

Themenliste für das Seminar “Algorithmische und statistische Methoden der Zeitreihenanalyse”

Lehrstuhl für Angewandte Statistik
FernUniversität in Hagen

Wintersemester 2026/27

Überblick

Der Lehrstuhl für Angewandte Statistik betreut im Wintersemester 2026/27 Seminararbeiten im Bereich der angewandten Zeitreihenanalyse. Die Seminarvorträge werden gemeinsam mit dem Lehrgebiet Data Science von Professor Beecks abgehalten. Prof. Beecks bietet ein gleichnamiges Seminar für Studierende der Fakultät Mathematik und Informatik an. Ein Ziel dieses Seminars ist der interdisziplinäre Austausch der Studierenden beider Fakultäten. Die Methoden werden auf reale Zeitreihendaten angewendet, insbesondere aus der Makroökonomik und Finanzwirtschaft. In begleitenden Tutorien, die voraussichtlich im Oktober und Anfang November stattfinden, wird eine Einführung in die Programmierung mit R sowie in die Arbeit mit ökonomischen Zeitreihendaten gegeben. Zudem erfolgt eine Einführung in die Literaturrecherche durch die Universitätsbibliothek. Im Rahmen der einzelnen Themen erarbeiten die Studierenden eigenständig die zugrunde liegenden Methoden und führen darauf aufbauend empirische Analysen durch. Die Verwendung der Open-Source-Software R wird dabei nachdrücklich empfohlen (<https://www.fernuni-hagen.de/angewandte-statistik/lehre/software.shtml>).

Terminübersicht

- **Einführungsveranstaltung:** 06.10.2026, 12:00–13:00 Uhr per Zoom
- **Schulung zum wissenschaftlichen Arbeiten:** tbd per Zoom
- **Abgabe der Themenpräferenzen:** 11.10.2026 23:59 Uhr
- **Themenzuteilung:** 12.10.2026
- **R-Tutorien:** im Oktober und Anfang November per Zoom
- **Abgabe der Gliederung:** 08.11.2026
- **Abgabe der Seminararbeit:** 13.01.2027 23:59 Uhr
- **Seminarvorträge:** 27.01.2027–29.01.2027, jeweils zwischen 09:30–18:00 Uhr per Zoom

(Änderungen und Irrtümer vorbehalten)

Basisliteratur

Die folgenden Lehrbücher bilden die Basisliteratur des Seminars:

- James, G., Witten, D., Hastie, T., and Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications in R*. Springer, 2nd edition
- Hastie, T. and Tibshirani, Robert, F. J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2nd edition

Themenvorschläge

1. Anomaly Detection

Anomaly detection befasst sich mit der Herausforderung, deutliche Abweichungen von der Modellstruktur zu erkennen und als solche zu klassifizieren. Typischerweise unterstellt man für den datengenerierenden Prozess z. B. konstante Parameter und eine Normalverteilung der Innovationen. Starke Abweichungen, die als Ausreißer oder allgemeiner als Anomalien bezeichnet werden können, haben im Allgemeinen einen sehr starken Einfluss auf die Modellierung, Schätzergebnisse und Prognosen. Zwei der gängigen Verfahren stehen in diesem Seminar zur Verfügung: Zum einen “Indicator Saturation”, zum anderen “Collective and Point Anomaly”. In der Seminararbeit sollen die Grundideen und eines der beiden Verfahren eingeführt, kritisch beleuchtet und anschließend empirisch angewendet werden.

- **R-Pakete:** `gets`, `CAPA`
- **Einstiegsliteratur:** Pretis et al. (2018), Fisch et al. (2024)

2. Classification

Die Prognose ökonomischer oder finanzwirtschaftlicher Regime kann als Klassifikationsproblem verstanden werden, bei dem diskrete Zustände wie Rezessionen, Volatilitätsphasen oder Finanzmarktstress vorhergesagt werden. In dieser Arbeit betrachten Sie ein geeignetes Klassifikationsverfahren zur Out-of-Sample-Prognose solcher Zustände und vergleichen dessen Performance mit klassischen ökonometrischen Ansätzen wie Logit- oder Probit-Modellen. Die Prognosegüte wird anhand geeigneter Maße für probabilistische Klassifikation bewertet.

- **R-Pakete:** `glmnet`, `pROC`, `yardstick`
- **Einstiegsliteratur:** Kauppi and Saikkonen (2008), Vrontos et al. (2021a), Vrontos et al. (2021b)

3. Clustering

Clustering befasst sich mit der Aufgabe, aus einem multivariaten Datensatz von Zeitreihen Cluster zu bilden. Diese Cluster sollen jeweils möglichst ähnliche Zeitreihen aufweisen und die Unterschiede zwischen den Clustern sollen deutlich hervortreten. Dazu bedarf es zunächst einiger Metriken, die die Ähnlichkeit bestimmter fundamentaler Charakteristika messen. Zudem müssen die Zielgrößen definiert werden. Aufgabe der Clustering-Algorithmen ist es nun, einzelne Zeitreihen den verschiedenen Clustern effizient zuzuordnen und Kriterien bereitzustellen, anhand derer sich die Anzahl der Cluster bestimmen lässt. Zudem sollen die Cluster evaluiert werden. In der Seminararbeit sollen die Grundideen und gängigen Verfahren eingeführt, kritisch beleuchtet und anschließend empirisch angewendet werden.

- **R-Pakete:** `TSclust`
- **Einstiegsliteratur:** Montero and Vilar (2015); Peña and Tsay (2021)

4. Deep Learning

Deep-Learning-Methoden ermöglichen es, komplexe nichtlineare Strukturen in makroökonomischen und finanzwirtschaftlichen Datensätzen zu modellieren. In dieser Arbeit verwenden Sie neuronale Netze zur Out-of-Sample-Prognose einer makroökonomischen oder finanziellen Zielvariablen und untersuchen, ob diese gegenüber klassischen ökonometrischen Modellen oder einfacheren Machine-Learning-Verfahren zusätzliche Prognosegewinne liefern. Ein Fokus liegt dabei auf der Netzarchitektur, Hyperparameterwahl, Regularisierungsverfahren und Trainingsverfahren.

- **R-Pakete:** `torch`
- **Einstiegsliteratur:** Goodfellow et al. (2016), Gu et al. (2020), Prince (2023)

5. Forecasting

Die Prognose makroökonomischer und finanzwirtschaftlicher Zeitreihen ist eine zentrale Anwendung ökonometrischer und statistischer Methoden. In dieser Arbeit untersuchen Sie geeignete Verfahren zur Out-of-Sample-Prognose einer makroökonomischen oder finanziellen Zielvariablen und vergleichen deren Prognoseleistung mit einfachen Benchmark-Modellen. Dabei können sowohl klassische Zeitreihenmodelle als auch moderne Machine-Learning-Ansätze berücksichtigt werden. Ein Fokus liegt auf der Wahl geeigneter Prognosehorizonte, der Konstruktion eines Out-of-Sample-Evaluationsdesigns sowie der Bewertung der Prognosegüte anhand geeigneter Fehlermaße.

- **R-Pakete:** `forecast`, `fable`, `glmnet`
- **Einstiegsliteratur:** Hyndman and Athanasopoulos (2021)

Literatur

- Fisch, A., Grose, D., Eckley, I. A., Fearnhead, P., and Bardwell, L. (2024). anomaly: Detection of Anomalous Structure in Time Series Data. *Journal of Statistical Software*, 110:1–24.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.
- Gu, S., Kelly, B., and Xiu, D. (2020). Empirical Asset Pricing via Machine Learning. *The Review of Financial Studies*, 33(5):2223–2273.
- Hastie, T. and Tibshirani, Robert, F. J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2nd edition.
- Hyndman, R. J. and Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. OTexts, Melbourne, Australia, 3 edition.
- James, G., Witten, D., Hastie, T., and Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications in R*. Springer, 2nd edition.
- Kauppi, H. and Saikkonen, P. (2008). Predicting U.S. Recessions with Dynamic Binary Response Models. *The Review of Economics and Statistics*, 90(4):777–791.
- Montero, P. and Vilar, J. A. (2015). TSclust: An R Package for Time Series Clustering. *Journal of Statistical Software*, 62.
- Peña, D. and Tsay, R. S. (2021). *Statistical Learning for Big Dependent Data*. John Wiley & Sons.
- Pretis, F., Reade, J. J., and Sucarrat, G. (2018). Automated General-to-Specific (GETS) Regression Modeling and Indicator Saturation for Outliers and Structural Breaks. *Journal of Statistical Software*, 86:1–44.
- Prince, S. J. (2023). *Understanding Deep Learning*. The MIT Press.
- Vrontos, S. D., Galakis, J., and Vrontos, I. D. (2021a). Implied volatility directional forecasting: a machine learning approach. *Quantitative Finance*, 21(10):1687–1706.
- Vrontos, S. D., Galakis, J., and Vrontos, I. D. (2021b). Modeling and predicting U.S. recessions using machine learning techniques. *International Journal of Forecasting*, 37(2):647–671.