AUFFÄLLIGKEITEN IN FINANZDATEN

Fraunhofer ITWM
Dr. Stefanie Schwaar

Geschäftsfeldentwicklerin „Abrechnungsprüfung“
Abteilung Finanzmathematik

Fraunhofer-Institut für Techno- und Wirstschaftmathematik (ITWM)
Fraunhofer-Platz 1
67663 Kaiserslautern

Fraunhofer
ITWM

Die Abteilung Finanzmathematik ist mehr als Mathematik für Banken und Versicherungen

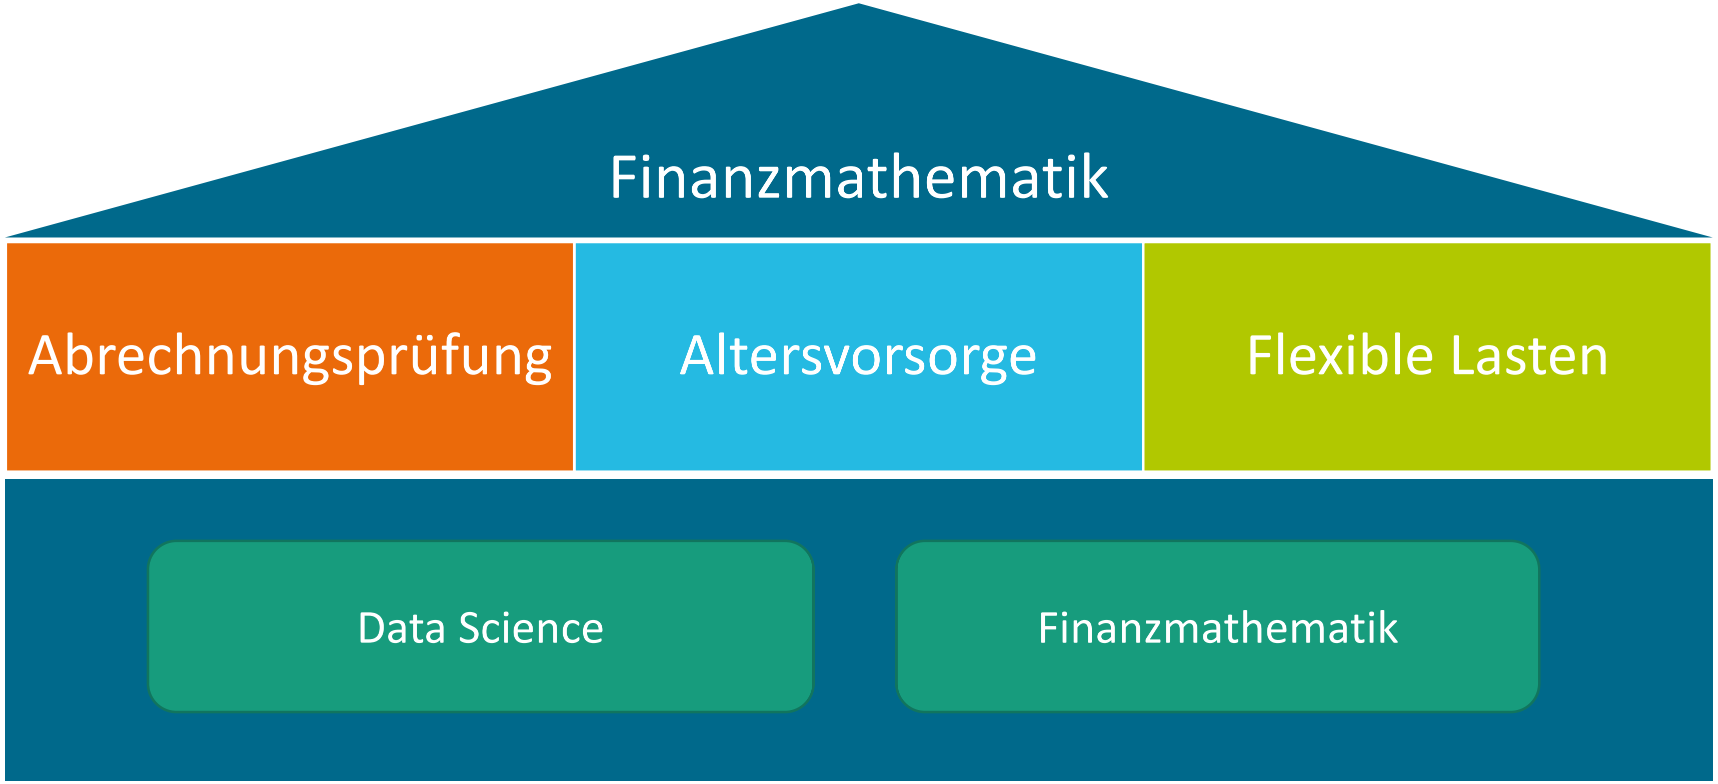

Fraunhofer ITWM

Abrechnungsprüfung beginnt bei der Datenerfassung und endet bei der Entscheidung

Pixabay.com

Abrechnungsprüfung beginnt bei der Datenerfassung und endet bei der Entscheidung

Pixabay.com

Fraunhofer ITWM

Projekte aus dem Geschäftsfeld Abrechnungsprüfung setzten an unterschiedlichen Positionen an

Datenerfassung

Operationalisierung

Auffälligkeitsdetektion

Digitalisierung

Qualitätskontrolle/ Betrugserkennung

Produktivsystem

Pixabay.com

Fraunhofer ITWM

Abrechnungen sind verschiedene mathematische Objekte

Regressionsmodell:
$f(x_{1i}, x_{2i}, \dots, x_{di}) \; = y_i$

Zeitreihen:
$f(x_{1t}, x_{2t}, \dots, x_{dt}) \; = y_t$

$x \rightarrow f \rightarrow y$

Netzwerke:

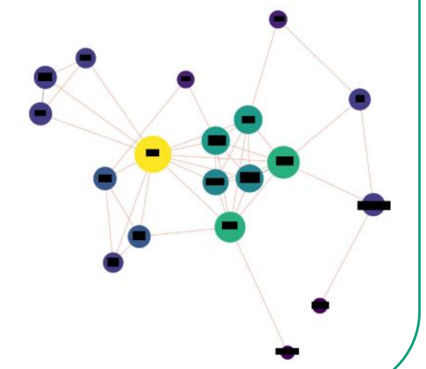

Bestandteile einer Rechnung:

- Beschreibung des abzurechnenden Objektes
- Zeitpunkt der Abrechnung
- Ort der Abrechnung
- Elemente der Rechnung (Arbeitszeit, Material)
- Kosten
- Zusätzliche Informationen

Fraunhofer ITWM

Auffälligkeiten können unterschiedlichster Natur sein

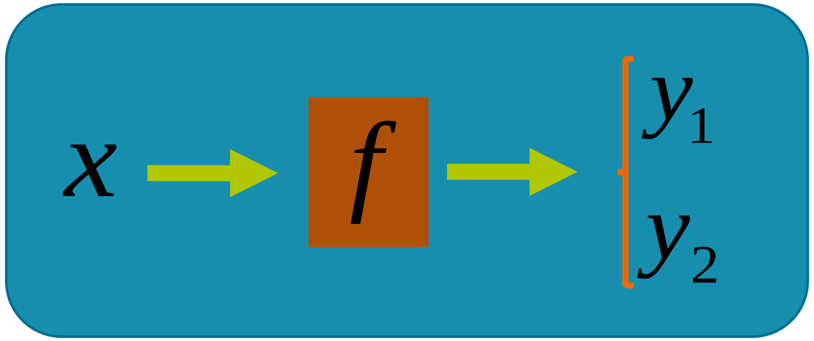

Ausreißer in den Beobachtungen

Zeitliche Änderungen des Zusammenhangs

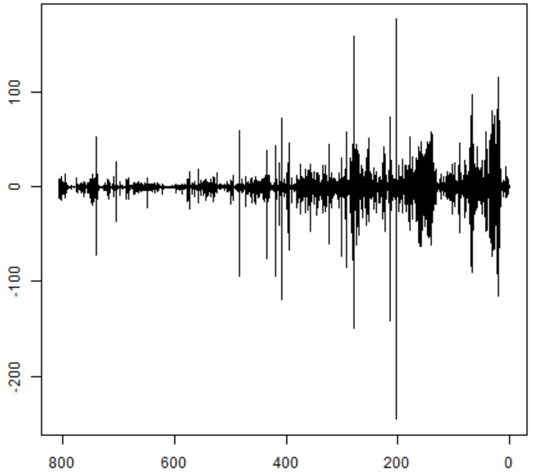

Strukturänderungen in Zeitreihen erkennen ist eine Herausforderung

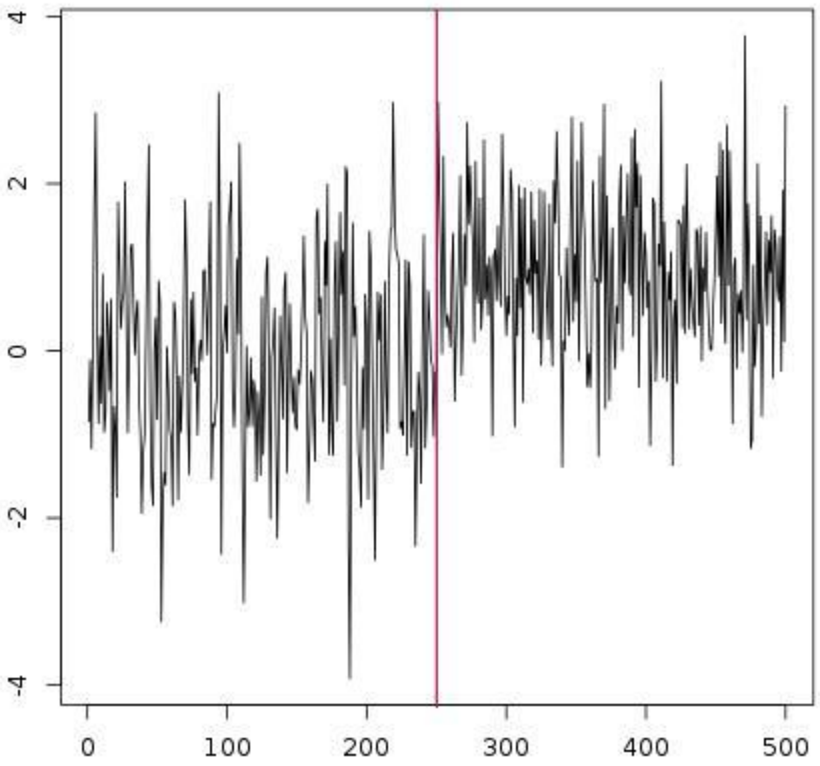

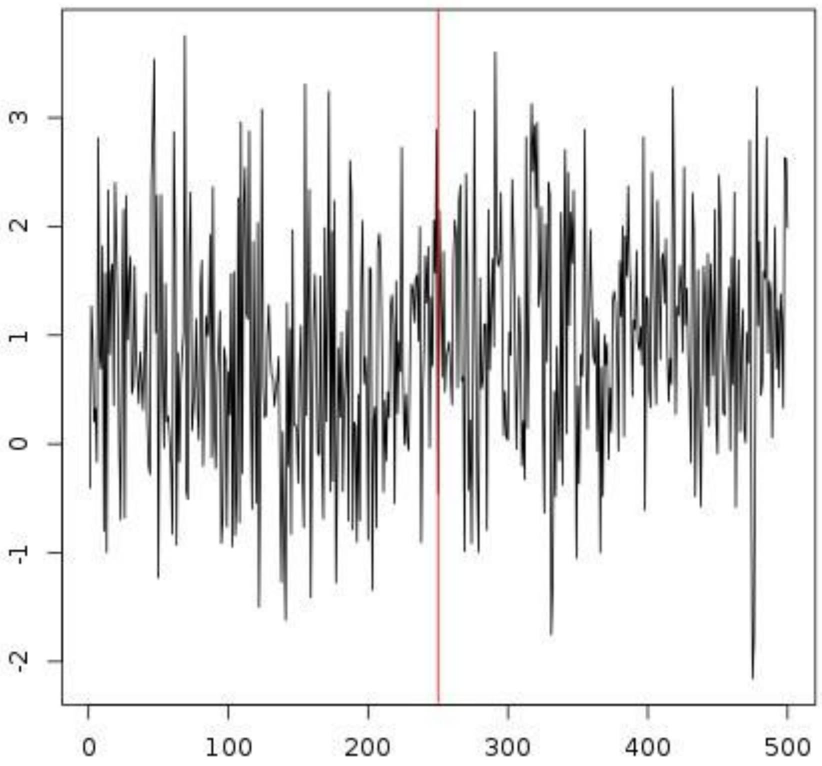

Erkennen von Änderungen in den Zusammenhängen

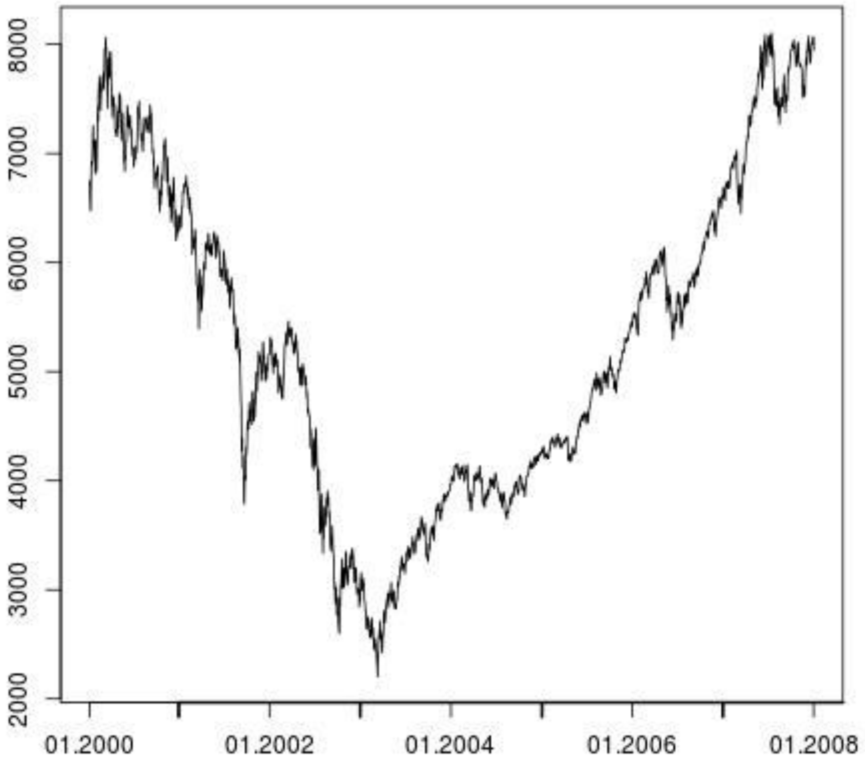

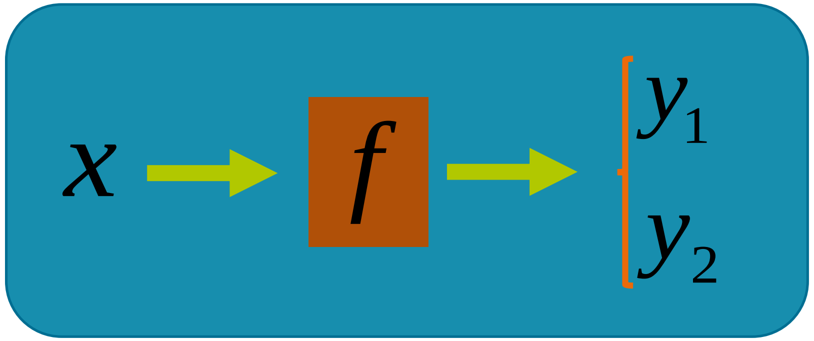

Erkennen von Änderungen in den Zusammenhängen

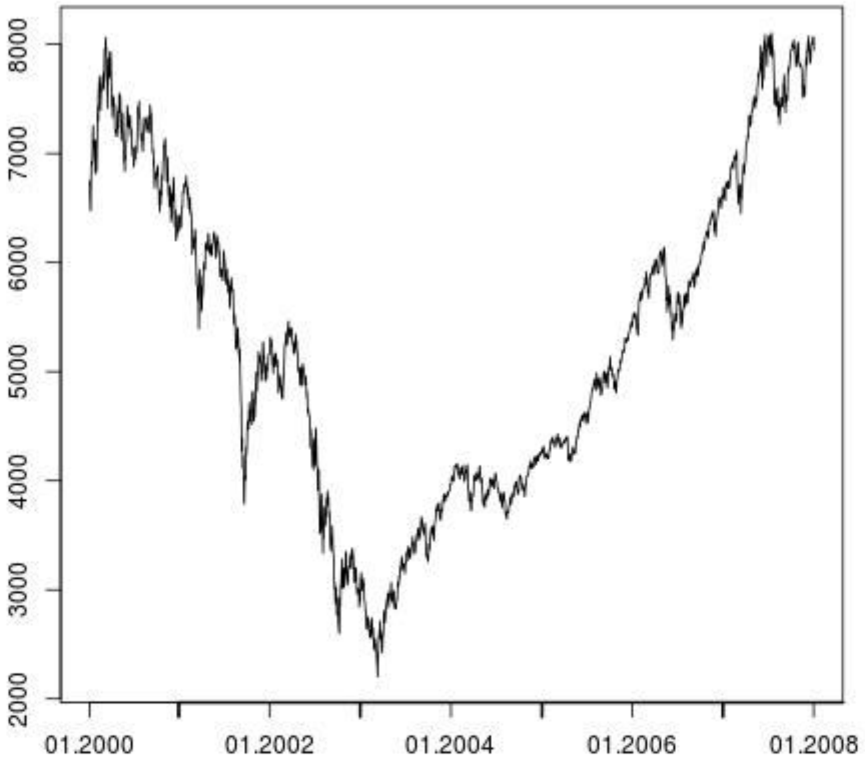

$$X_t = \begin{cases} g_1(\mathbb{X}_t) + \varepsilon_t, & t \leq m \\ g_2(\mathbb{X}_t) + \varepsilon_t, & t > m \end{cases}$$

Hierbei sind unbekannt:

- Funktionen g_1 und g_2
- der Change-Point m und
- das „Rauschen" ε_t.

Fraunhofer ITWM

Neuronale Netze zur Bestimmung von Änderungen in Zeitreihen verwenden

Idee:

Nutzen der Universalapproximationseigenschaft von Neuronalen Netzen, d.h.

$$g(x) \approx f(x,\theta) = \nu_0 + \sum_{i=1}^{H} \nu_i \phi\big(\langle \alpha_i, x\rangle + \beta_i\big)$$

f ein Neuronales Netz mit sigmoider Aktivierungsfunktion wodurch der unbekannte Zusammenhang approximiert wird

Hornik et al. (1989),
Multilayer feedforward networks are universal approximators

Fraunhofer ITWM

Praktische Anwendungen liefern vielversprechende Resultate

$$X_t = \begin{cases} f(\mathbb{X}_t, \theta_1) + \varepsilon_t & 1 \le t \le m \\ f(\mathbb{X}_t, \theta_2) + \varepsilon_t & m < t \le n \end{cases}$$

$$\hat{\theta} = \arg\min_{\theta} \left\| \sum_{t=1}^{n} \left(X_t - f(\mathbb{X}_t, \theta)\right)^2 \right\|$$

$$T(X) = \max_{1 \le k < n} \frac{1}{\sqrt{n}} \left\| \sum_{t=1}^{k} \left(X_t - f\left(\mathbb{X}_t, \hat{\theta}\right)\right) \right\|$$

Kirch, Tadjuidje Kamgaing (2014),
A uniform central limit theorem for neural network-based autoregressive processes with applications to change-point analysis

Fraunhofer ITWM

Praktische Anwendungen liefern vielversprechende Resultate

$$X_t = \begin{cases} f(\mathbb{X}_t, \theta_1) + \varepsilon_t & 1 \leq t \leq m \\ f(\mathbb{X}_t, \theta_2) + \varepsilon_t & m < t \leq n \end{cases}$$

$$\hat{\theta} = \arg\min_{\theta} \left\| \sum_{t=1}^{n} \left(X_t - f(\mathbb{X}_t, \theta)\right)^2 \right\|$$

$$T(X) = \max_{1 \leq k < n} \frac{1}{\sqrt{n}} \left\| \sum_{t=1}^{k} \left(X_t - f\left(\mathbb{X}_t, \hat{\theta}\right)\right) \right\|$$

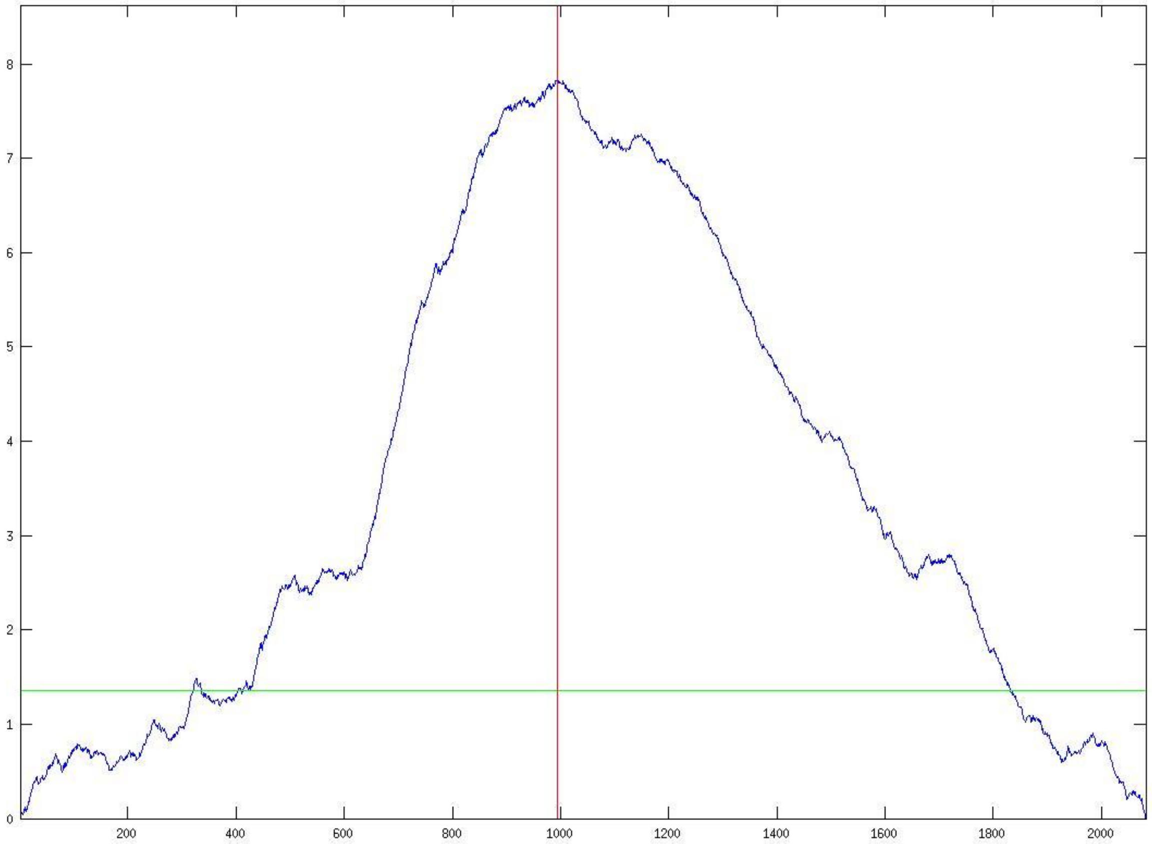

Kirch, Tadjuidje Kamgaing (2014),
A uniform central limit theorem for neural network-based autoregressive processes with applications to change-point analysis

Fraunhofer ITWM

Praktische Anwendungen liefern vielversprechende Resultate

$$X_t = \begin{cases} f(\mathbb{X}_t, \theta_1) + \varepsilon_t & 1 \le t \le m \\ f(\mathbb{X}_t, \theta_2) + \varepsilon_t & m < t \le n \end{cases}$$

$$T(X) = \max_{1 \le k < n} \frac{1}{\sqrt{n}} \left\| \sum_{t=1}^{k} \left(\nabla f(\mathbb{X}_t, \hat{\theta}) \right) \left(X_t - f(\mathbb{X}_t, \hat{\theta}) \right) \right\|$$

$$\hat{m} = \arg\max_{1 \le k < n} \left\| \sum_{t=1}^{k} \left(\nabla f(\mathbb{X}_t, \hat{\theta}) \right) \left(X_t - f(\mathbb{X}_t, \hat{\theta}) \right) \right\|$$

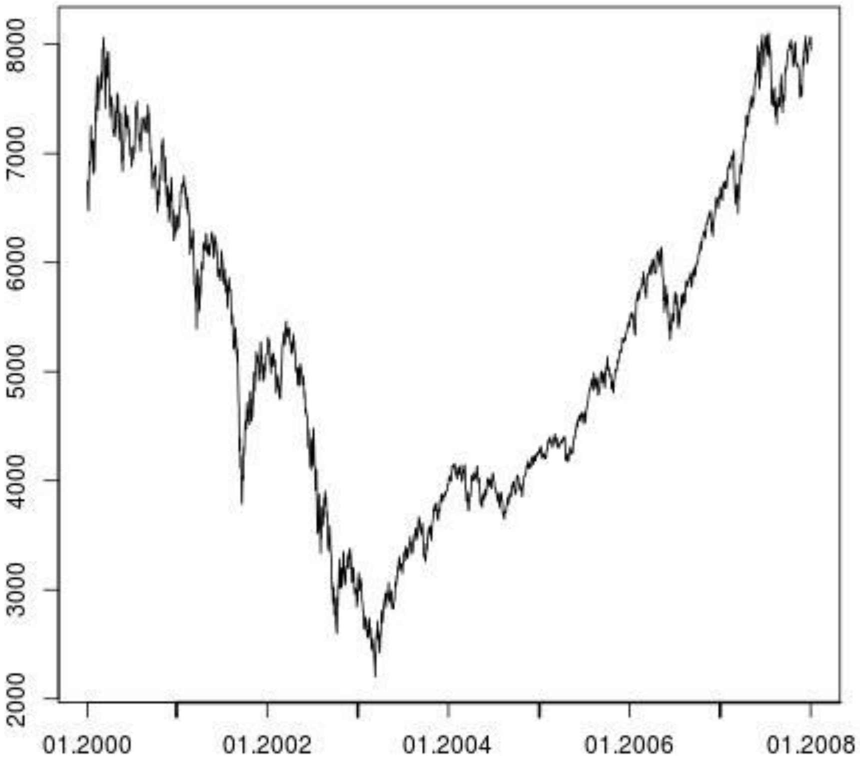

Schwaar (2016),
Asymptotics for change-point tests and change-point estimators

Die Anwendung ist in verschiedenen Bereichen möglich

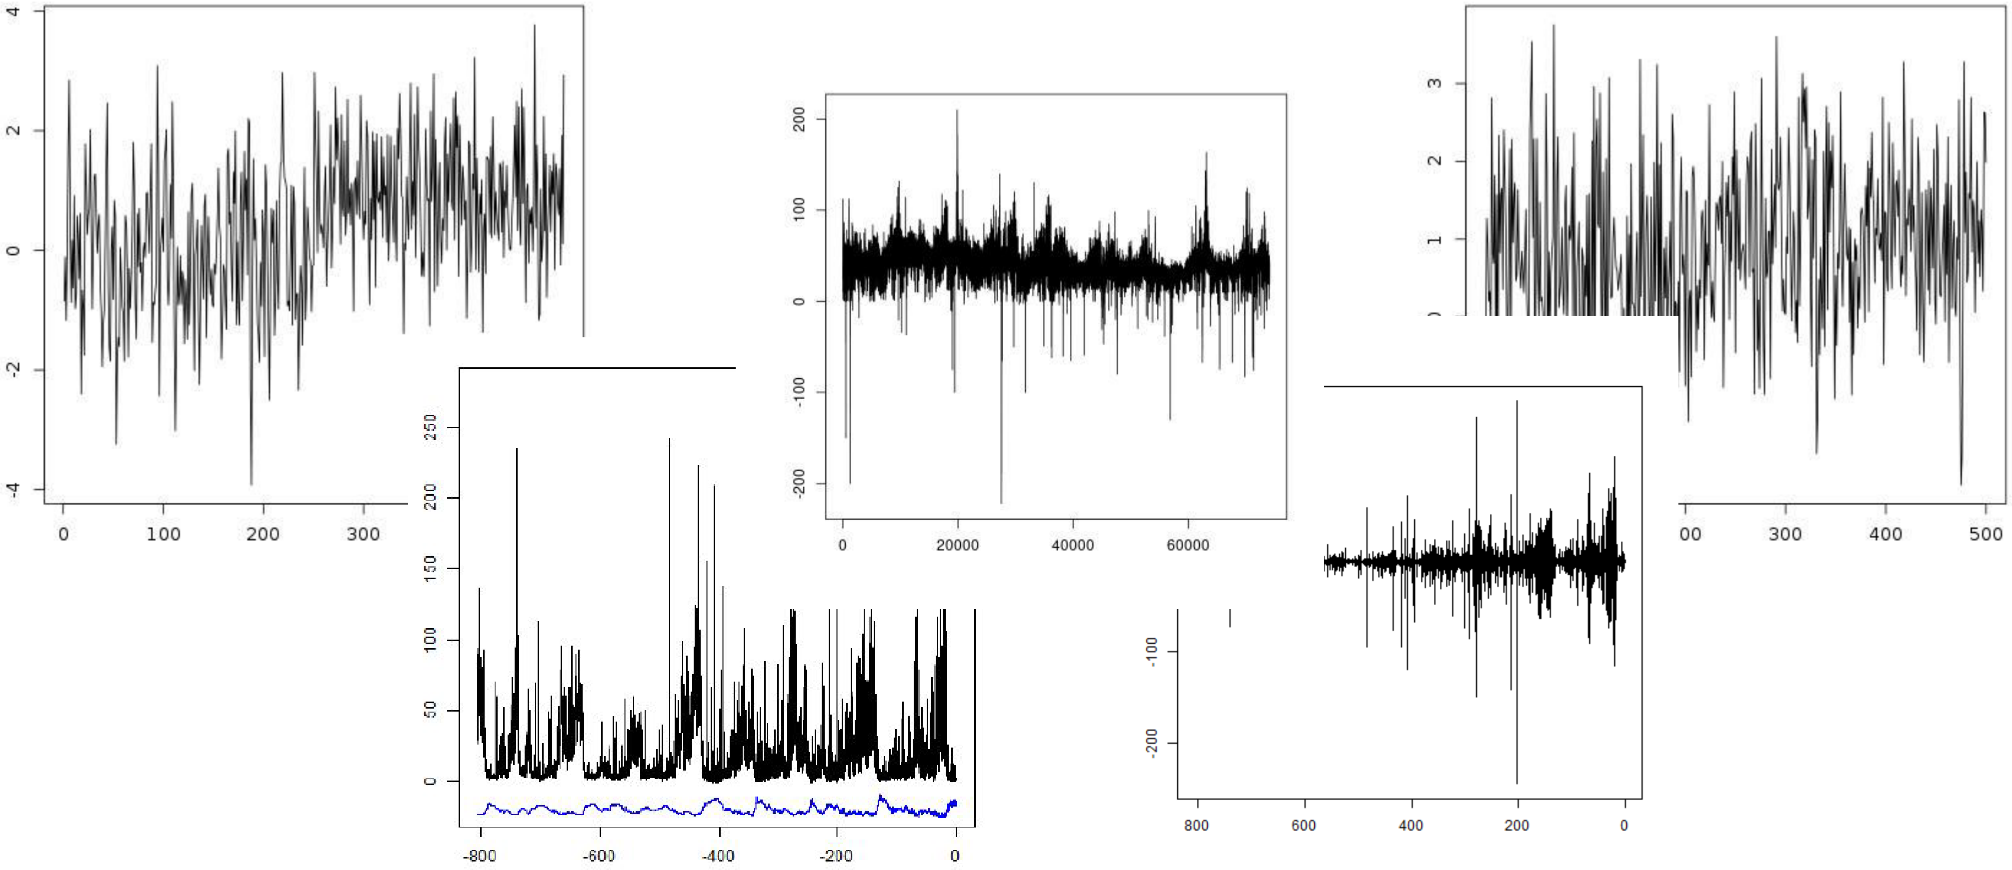

Fraunhofer ITWM

Aktuelle Forschungsgebiete in Zeitreihen beinhalten verschiedene Aspekte

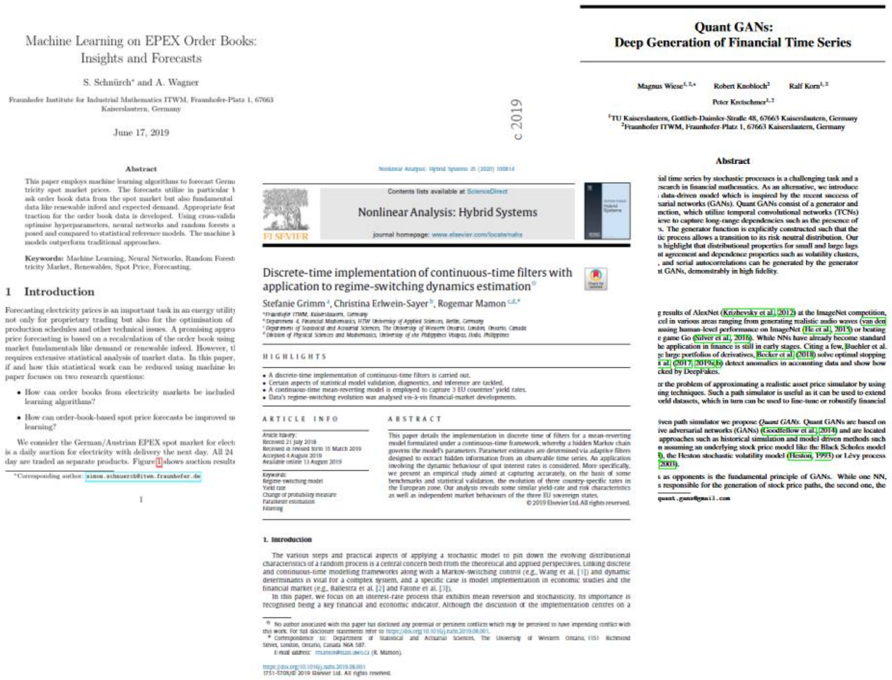
Machine Learning on EPEX Order Books: Insights and Forecasts

S. Schnürch and A. Wagner

June 17, 2019

Abstract

1 Introduction

Quant GANs: Deep Generation of Financial Time Series

Magnus Wiese, Robert Knobloch, Ralf Korn, Peter Kretschmer

Abstract

Nonlinear Analysis: Hybrid Systems

Discrete-time implementation of continuous-time filters with application to regime-switching dynamics estimation

Stefanie Grimm, Christina Erlwein-Sayer, Rogemar Mamon

HIGHLIGHTS

ARTICLE INFO

ABSTRACT

1. Introduction

Aktuelle Forschung behandeln:

- Forecasting mit Machine-Learning Algorithmen
- Simulation von Zeitreihen
- Detektion von verborgenen Zuständen
- Einfluss von Datenfehlern

Weitere Forschungsprojekte finden Sie auf:
https://www.itwm.fraunhofer.de/de/abteilungen/fm/aktuelles/aktuelle-forschungsthemen.html

Fraunhofer ITWM

Das Zusammenspiel unterschiedlicher Techniken liefert effiziente Unterstützung

Fraunhofer
ITWM

Auffälligkeiten in Finanzdaten

Dr. Stefanie Schwaar

Geschäftsfeldentwicklerin „Abrechnungsprüfung“
Abteilung Finanzmathematik

Fraunhofer-Institut für Techno- und
Wirstschaftmathematik (ITWM)

Fraunhofer-Platz 1
67663 Kaiserslautern

Fraunhofer
ITWM