u_i$
- Annahme für Unverzerrtheit des Schätzers (wie üblich für OLS)
 - Lineare Modellannahme
 - Zufällige Stichprobengröße
 - Variation in der erklärenden Variable
 - Zero Conditional Mean : $E[u_i | x_i] = 0$
- Problem für beobachtete Daten: diese können nicht mehr zufällig zugeordnet werden!
 - Bestimmte Schätzmethoden versuchen das Problem zu minimieren


Counterfactual-Analyse – Intuition



- Beide Gruppen haben einen Durchschnittswert von 160
- Hat das Medikament keine Wirkung?
- Schlussfolgerung nicht möglich. Warum?
- Keine zufällige Zuordnung von Treatment
- → Treatment ist evtl. abhängig von Variablen, welche auch den Blutdruck beeinflussen (z.B. Gewicht)

Quelle: STATA Manual (2015), S. 192


Counterfactual-Analyse – Intuition



- Annahme: Beobachtung aller potentiellen Zustände möglich (tatsächliche Beobachtungen (ausgemalt) und Counterfactuals (leer))
- $ATE = 182 - 137 = 45$

Quelle: STATA Manual (2015), S. 193

Counterfactual-Analyse – Intuition



- Verzerrende Schätzung ohne Counterfactual Szenario
- Beobachteter Durchschnitt der Untreated wird unterschätzt (160 vs. 182)
- Beobachteter Durchschnitt der Treated wird überschätzt (160 vs. 137)

Quelle: STATA Manual (2015), S. 193



Counterfactual-Analyse – Intuition

- Die Schätzung von ATE ist im wesentlichen ein Problem fehlender Daten
- Sobald es Variablen gibt, welche sowohl mit dem Treatment (X) als auch mit dem potentiellen Zustand (Y) zusammenhängen (informative Daten), kann nicht einfach die Differenz der Durchschnittswerte genommen werden
- Die folgenden Schätzer nutzen gezielt diese Zusammenhänge weiterer Variablen aus und versuchen so das Problem einer fehlenden zufälligen Datenlage zu lösen



Counterfactual-Analyse – Schätzmethoden


- Regression Adjustment (RA)
- Inverse Probability Weighting (IPW)
- Kombination RA und IPW
- Matching
- Synthetic Counterfactuals (SC)



Counterfactual-Analyse – Regression Adjustment (RA)

- Die RA-Methode erweitert die Idee den TE mithilfe simpler Durchschnittswerte zu schätzen
- Vorhersage potentieller Zustände durch beeinflussende Variablen mithilfe eines Regressionsmodells
- Beispiel: Welchen (kausalen) Effekt hat Rauchen während der Schwangerschaft auf das Geburtsgewicht des Kindes


Counterfactual-Analyse – Regression Adjustment (RA)



- Was fällt auf?
- Warum reicht nicht die simple Differenz der Beobachtungen?

Quelle: STATA Manual (2015), S. 194

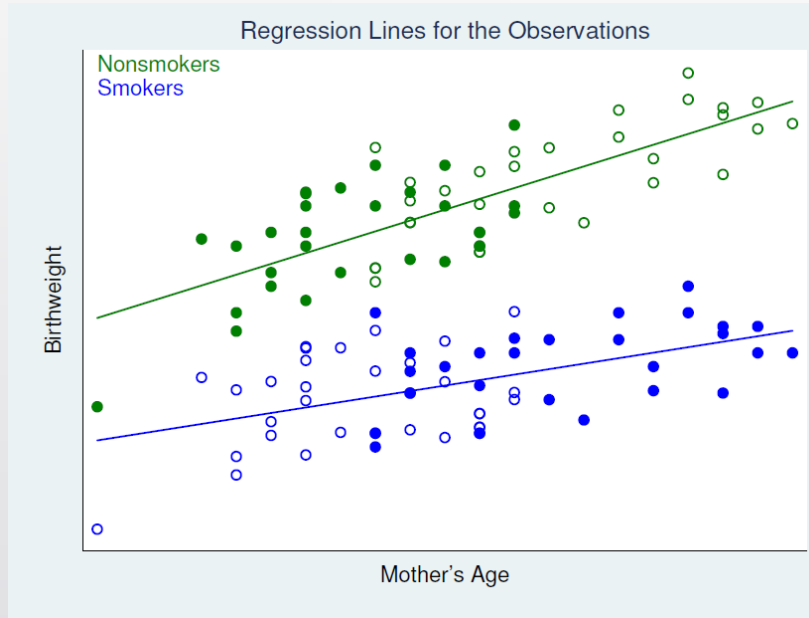
Counterfactual-Analyse – Regression Adjustment (RA)



- Lineare Regression des beobachteten Körpergewichts anhand des **Alters** für Nichtraucher
- Lineare Regression des beobachteten Körpergewichts anhand des **Alters** für Raucher

Quelle: STATA Manual (2015), S. 195

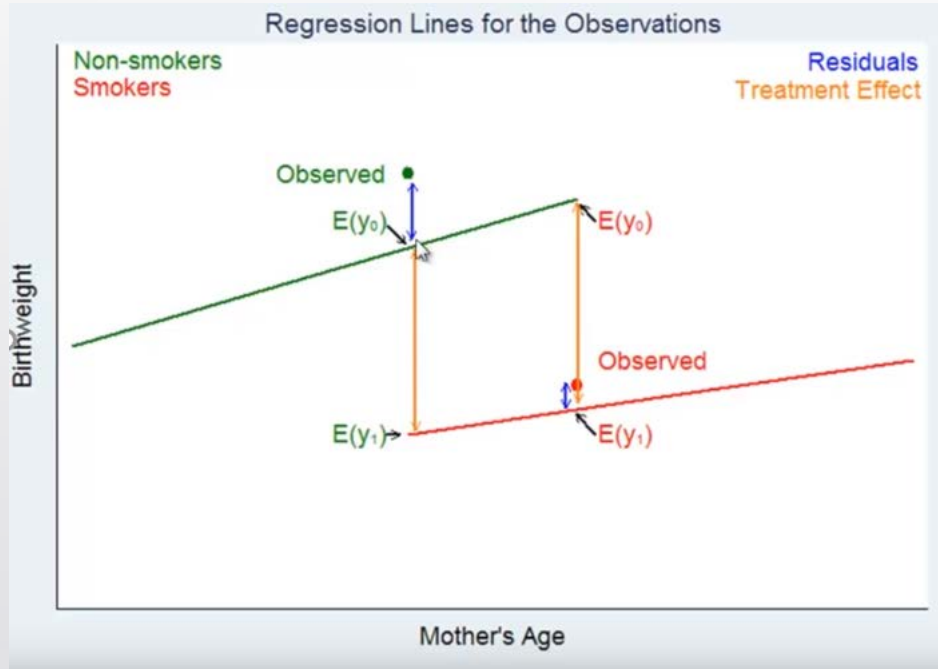
Counterfactual-Analyse – Regression Adjustment (RA)



- Lineare Regression des beobachteten Körpergewichts anhand des Alters für Nichtraucher
- Lineare Regression des beobachteten Körpergewichts anhand des Alters für Raucher

Quelle: STATA Manual (2015), S. 195


Counterfactual-Analyse – Regression Adjustment (RA)



Quelle: www.youtube.de

- TE: Differenz zwischen den beiden Regressionsgeraden
- ATE: Durchschnitt der Differenzen aller Beobachtungen
- Was bedeutet die unterschiedliche Steigung der Geraden (Interaktionsterm bei klassischer Regression nötig!)?

Counterfactual-Analyse – Inverse Probability Weigthing (IPW)



- Die IPW-Methode versucht anhand gewichteter Durchschnitte den Effekt des Treatments von weiteren beeinflussenden Variablen zu trennen
- Hierfür wird die Wahrscheinlichkeit, dass ein Treatment realisiert wird, geschätzt
- Diese (inversen) Wahrscheinlichkeiten für die Gewichtung werden anhand einer Funktion, welche das Treatment anhand beeinflussender Variablen beschreibt, ermittelt

Counterfactual-Analyse – Inverse Probability Weigthing (IPW)

```
. logistic mbsmoke mage
Logistic regression           Number of obs   =        60
                               LR chi2(1)       =       30.45
                               Prob > chi2      =       0.0000
                               Pseudo R2       =       0.3661
Log likelihood = -26.362201
```


mbsmoke	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
mage	1.631606	.21316	3.75	0.000	1.263022 2.107754
_cons	7.76e-06	.0000243	-3.76	0.000	1.69e-08 .0035718

Note: _cons estimates baseline odds.

Quelle: STATA Manual (2015), S. 197

- Logistische Regression (da abhängige Variable diskret) zur Ermittlung der Wahrscheinlichkeit Raucher zu sein (treated)
- Hier: nur Alter wird mitberücksichtigt
- Gewichtung für Raucher: Inverse der vorhergesagten Wahrscheinlichkeit Raucher zu sein
- Somit wird der verzerrende Einfluss des Alters (da das Alter sich sowohl auf den Raucherstatus als auch auf das Geburtsgewicht bezieht) mitberücksichtigt

Counterfactual-Analyse – Inverse Probability Weigthing (IPW)



Quelle: STATA Manual (2015), S. 197

- Punkte sind proportional zur Gewichtung der jeweiligen Beobachtung
- Die größten blauen Punkte gehören zu den jüngsten Raucherinnen, welche damit am meisten Gewichtung bekommen bei der Berechnung des Durchschnittsgewichts der Babys von Raucherinnen
- Grüne Punkte?
- Vorsicht bei kleinen Wahrscheinlichkeiten !



Counterfactual-Analyse – Kombination von RA und IPW

- RA: lineare Regression um Vorhersage des Outputs eines jeden Individuums zu treffen; sagt nichts darüber aus wie Treatment zustande kommt
- IPW: logistische Regression um Treatment-Status vorherzusagen; kein formales Model über den Output eines Individuums
- Kombination beider Elemente: Augmented Inverse-Probability-Weighted (IPW) und Inverse-Probability-Weighted Regression-Adjustment (IPWRA) Schätzer
- Robust gegen Fehlspezifikationen der einzelnen Schätzer



Counterfactual-Analyse – Matching

- Idee: Vergleich zwischen möglichst identischen Individuen (bis auf den Treatment-Status)
- Bsp.: zwei gleichaltrige Mütter mit Unterschied Raucherin oder Nichtraucherin
- Komplexität steigt mit der Anzahl zu beachtender Variablen
- Annäherung an Vergleich zwischen möglichst gleichen Individuen
- Nearest-Neighbor Matching (NNM) und Propensity-Score Matching



Counterfactual-Analyse – Matching

- Nearest-Neighbor Matching (NNM) und Propensity-Score Matching
- NNM: Schätzen von Distanzen zwischen Beobachtungen im Hinblick auf Kovariablen; danach werden die Beobachtungen mit den geringsten Distanzen für den Vergleich „gematcht“
- PSM: Schätzen der Vergleichbarkeit zweier Beobachtungen aufgrund deren Vorhergesagte Wahrscheinlichkeit des Treatments durch Kovariablen (i.e. propensity scores)



Counterfactual-Analyse - Annahmen

- Independent and identically distributed (i.i.d.): Output und Treatment-Status der Beobachtungen sind unabhängig von allen anderen Beobachtungen in der Gesamtmenge (Problem bei Paneldaten)
- Conditional-Independence (CI): nachdem für alle beobachtbaren Variablen kontrolliert worden ist gilt, dass die Potential Outcomes unabhängig vom Treatment sind (Beispiel: Gesundheitsbewusstsein)
- Overlap: Jede Beobachtung muss eine positive Wahrscheinlichkeit für Treatment besitzen (Bsp. Junge Mütter haben wohl keine positive Wahrscheinlichkeit Raucher zu sein)



Counterfactual-Analyse – Synthetic Counterfactuals (SC)

- SC erlaubt die Variation unbeobachteter Effekte über die Zeit
 - Analyse von Auswirkungen bestimmter Ereignisse über mehrere Jahre möglich (Paneldaten!)
- Erweiterung des Difference-in Difference Schätzers (zwei Perioden):

$$TE = (y_2(1) - y_1(1)) - (y_2(0) - y_1(0))$$

- Abadie, Diamond und Hainmüller (2010): Synthetic Control Approach



Counterfactual-Analyse – Synthetic Counterfactuals (SC)

- Abadie, Diamond und Hainmüller (2010): Synthetic Control Approach
- Schätzung des Effekts einer Intervention/Treatment (z.B. Sparmaßnahmen) anhand der Entwicklung bestimmter Variablen (z.B. BIP pro Kopf)
- Idee: Counterfactual-Szenario (i.e. synthetic control group) wird anhand einer Kombination von *mehreren* Einheiten (Individuen, Länder, etc.) konstruiert (z.B.: eine Kombination von mehreren Ländern kann sich besser der Entwicklung eines Landes annähern)
- Kontrollgruppe: Gewichtete Kombination mehrerer Einheiten ohne Treatment;
Ziel: Kontrollgruppe soll möglichst den Verlauf der Variablen der betroffenen Einheit abbilden;
Maßstab: Set von erklärende Variablen des Outputs (längere Pre-Treatment-Periode erlaubt eine bessere Kalibrierung der synthetischen Kontrollgruppe)

Counterfactual-Analyse – Synthetic Counterfactuals (SC)

- 1. Schritt: Konstruktion eines Gewichtungsvektors W^* , der die „Distanz“ der Variablen (zur Schätzung des Outputs Y) zwischen Treatment-Einheit (X_1) und restlichen Einheiten (X_C) minimiert (Pre-Treatment!)

$$\min(X_1 - X_C W) \mathcal{V}(X_1 - X_C W)$$

- 2. Schritt: Der Treatment-Effekt ist die Differenz der Outputs zwischen der betroffenen Einheit (Y_{1t}) und dem gewichteten Durchschnitt der nicht betroffenen Einheiten ($\sum_{i=2}^{N+1} w_i^* Y_{it}$)

$$TE_{it} = Y_{1t} - \sum_{i=2}^{N+1} w_i^* Y_{it}, \forall t \geq T_0$$




Counterfactual-Analyse – SC – Annahmen und Grenzen

- Auswahl an Pre-Treatment Charakteristika soll Variablen beinhalten, welche die Entwicklung des Outputs der betroffenen Einheit annähern können; es sollten keine Variablen enthalten sein, welche das Treatment antizipieren
- Die Vergleichseinheiten (Länder, etc.), welche für die Kontrollgruppe verwendet werden, dürfen nicht durch das Treatment beeinflusst werden
- SC erlaubt oftmals keine etablierten Signifikanztests, da die Anzahl von Beobachtungen oftmals klein ist (andere Testweisen !)


Counterfactual-Analyse – SC - Beispiele

Einführung Proposition 99 in Kalifornien (1988)



Quelle: Abadie et al. (2010), S. 499

EU-Beitritt Großbritannien (1973)



Quelle: Campos et al. (2013), S. 32



Weiteres Vorgehen

- Kommende Praxisstunden
 - Grundlagen STATA
 - Praktisches Schätzen der heutigen Beispiele
 - Replikation Forschungsliteratur



Weiteres Vorgehen

- Bis zum nächsten Mal
 - 2er Gruppen
 - Themenvorschläge (z.B. Auswirkungen auf die Umwelt durch ein bestimmtes Ereignis) mit Blick auf Datenlage und Umfang und Schätzmethode
 - Installation STATA?



Literatur

- Abadie, A., Diamond, A., & Hainmueller, J. (2010). Synthetic control methods for comparative case studies: Estimating the effect of California's tobacco control program. *Journal of the American statistical Association*, 105(490), 493-505.
- Bennett, J. (1987). Event causation: The counterfactual analysis. *Philosophical perspectives*, 1, 367-386.
- Campos, N. F., Coricelli, F., & Moretti, L. (2014). Economic growth and political integration: estimating the benefits from membership in the European Union using the synthetic counterfactuals method.
- Holland, P. W. (1986). Statistics and causal inference. *Journal of the American statistical Association*, 81(396), 945-960.
- Rubin, D. B. (1974). Estimating causal effects of treatments in randomized and nonrandomized studies. *Journal of educational Psychology*, 66(5), 688.
- StataCorp. (2017). *Stata 15 Base Reference Manual*. College Station, TX: Stata Press.
- Wooldridge, J. M. (2016). *Introductory econometrics: A modern approach*. Nelson Education.