

Volkswirtschaftliches Seminar (BW37)

Wintersemester 2023/24

Prof. Dr. Jannis Kück

Seminar "Causal Inference"

Inhalt:

Wird mehr Bildung mein Gehalt oder das von anderen erhöhen? Verringert eine härtere Bestrafung die Kriminalität? Arbeiten Mütter mehr, wenn die Kinderbetreuung kostenlos ist? Gesellschaftlich relevante Fragen, die die Politik, das Arbeitsleben, die Gesundheit und die Gesellschaft im Allgemeinen betreffen, sind häufig kausaler Natur. Im Rahmen des Seminars soll eine Einführung gegeben werden, wie solche kausalen Fragestellungen analysiert werden können. Die Grundlage dafür bietet das Buch "Causal Analysis - Impact Evaluation and Causal Machine Learning with Applications in R".

Content:

Will more education increase my salary or that of others? Does harsher punishment reduce crime? Do mothers work more if childcare is for free? Socially relevant questions concerning politics, work life, health, and society in general are often causal. The seminar will provide an introduction to how such causal effects can be analyzed.

Zielgruppe / Target group: B.Sc. VWL / B.Sc. BWL / B.A.PPE

Voraussetzungen / Prerequisite: BS01, BS02, BS03

Maximale Anzahl an Studierenden / Maximum number of students: 10

Prüfung / Examination: Seminararbeit 10-12 Seiten (50%), Präsentation und Diskussion (50%)

Themen / Topics:

1. Kausalität oder keine Kausalität – Ein Überblick / Causality or no causality – An overview

Es soll eine Einführung in das Konzept der Kausalität gegeben werden. Darüber hinaus soll in der Seminararbeit ein Überblick über verschiedene Methoden gegeben werden, wie kausale Effekte gemessen werden können.

2. Randomisierte Experimente und kausale Inferenz / Social experiments and causal inference

Die wohl intuitivste Methode zur Kausalanalyse sind randomisierte Experimente. Dabei wird das Treatment nach dem Zufallsprinzip zugewiesen, sodass Unterschiede in den durchschnittlichen Outcomes zwischen Treatment und Non-treatment Gruppe glaubhaft auf das Treatment zurückgeführt werden können. Die Erörterung der experimentellen Schätzung der Unterschiede in den durchschnittlichen Outcomes basiert auf der linearen Regression, einer der gängigsten Methode in der Statistik.

3. Kausale Inferenz unter Einbezug von Kovariaten / Causal Inference under selection on observables

Es werden verschiedene Methoden für die Kausalanalyse unter der sogenannten „selection-on-observables-assumption“ vorgestellt, wie regression, matching, weighting and doubly robust estimators. Die Idee dieser Ansätze besteht darin, nur die Outcomes von Probanden mit Treatment mit jenen ohne zu vergleichen, die in Bezug auf die Kovariaten ähnlich sind. Das Ziel ist es den experimentellen Kontext mit Hilfe der beobachteten Informationen zu imitieren.

4. Causal Machine Learning

Beim Causal Machine Learning werden maschinelle Lerntechniken verwendet, um kausale Effekte zu identifizieren. Unter der „selection-on-observables-assumption“ können solche kausalen maschinellen Algorithmen lernen, welche Kovariaten das Treatment und den Outcome maßgeblich beeinflussen. Dies ist angesichts der fortschreitenden Digitalisierung und der immer größeren Verfügbarkeit von Daten und beobachteten Kovariaten nützlich.

5. Instrumentvariablen für kausale Inferenz / Instrumental variables for causal inference

Die Instrumentvariablenschätzung ist eine Methode in der kausalen Inferenz, die verwendet wird, um den kausalen Effekt einer Treatment ähnlichen Variable auf den Outcome zu schätzen, wenn es zu Endogenitätsproblemen kommt. Endogenität tritt auf, wenn die Treatment Variable mit dem Fehlerterm korreliert.

6. Differenz-von-Differenzen-Ansatz / Difference-In-Differences approach

Bei diesem Ansatz wird der interessierende Outcome im Zeitverlauf beobachtet, das heißt vor und nach Einführung eines Treatments für eine bestimmte Gruppe. Der Differenz-von-Differenzen-Ansatz basiert auf der Annahme, dass sich die Outcomes der Gruppen mit und ohne Treatment im Laufe der Zeit gleich entwickelt hätten. Zudem werden Erweiterungen dieses Ansatzes betrachtet.

7. Synthetische Kontrollmethode / Synthetic control method

Dies ist ein Ansatz der auf der Beobachtung des Outcomes vor und nach Einführung des Treatments beruht und ursprünglich für Fallstudien mit nur einer Einheit im Treatment und vielen Einheiten ohne Treatment entwickelt wurde. Er basiert auf der Differenz zwischen dem Outcome der Einheit mit Treatment und einem gewichteten Durchschnitt der Outcomes der Einheiten ohne Treatment.

8. Regression Discontinuity, Kink, and Bunching Design

Das Regression Discontinuity Design zielt darauf ab den experimentellen Kontext eines zufällig zugewiesenen Treatments bei einem bestimmten Schwellenwert, die den Zugang zum Treatment bestimmt, nachzuahmen. Das Regression Kink Design hingegen ist nützlich, um kausale Schätzungen zu erhalten, wenn eine größtenteils differenzierbare kontinuierliche Variable Knicke in der ersten Ableitung aufweist. Das Bunching Design berücksichtigt den Fall, dass die Probanden selbst auswählen können, ob sie über oder unter dem Schwellenwert liegen (z.B. bestimmte Einkommenssteuerklasse in Abhängigkeit von der Beschäftigung).

9. Partielle Identifikation und Sensitivitätsanalyse / Partial identification and sensitivity analysis

Die partielle Identifikation bezieht sich auf ein Szenario, in dem ein kausaler Effekt nicht eindeutig auf einen einzigen Wert festgelegt werden kann, sondern nur innerhalb eines bestimmten Intervalls oder einer Menge möglicher Werte liegt. Dabei werden schwächere oder gar keine statistischen Annahmen zugrunde gelegt. Die Sensitivitätsanalyse hingegen bewertet die Robustheit der kausalen Effekte gegenüber geringfügigen oder sogar stärkeren Abweichungen von den Standard Annahmen.

10. Bewertung des Treatments bei Interferenzeffekten / Treatment evaluation under interference effects

Interferenz- oder Spillover-Effekte werden nicht mehr ausgeschlossen, sodass der Outcome eines Probanden in einer Population durch das Treatment eines anderen Probanden beeinflusst werden kann.

Hauptliteratur / Main literature:

Huber (2023): Causal Analysis - Impact Evaluation and Causal Machine Learning with Applications in R.

Weitere Literatur / Further literature:

Hastie, Tibshirani & Friedman (2009): The Elements of Statistical Learning – Data Mining, Inference, and Prediction.

Cunningham (2021): Causal Inference – The Mixtape.

Hernan & Robins (2020): Causal Inference – What if.

Pearl, Glymour & Jewell (2016): Causal Inference in Statistics – A Primer.