


Bachelor-/Masterarbeit

Analyse des Lernverhaltens von Deep-Learning-Modellen hinsichtlich kausaler Zeitstrukturen



Ausgangslage

Moderne Deep-Learning-Modelle erzielen in der Zeitreihenvorhersage hohe Prognosegenauigkeiten und werden in zahlreichen Anwendungsbereichen eingesetzt. Der Erfolg dieser Verfahren basiert auf dem Erlernen komplexer Muster aus historischen Daten. Für den zuverlässigen Einsatz solcher Modelle ist es jedoch wichtig zu verstehen, welche Informationen die Vorhersagen tatsächlich beeinflussen und wie robust die erlernten Zusammenhänge sind.

Problemstellung

Trotz der hohen Vorhersagegenauigkeit moderner Deep-Learning-Modelle ist bislang weitgehend ungeklärt, ob diese tatsächlich zugrunde liegende kausale Strukturen lernen oder primär statistische Korrelationen ausnutzen. Insbesondere fehlen systematische Untersuchungen dazu, wie verschiedene Modellarchitekturen mit kausalen Zusammenhängen und Confoundern umgehen und welche Auswirkungen dies auf ihr Vorhersageverhalten hat.

Vorgehensweise und erwartete Ergebnisse

Ziel dieser Arbeit ist es, das Lernverhalten verschiedener Deep-Learning-Modelle hinsichtlich kausaler Zeitstrukturen systematisch zu untersuchen. Hierzu sollen verschiedene Modellarchitekturen auf Datensätzen mit bekannter Kausalstruktur analysiert und hinsichtlich ihrer Vorhersageleistung, ihrer Nutzung von Confoundern sowie ihrer Sensitivität gegenüber Störungen entlang kausaler Abhängigkeiten verglichen werden.

Im Rahmen der Arbeit sollen insbesondere folgende Fragestellungen untersucht werden:


- In welchem Umfang lernen verschiedene Deep-Learning-Modelle die zugrunde liegenden kausalen Strukturen eines Systems?
- Wie stark unterscheiden sich verschiedene Modellarchitekturen hinsichtlich ihrer Nutzung von kausalen Zusammenhängen und Confoundern?
- Welche Auswirkungen haben Eingriffe entlang der kausalen Kette auf die Vorhersageleistung der Modelle?
- Besteht ein Zusammenhang zwischen Vorhersagegenauigkeit und der Fähigkeit eines Modells, kausale Strukturen zu erfassen?

Ansprechpartner

Jan Voets | **E-Mail:** voets@uni-wuppertal.de

Bachelor's / Master's Thesis

Analyzing the Learning Behavior of Deep Learning Models with Respect to Causal Time-Series Structures



Initial Situation

Modern deep learning models achieve high forecasting accuracy in time series prediction and are widely used across numerous application domains. The success of these methods is based on their ability to learn complex patterns from historical data. However, for the reliable deployment of such models, it is important to understand which information actually influences their predictions and how robust the learned relationships are.

Problem Definition

Despite the high predictive accuracy of modern deep learning models, it remains largely unclear whether these models actually learn underlying causal structures or primarily exploit statistical correlations. In particular, there is a lack of systematic investigations into how different model architectures handle causal relationships and confounding factors, and how these aspects affect their forecasting behavior.

Methods and Expected Results

The aim of this thesis is to systematically investigate the learning behavior of different deep learning models with respect to causal temporal structures. To this end, various model architectures will be analyzed on datasets with known causal structures and compared in terms of their predictive performance, their reliance on confounding factors, and their sensitivity to perturbations along causal dependencies.

In particular, the following research questions will be investigated:

- To what extent do different deep learning models learn the underlying causal structures of a system?
- How do different model architectures differ in their reliance on causal relationships and confounding factors?
- What impact do interventions along the causal chain have on the predictive performance of the models?
- Is there a relationship between predictive accuracy and a model's ability to capture causal structures?

Contact Person

Jan Voets | **E-Mail:** voets@uni-wuppertal.de