

## Datenmanagement & -analyse

### Übung 9 – Maschinelles Lernen: Von der Erklärung zur Prädiktion

Dr. Nikolai Stein

Lehrstuhl für WI & BA

Julius-Maximilians-Universität Würzburg

Sommersemester 2021




## Recap: Lineare Regression

- Ziel: Erklärung der Varianz in der Zielvariablen durch Linearkombination unabhängiger Variablen
  - Zugehöriges Gütemaß:  $R^2$
  - Interpretation der Ergebnisse durch Koeffizienten und deren Signifikanz
- Probleme:
  - $R^2$  ist monoton wachsend in der Anzahl unabhängiger Variablen
    - Robustheit des geschätzten Modells nicht gegeben
    - Generalisiert es auf unbekannte Datensätze?
  - Lineare Struktur für komplexe Zusammenhänge zu limitiert
- Möglichkeiten mit diesem Problem umzugehen?
  - Ökonometrie: andere Modellspezifikationen (robuste Standardfehler), Variablentransformation,
  - **Maschinelles Lernen / prädiktive Analyse:**
    - Lernen als zugrunde liegendes Paradigma (Verallgemeinerung)
    - Vielzahl unterschiedlicher Verfahren stehen zur Verfügung
    - Management des Bias-Varianz-Tradeoffs

## What is Machine Learning?

- Tom Mitchell: “A computer program is said to learn from experience  $E$  with respect to some class of tasks  $T$  and performance measure  $P$ , if its performance at tasks in  $T$ , as measured by  $P$ , improves with experience  $E$ .”




## Why let machines “learn”?

- There is no need to “learn” how to calculate the payroll
- Learning is used when:
  - Human expertise does not exist (navigating on Mars),
  - Humans are unable to explain their expertise (speech recognition)
  - Solution changes in time (traffic routing)
  - Solution needs to be adapted to particular cases (user biometrics)

## Klassische Programmierung



## Maschinelles Lernen



- „Automatisierung automatisieren“
- Computer dazu bringen, sich selbst zu programmieren
- Lassen Sie stattdessen die Daten die Arbeit machen!

## Verschiedene Formen des maschinellen Lernen


Heute



- Überwachtes Lernen
    - Trainingsdaten enthalten gewünschte Ausgaben
  - Unüberwachtes Lernen
    - Trainingsdaten enthalten nicht die gewünschten Ausgaben
  - Reinforcement Learning
    - Lernen aus einer Folge von Aktionen und Belohnungen
- Auf Basis von Trainingsdaten  $(X, Y)$  eine Funktion  $X \mapsto Y = f(x)$  bestimmen
  - Die Funktion soll zuverlässig  $Y$ -Werte für neue Datenpunkte  $X$  bestimmen
    - Diskrete Funktion  $f(x)$ : Klassifikation
    - Kontinuierliche Funktion  $f(x)$ : Regression

## Vorteile von Entscheidungsbäumen

Titanic: Wurden Frauen und Kinder zuerst gerettet?



- Relativ schnell im Vergleich zu anderen Klassifikationsmodellen
- Erzielt oft gute Genauigkeit im Vergleich zu anderen Modellen
- Einfach und leicht zu verstehen
- Kann in einfache und leicht verständliche Klassifikationsregeln umgewandelt werden


## Wie werden Entscheidungsbäume erzeugt?



Splittingregel bestimmen (Attribut und Schwellwert)




Datensatz mithilfe der Splittingregel in disjunkte Teildatensätze aufteilen



So lange wiederholen bis Teildaten ausreichend rein sind


## Unteranpassung



- Zu einfach
- Bereits die Trainingsdaten können nicht gut klassifiziert werden



## Überanpassung




- Sehr kompliziert
- Trainingsdaten werden perfekt gelernt
- Verallgemeinerbar??

## Verzerrung-Varianz-Tradeoff

Unteranpassung  
Underfitting

Überanpassung  
Overfitting



### Strategien zur Vermeidung von Überanpassung

- Testdatenmanagement
- Regularisierung
- Ensemblemethoden