

Wirtschaftswissenschaftliche Fakultät Institut für Empirische Wirtschaftsforschung Bereich Statistik

Prof. Dr. Roland Schuhr

#### Modul 07-202-2302

# **Multivariate Datenanalyse und Data Mining**

Sommersemester 2023

30.03.2023

Dozent / Übungsleiter:

Roland Schuhr

Umfang / Beginn:

6 SWS / 05.04.2023, 13:15 - 14:45, PC-Pool 4

Vorlesung:

On Demand E-Learning-Videos im Umfang von ca. 4 SWS. Die E-Learning-Einheiten werden durch vier (optionale) Q&A-Stunden ergänzt:

Montag, 11:15 – 12:45, SR 5 (unregelmäßiger Turnus)

Übung:

Computer-Übung im Umfang von 2 SWS:

Mittwoch, 13:15-14:45, PC-Pool 4+BBB-Konferenz

Zielgruppe:

Studierende wirtschaftswissenschaftlicher Master-Studiengänge und des Studiengangs M.Sc. Data Science mit Interesse an quantitativer Marketingforschung, Knowledge Discovery in Databases, Business Intelligence sowie empirischer Wirtschaftsforschung.

Inhalt:

Unter Begriffen wie Data Mining, Knowledge Discovery in Databases oder Business Intelligence subsumiert man Strategien, Methoden und Techniken der Exploration wirtschaftlich verwertbarer, zunächst verborgener Information in großen Datenbeständen (Big Data) mit dem Ziel der Entwicklung neuer Geschäftsmöglichkeiten für Unternehmen. Die verwendeten datenanalytischen Methoden haben ihre Wurzeln meist in der Multivariaten Statistik oder in dem zum interdisziplinären Forschungsfeld Artificial Intelligence gehörigen Bereich des Machine Learning.

Die Lehrveranstaltung stellt typische Fragenstellungen des Data Mining und ausgewählte Analysemethoden der Multivariaten Statistik und des Machine Learning vor. Im Vordergrund stehen die methodischen Grundlagen der Dimensionsreduktion/ Feature Extraction sowie der Klassifikation und Diskrimination von empirischen Objekten. In Computer-Übungen werden Datensätze aus Fallbeispielen mit Hilfe der Statistik-Software R analysiert.

## Gliederung:

- 1. Multivariate Daten und Wahrscheinlichkeitsverteilungen
- 2. Dimensionsreduktion/ Feature Extraction: Hauptkomponenten- und Faktorenanalyse
- 3. Clusteranalyse (hierarchische Verfahren, k-means, Fuzzy-Verfahren, mclust)
- Lineare Diskriminanzanalyse und multivariate Varianzanalyse, Nearest Neighbor-Diskrimination
- 5. Entscheidungsbäume (ID3, C4.5/C5.0, CART, Bagging und Boosting)
- 6. Künstliche Neuronale Netze (MLP, Autoencoder, Deep-Learning, SOM)

Universität Leipzig

Wirtschaftswissenschaftliche Fakultät

Institut für Empirische Wirtschaftsforschung Grimmaische Straße 12 04109 Leipzig

Telefon

+49 341 97-33 530

Fax

+49 341 97-33 789

E-Mail

schuhr@wifa.uni-leipzig.de

Web

www.wifa.uni-leipzig.de/iew

Postfach intern 171401

Kein Zugang für elektronisch signierte sowie für verschlüsselte elektronische Dokumente



Wirtschaftswissenschaftliche Fakultät Institut für Empirische Wirtschaftsforschung Bereich Statistik

Prof. Dr. Roland Schuhr

#### Literatur:

Berk, R.A.: Statistical Learning from a Regression Perspective; Springer 2008

Bishop, C.M.: Neural Networks for Pattern Recognition; Oxford University Press 1995

Burkov, A.: The hundred-page machine learning book; Andriy Burkov 2019

http://themlbook.com/wiki/doku.php

http://themlbook.com/wiki/doku.php?id=start&do=index

https://freecomputerbooks.com/The-Hundred-Page-Machine-Learning-Book.html

Chapman, C. & E. McDonnell Feit: R for Marketing Research and Analytics; Springer 2015

Cios, K.J., Pedrycz, W., Swiniarski, R.W. & L.A. Kurgan: *Data Mining. A Knowledge Discovery Approach*; Springer 2007

Fahrmeir, L., A. Hamerle & G. Tutz (Hrsg.): Multivariate statistische Verfahren, 2. Aufl.; de Gruyter 1996

Han, J., Kamber, M. & J. Pei: Data mining. Concepts and techniques, 3<sup>rd</sup> ed.; Morgan Kaufmann 2011

Handl, A. & T. Kuhlenkasper: Multivariate Analysemethoden. Theorie und Praxis mit R, 3.Aufl; Springer 2017

Hastie, T., Tibshirani, R. & J. Friedman: *The elements of statistical learning. Data mining, inference, and prediction, 2<sup>nd</sup> ed.*; Springer 2017

James, G., Witten, D., Hastie, T. & R. Tibshirani: An Introduction to statistical learning with applications in R, 2<sup>nd</sup> ed.; Springer 2021

Lantz, B.: Machine Learning with R, 2<sup>nd</sup> ed.; Packt Publishing 2015

Michie, D., D.J. Spiegelhalter & C.C. Taylor (Eds.): Machine learning, neural and statistical classification; Ellis Horwood 1994

http://www1.maths.leeds.ac.uk/~charles/statlog/

Mitchell, T.M.: Machine Learning; McGraw-Hill 1997 http://www.cs.cmu.edu/~tom/mlbook.html

## Erwartete Grundkenntnisse:

Gute Kenntnisse in Wahrscheinlichkeitsrechnung, Statistik und linearer Algebra

## Modulprüfung:

Klausur (90 Minuten)

## moodle-Lernplattform:

Kursteilnehmer können auf Lehrmaterialien und aktuelle Mitteilungen zur Vorlesung und Übung über die Lernplattform Moodle zugreifen.

Der Link des moodle-Kurses wird den Kursteilnehmern zu Beginn des Semesters in AlmaWeb mitgeteilt.