

---

# KI-BASIERTE ANOMALIEDETEKTION IN DER PRODUKTION

Forum Künstliche Intelligenz 14. Mai 2020, Virtuelles Event

---



*Dr. Olaf Enge-Rosenblatt, Oliver Mey, Willi Neudeck*

Fraunhofer-Institut für Integrierte Schaltungen, Institutsteil Entwicklung Adaptiver Systeme EAS

---

---

# KI-basierte Anomaliedetektion in der Produktion

---

## Agenda

- Digitalisierung & Industrie 4.0
- Maschinelles Lernen
- Anomalieerkennung – einige nicht-neuronale Methoden
- Anomalieerkennung mittels Projektionsfehler
- Anomalieerkennung mittels Zeitreihenvorhersage
- Beispiel aus der Stahlindustrie
- Angebote des Fraunhofer EAS

---

# KI-basierte Anomaliedetektion in der Produktion

---

## Agenda

- Digitalisierung & Industrie 4.0
- Maschinelles Lernen
- Anomalieerkennung – einige nicht-neuronale Methoden
- Anomalieerkennung mittels Projektionsfehler
- Anomalieerkennung mittels Zeitreihenvorhersage
- Beispiel aus der Stahlindustrie
- Angebote des Fraunhofer EAS

# Digitalisierung & Industrie 4.0

## Herausforderungen der Industrie im Überblick



### Anforderungen an den Anlagenbau

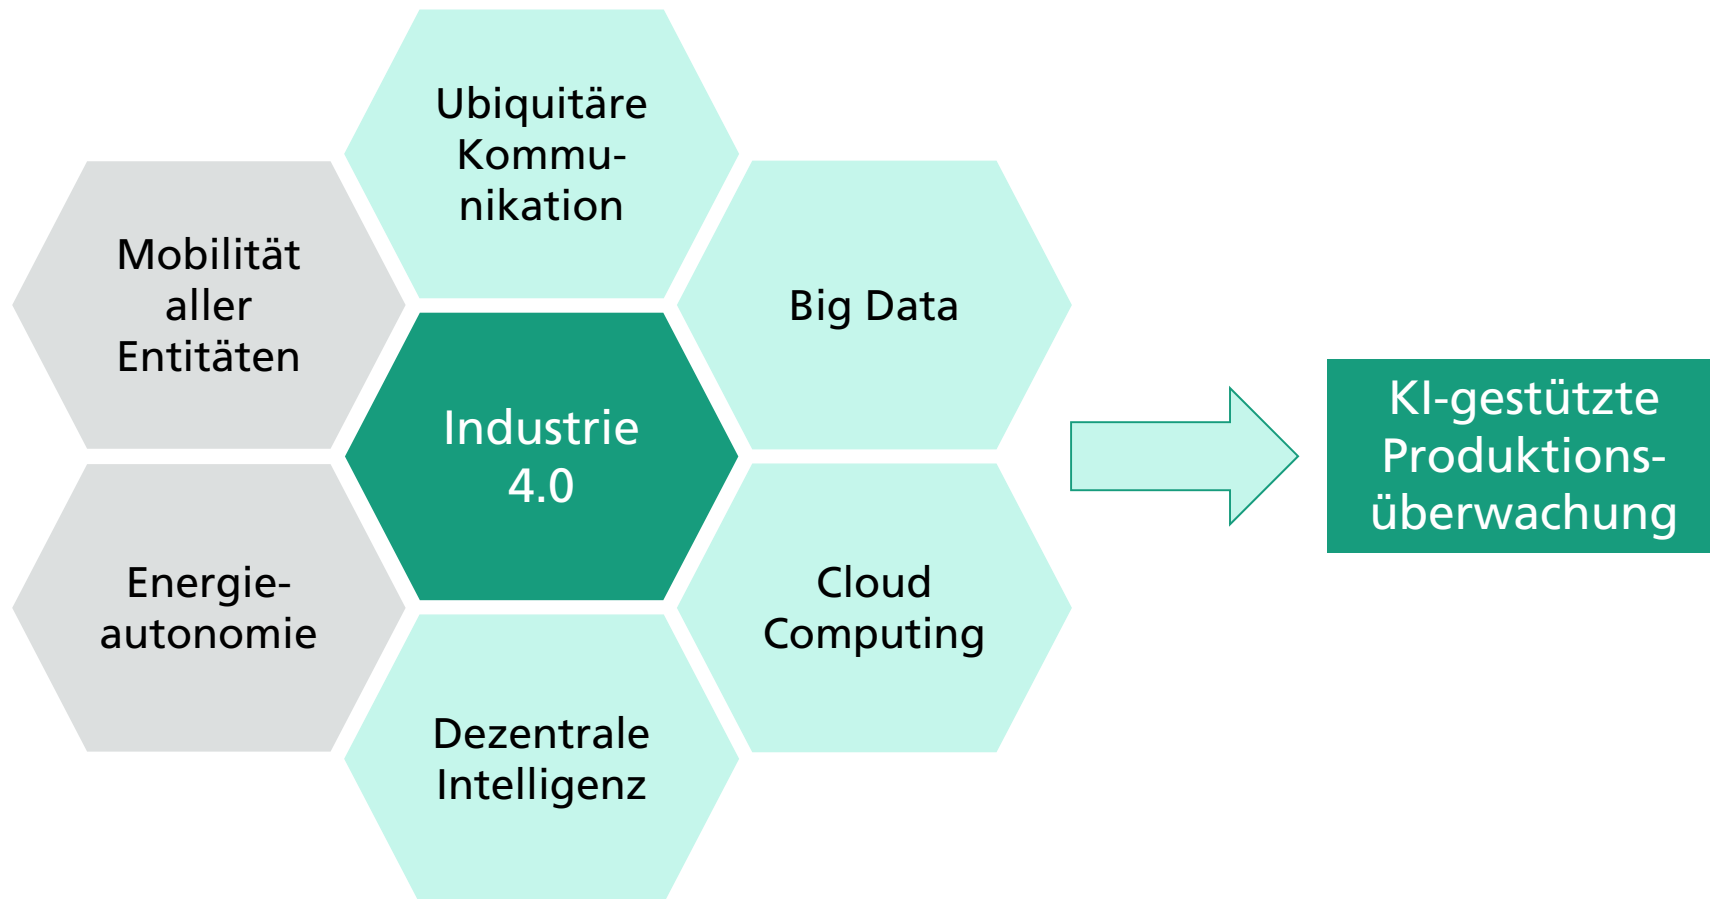
- Komplexe, schnelle Fertigungsprozesse
- Heterogene Automatisierungswelten
- Miteinander interagierende Steuerungen
- Optimierung von Energie- & Ressourcenverbräuchen

### Anforderungen an die Produktion

- Life-Cycle-Management
- Überwachung & Optimierung der Produktivität
- Automatische Qualitätsprüfung der produzierten Komponenten
- Gewährleistung der Rückverfolgbarkeit
- Individualisierung der Produktion

# Digitalisierung & Industrie 4.0

## Technologische Ansätze



# Digitalisierung & Industrie 4.0

## Datenkategorien

### Unterschiedlichste Datenquellen



#### ■ Sensoren

- Temperaturen
- Schwingungen
- Kräfte
- Feuchte
- elektrische Ströme

#### ■ Prozessparameter

- Positionen/Lage
- Geschwindigkeiten
- Drehzahlen
- Spannkkräfte
- Reglereinstellungen

#### ■ Betriebsdaten

- Betriebszustände
- Stückzahlen
- Materialchargen
- Zeiterfassung
- KPIs

---

# KI-basierte Anomaliedetektion in der Produktion

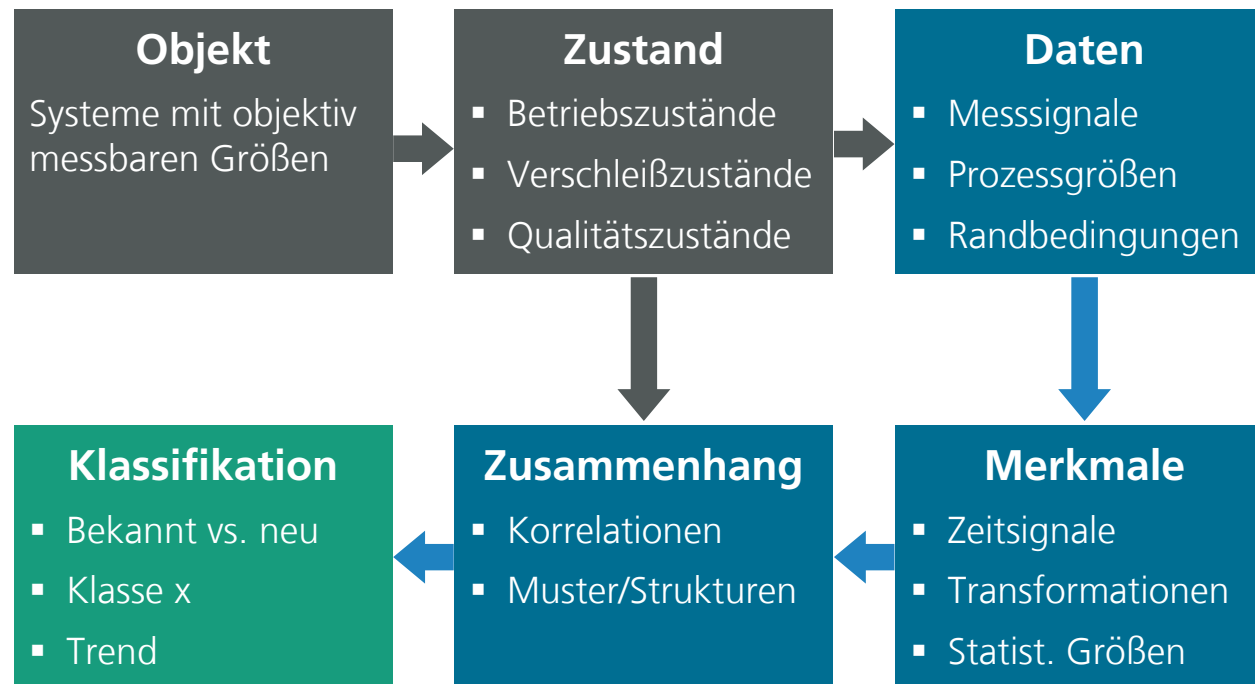
---

## Agenda

- Digitalisierung & Industrie 4.0
- **Maschinelles Lernen**
- Anomalieerkennung – einige nicht-neuronale Methoden
- Anomalieerkennung mittels Projektionsfehler
- Anomalieerkennung mittels Zeitreihenvorhersage
- Beispiel aus der Stahlindustrie
- Angebote des Fraunhofer EAS

# Maschinelles Lernen

## Datenbasierte Analysen in der Industrie



# Maschinelles Lernen


## Ursachen für Strukturen in Daten

- Verschiedene (diskrete) Betriebszustände / Prozesseinstellungen, u.a.:
  - Drehzahlen, Vorschubgeschwindigkeiten
  - Lastsituationen
  - Prozesstemperaturen
- Verschiedene Randbedingungen, u.a.:
  - Ausgangsmaterial (Lieferant, Charge), Werkzeug (Hersteller, Qualität)
  - Herstellungspfad des Werkstücks (genutzte Maschinen, Prozess-Stationen)
  - Parameter von Hilfsmedien
- Verschiedene Alterungs- / Verschleißphänomene, Qualitätskennwerte:
  - Abnutzungsgrad von Werkzeugen
  - Führung von beweglichen Komponenten (Wellenschwingungen, Getriebeispiel)
  - Reibungslose Funktion von Nebenprozessen
  - Ausnutzung von Toleranzbändern (späte Gegensteuerung)

# Maschinelles Lernen

## Zuordnung zu bekannten Klassen – Klassifizierung

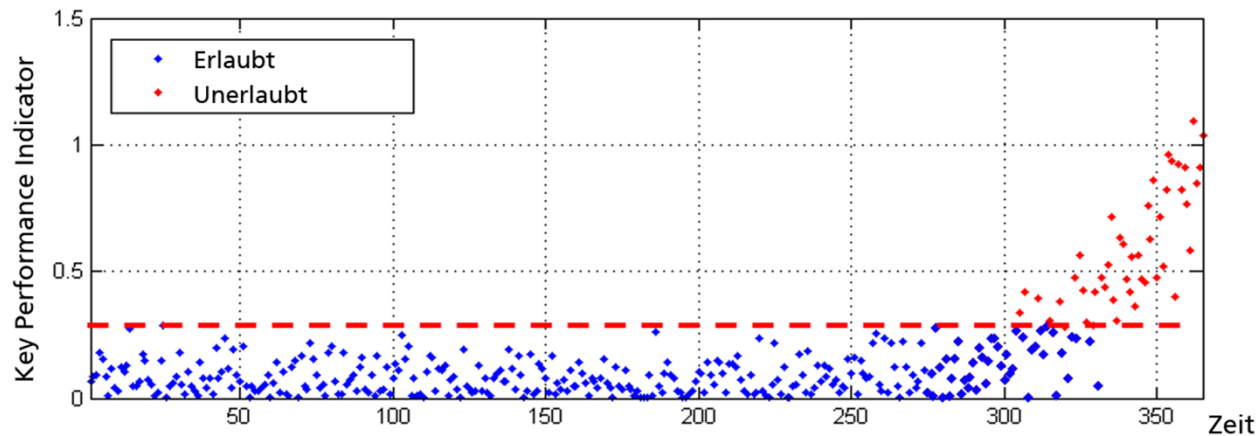

- Training mit Messungen aller Klassen / Betriebszustände
- Analyse:
  - Erkennung der bekannten Klassen
  - unbekannte Muster → „nicht klassifizierbar“
- Problem: Training auch mit n.i.O.-Klassen nötig → oft ungeeignet



# Maschinelles Lernen

## Detektion von Anomalien

- Einordnung aktueller Messungen in den Merkmalsraum (→ Messpunkte)
- Anomalieerkennung mittels Abstand zwischen Messpunkt(en) und der „i.O.-Punkt wolke“
- Vorteil: Training nur mit „i.O.-Zustand“



---

# KI-basierte Anomaliedetektion in der Produktion

---

## Agenda

- Digitalisierung & Industrie 4.0
- Maschinelles Lernen
- Anomalieerkennung – einige nicht-neuronale Methoden
- Anomalieerkennung mittels Projektionsfehler
- Anomalieerkennung mittels Zeitreihenvorhersage
- Beispiel aus der Stahlindustrie
- Angebote des Fraunhofer EAS

# Anomalieerkennung – einige nicht-neuronale Methoden

## Kennwert z-Score – Prinzip

- Ungewöhnlich große / kleine Messwerte  $x$  erkennen
- Basiert auf Mittelwert  $\bar{x}$ , (empirischer) Standardabweichung  $s$
- Definition:

$$z := \frac{x - \bar{x}}{s}$$


- Für große  $|z|$  wird Anomalie vermutet

Verwendete Quellen: NIST, 2013

# Anomalieerkennung – einige nicht-neuronale Methoden

## Regelkarten (engl.: „Control Chart“) – Prinzip

- Ungewöhnliche Verläufe einer Messreihe  $x[k]$  erkennen
- Verdächtige Messpunkte ergeben sich aus Regeln; z.B.:
  - Ein Messpunkt außerhalb  $\mu \pm 3\sigma$  ( $\mu$  = Mittelwert,  $\sigma$  = Standardabw.)
  - Vier von fünf Messpunkten unterhalb  $\mu - \sigma$  (Analog: oberhalb  $\mu + \sigma$ )



Verwendete Quellen: NIST, 2013

# Anomalieerkennung – einige nicht-neuronale Methoden

## z-Score & Regelkarten – Einschätzung

### ■ Vorteile

- Einfach umsetzbar
- Leicht zu verstehen


### ■ Nachteile

- Starke Voraussetzungen nötig, z.B.
    - (Annähernd) Normalverteilte  $x$  bzw.  $x[k]$
    - Statistische Unabhängigkeit
    - Stationarität
- } Meist nicht erfüllt

# Anomalieerkennung – einige nicht-neuronale Methoden

## One-Class SVM – Prinzip

- Nichtlineare Abbildung in (meist) höherdimensionalen Raum
- Dadurch soll Zugehörigkeit zur „Gutklasse“ leichter feststellbar werden



Verwendete Quellen: Hayton, 2007

# Anomalieerkennung – einige nicht-neuronale Methoden

## One-Class SVM – Einschätzung

### ■ Vorteile

- Eignung auch für nicht-normalverteilte Daten
- Kann nichtlineare Zusammenhänge zwischen Messwerten lernen

### ■ Nachteile

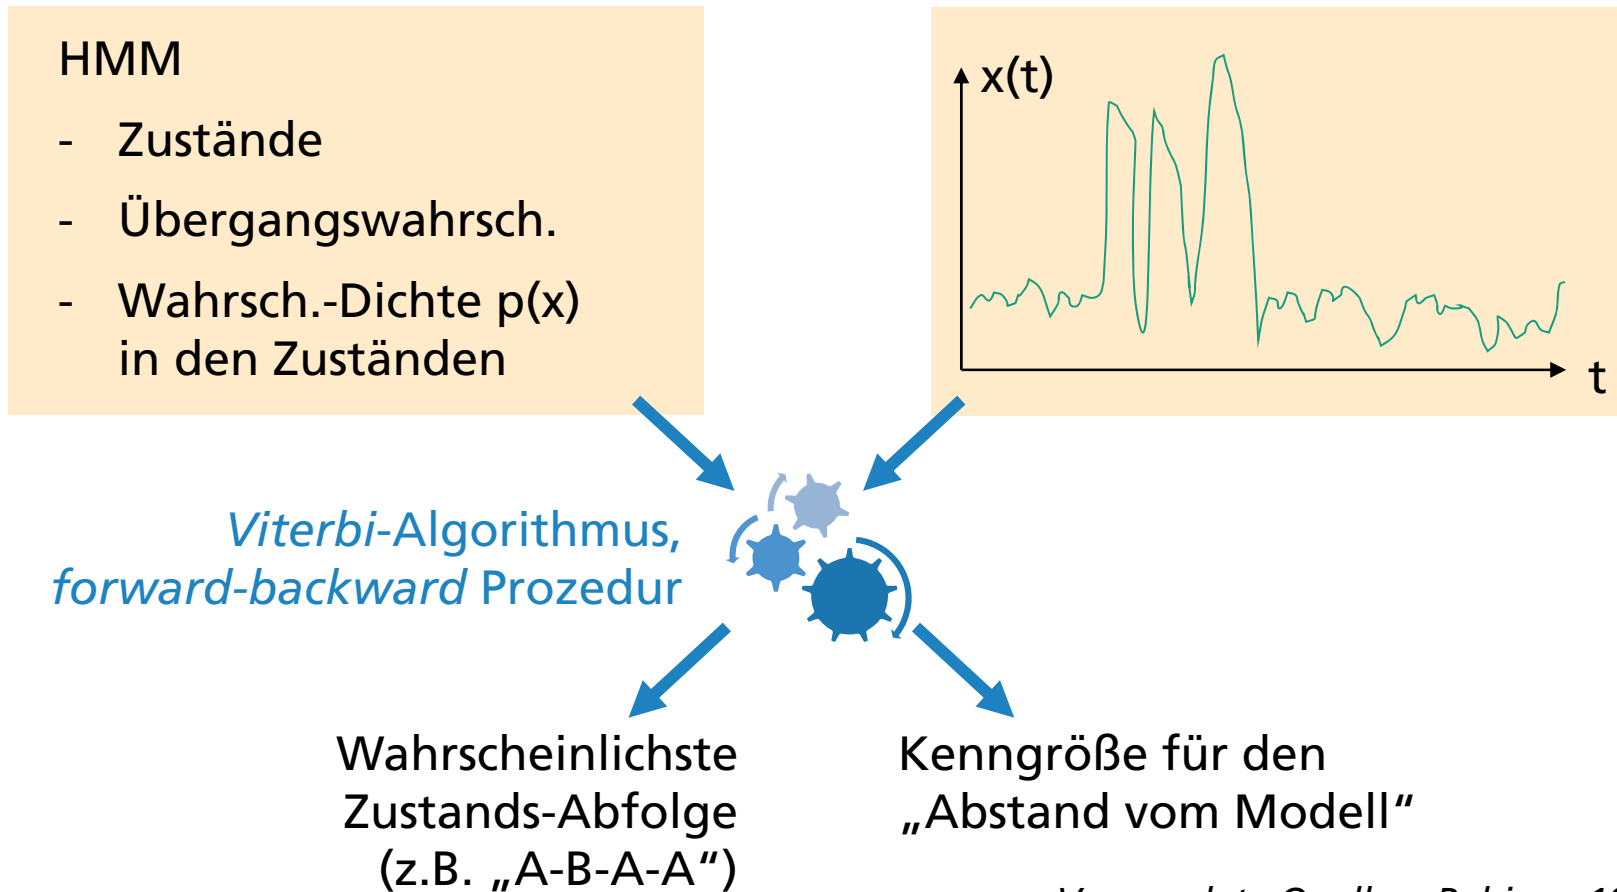
- Oft ist zuvor ein (aufwändiges) Feature-Engineering nötig
- Nur bedingt geeignet für instationäre Prozesse
- Training: Rechenzeit (je nach Algorithmus) in etwa quadratisch bzgl. Anzahl Trainingsdaten

→ Nur für kleine bis mittlere Trainingsdatensätze geeignet

*Verwendete Quellen: Hayton, 2007*

# Anomalieerkennung – einige nicht-neuronale Methoden

## Hidden Markov Model – Prinzip



Verwendete Quellen: Rabiner, 1986

# Anomalieerkennung – einige nicht-neuronale Methoden

## Hidden Markov Model – Einschätzung

- Vorteile
  - Geeignet für instationäre Systeme
- Nachteile
  - Meist ist Feature-Engineering nötig  
(kann z.B. mit MFCC-Features kombiniert werden)

---

# KI-basierte Anomaliedetektion in der Produktion


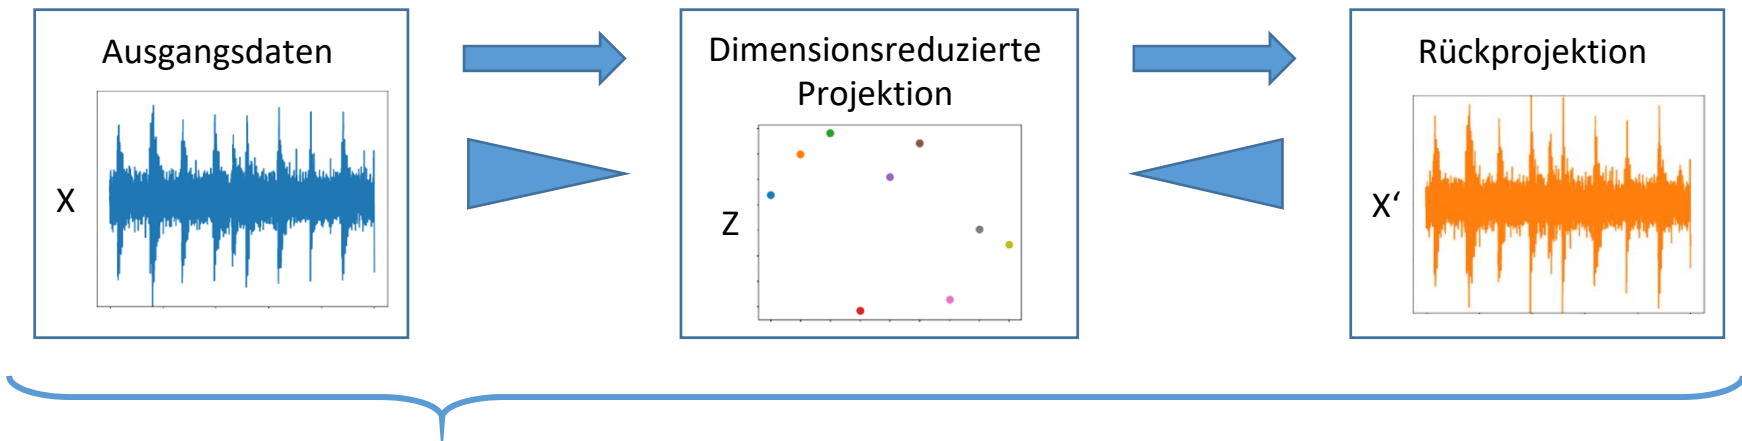
---

## Agenda

- Digitalisierung & Industrie 4.0
- Maschinelles Lernen
- Anomalieerkennung – einige nicht-neuronale Methoden
- **Anomalieerkennung mittels Projektionsfehler**
- Anomalieerkennung mittels Zeitreihenvorhersage
- Beispiel aus der Stahlindustrie
- Angebote des Fraunhofer EAS

# Anomalieerkennung mittels Projektionsfehler

## PCA vs. Autoencoder – Prinzip



# Anomalieerkennung mittels Projektionsfehler

## PCA vs. Autoencoder – Prinzip

### PCA

- Lineare Abbildung eines hoch-dimensionalen Raums in einen niedrig-dimensionalen Raum
- Optimierungskriterium: Maximierung der Varianz der transformierten Daten im niedrig-dimensionalen Raum
- Anschaulich: Drehung des Koordinatensystems in Richtung der größten Varianz

### Autoencoder

- Datenkompression mithilfe eines neuronalen Netzes mit „Flaschenhals“ in der Mitte
- Werte im Flaschenhals sind gleichzeitig Projektion in niedrig-dimensionalen Raum
- Optimierungskriterium: Reduktion des Abbildungsfehlers  $E = \sum (X - X')$  und damit Maximierung der encodierten Information im niedrig-dimensionalen Raum

→ Idee bei beiden:  
Transformation von Daten, die sich stark von den Trainingsdaten unterscheiden, führt zu großem Abbildungsfehler → Anomalie

# Anomalieerkennung mittels Projektionsfehler

## PCA vs. Autoencoder – Einschätzung

### PCA

- + Geringer Rechenaufwand
- + Gute Ergebnisse bereits mit vergleichsweise wenigen Trainingsdaten
- Nur lineare Zusammenhänge in den Daten können modelliert werden
- i. Allg. höherer Abbildungsfehler  $E$  bei Regelbetriebsdaten, da Varianz im niedrig dim. Raum optimiert wird  
→ Verfahren weniger sensitiv
- Modellierungsgüte ist ab gewisser Datenmenge begrenzt

### Autoencoder

- Höherer Rechenaufwand
- Gefahr des Overfittings bei geringer Menge an Trainingsdaten
- + Beliebige Zusammenhänge in den Daten können modelliert werden
- + i. Allg. niedrigerer Abbildungsfehler  $E$  bei Regelbetriebsdaten, da dieser beim Training optimiert wird  
→ Verfahren sensitiver
- + Modellierungsgüte besser, je mehr Daten

---

# KI-basierte Anomaliedetektion in der Produktion

---

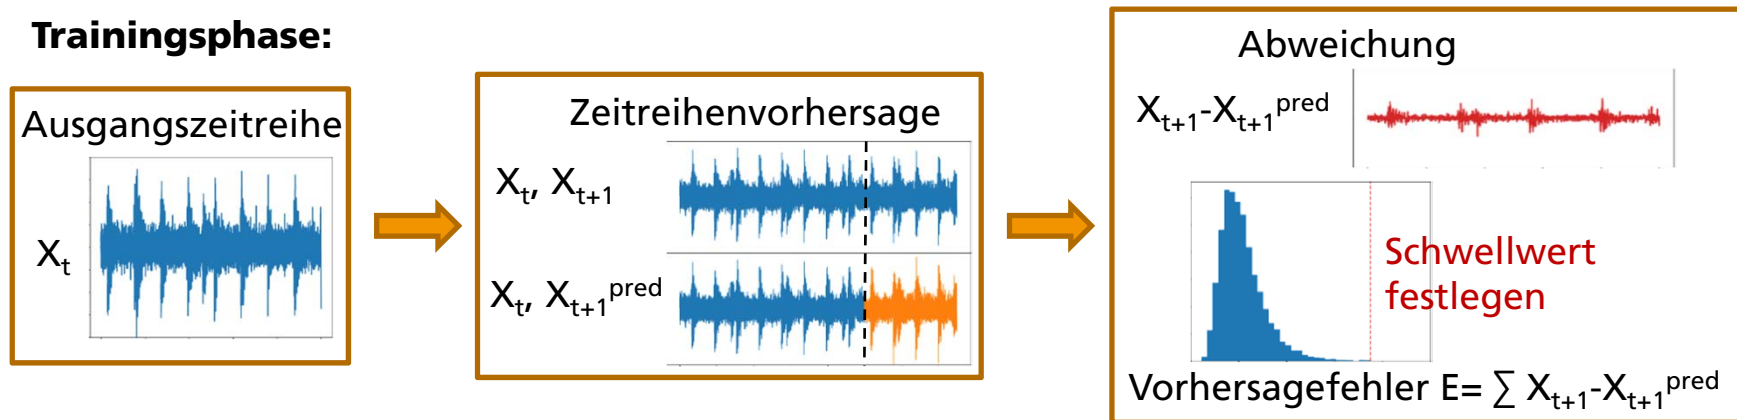
## Agenda

- Digitalisierung & Industrie 4.0
- Maschinelles Lernen
- Anomalieerkennung – einige nicht-neuronale Methoden
- Anomalieerkennung mittels Projektionsfehler
- **Anomalieerkennung mittels Zeitreihenvorhersage**
- Beispiel aus der Stahlindustrie
- Angebote des Fraunhofer EAS

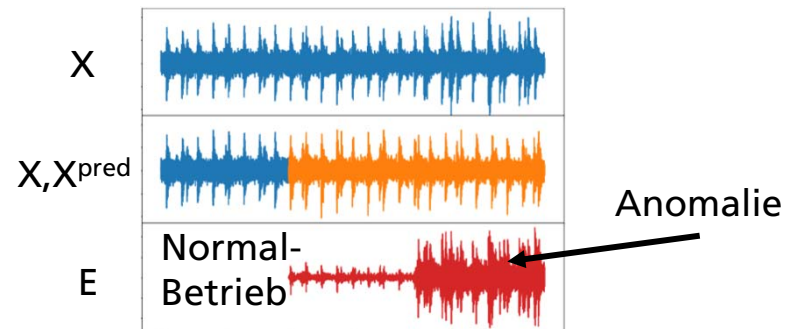
# Anomalieerkennung mittels Zeitreihenvorhersage

## ARIMA vs. RNN

### Trainingsphase:



### Produktivbetrieb:



# Anomalieerkennung mittels Zeitreihenvorhersage

## ARIMA vs. RNN – Prinzip

### ARIMA

- Gewichtete Summe aus:
  - Linearer Regression aus vorangegangenen Werten
  - Gleitendem Mittelwert
  - Weißem Rauschen
- Zeitreihe muss durch (mehrmaliges) Differenzieren stationär gemacht werden und der vom Modell vorhergesagte Wert anschließend wieder entsprechend oft integriert werden

→ Idee bei beiden:

Zeitreihenvorhersage funktioniert gut bei Daten, die den Trainingsdaten ähneln → Anomalie, wenn Vorhersagefehler dauerhaft hoch

### Rekurrente Neuronale Netze (RNN)

- Neuronale Netze mit „Zustandsgedächtnis“ → Output hängt nicht nur vom Input zur Zeit  $t$ , sondern auch von vorherigen Zuständen der Zeitreihe ab
- Neuronen-Input besteht aus Output-Werten der Vorgänger-Neuronen zum Zeitpunkt  $t$  sowie eigenem Output zum Zeitpunkt  $(t-1)$
- Output jeder Zelle ist der Zeitreihenwert zum Zeitpunkt  $(t+1)$

# Anomalieerkennung mittels Zeitreihenvorhersage

## ARIMA vs. RNN – Einschätzung

### ARIMA

- + Geringer Rechenaufwand
- + Einfaches Modell, welches bei einfachen Daten gute und nachvollziehbare Ergebnisse liefert
- Modellierungsgüte ist ab gewisser Datenmenge vom Verfahren begrenzt
- + Umweg über Differenzierung/Integration lässt auch nichtstationäre Daten zu

### Rekurrente Neuronale Netze (RNN)

- Höherer Rechenaufwand
- Komplexes Modell, welches große Menge an Trainingsdaten benötigt  
→ Overfitting-Gefahr
- + Modellierungsgüte besser, je mehr Daten
- + Kann (bei hinreichend vielen Trainingsdaten) auch gut mit nichtstationären Daten umgehen

---

# KI-basierte Anomaliedetektion in der Produktion


---

## Agenda

- Digitalisierung & Industrie 4.0
- Maschinelles Lernen
- Anomalieerkennung – einige nicht-neuronale Methoden
- Anomalieerkennung mittels Projektionsfehler
- Anomalieerkennung mittels Zeitreihenvorhersage
- **Beispiel aus der Stahlindustrie**
- Angebote des Fraunhofer EAS

# Beispiel aus der Stahlindustrie

## KI-basierte Zustandsüberwachung



### Motivation:

- Verschleiß der Stahlschneidmesser oftmals zu spät entdeckt
- Wunsch nach Erkennung von Ausbrüchen und stumpfen Messern

### Ziel:

- Verbesserung der Produktqualität
- Verringerung von Ausschuss

### Realisierung:

- Kombination aus Anomalieerkennung und Condition Monitoring

# Beispiel aus der Stahlindustrie

## KI-basierte Zustandsüberwachung

### Lösungsansatz:

- Kopplung von Schwingungssensormessungen mit weiteren Prozessgrößen
- Eliminierung von Störungen durch Filterung

### Schritte:

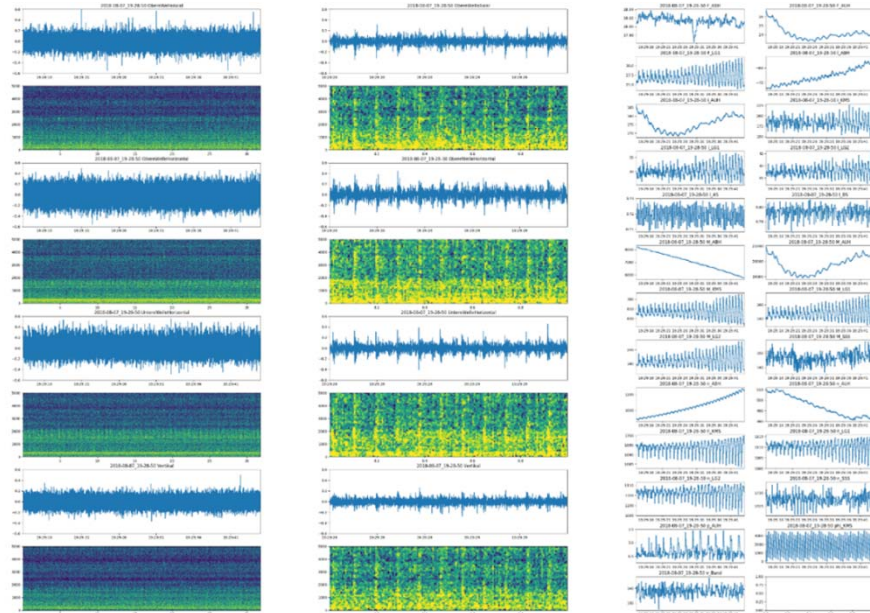
- Anomalieerkennung zur Identifikation potenzieller Merkmale
- Auswahl von geeigneten Merkmalen in Zeitverlauf und Spektrogramm

### Ergebnis:

- Ausbrüche überwiegend gut erkennbar (75% Erfolgsquote)
- Stumpfe Messer nicht erkennbar

### Nutzen:

- Wesentliche Reduktion von Ausschuss



---

# KI-basierte Anomaliedetektion in der Produktion

---

## Agenda

- Digitalisierung & Industrie 4.0
- Maschinelles Lernen
- Anomalieerkennung – einige nicht-neuronale Methoden
- Anomalieerkennung mittels Projektionsfehler
- Anomalieerkennung mittels Zeitreihenvorhersage
- Beispiel aus der Stahlindustrie
- Angebote des Fraunhofer IIS/EAS

# Angebote des Fraunhofer IIS/EAS

## Intelligente Datenanalyse



### Unsere Leistungen

- Machbarkeitsstudien zum Einsatz von Condition Monitoring Systemen und datenbasierter Qualitätssicherung
- Analyse, Klassifikation, Visualisierung vorhandener Mess- und Prozessdaten
- Anomalieerkennung
- Trendanalysen
- Datenanalyse auf verteilter Hardware
- Entwicklung kundenspezifischer Algorithmen und Software
- Umsetzung individueller Cloudlösungen

---

# VIELEN DANK FÜR IHRE AUFMERKSAMKEIT

---



**Dr. Olaf Enge-Rosenblatt**

Gruppenleiter  
Datenanalysesysteme

✉ [olaf.enge@eas.iis.fraunhofer.de](mailto:olaf.enge@eas.iis.fraunhofer.de)

☎ +49 351 4640-711

Fraunhofer-Institut für Integrierte Schaltungen IIS  
Institutsteil Entwicklung Adaptiver Systeme EAS  
Zeunerstraße 38  
01069 Dresden



[www.eas.iis.fraunhofer.de](http://www.eas.iis.fraunhofer.de)

# Literatur zu statistischen Verfahren, One-Class SVM und HMM

## Genannte Quellen:

- NIST/SEMATECH, "e-Handbook of Engineering Statistics," Version vom Okt. 2013. <https://www.itl.nist.gov/div898/handbook/>
- Paul Hayton et al., "Static and dynamic novelty detection methods for jet engine health monitoring," Philosophical Transactions of the Royal Society A, vol. 365, 2007.
- L. Rabiner and B. Juang, "An introduction to hidden markov models," IEEE ASSP Magazine, 1986.

## Weiterführende Literatur:

- Victoria J. Hodge, Jim Austin, „A Survey of Outlier Detection Methodologies," Artificial Intelligence Review, vol. 22, 2004.
- Marco A. F. Pimentel et al., "A review of novelty detection," Signal Processing, vol. 99, 2014.
- Peter J. Rousseuw, Mia Hubert, "Anomaly detection by robust statistics," WIREs Data Mining and Knowledge Discovery, vol. 8, 2018.
- T. Marwala and C. B. Vilakazi, "Computational intelligence for condition monitoring," 2007.

# Literatur zu PCA und Autoencoder

## Weiterführende Literatur:

- H. Ringberg, A. Soule, J. Rexford, and C. Diot, "Sensitivity of PCA for traffic anomaly detection," SIGMETRICS Perform. Eval. Rev., vol. 35, no. 1, p. 109, 2007.
- J. An and S. Cho, "Variational autoencoder based anomaly detection using reconstruction probability," Special Lecture on IE, vol. 2, no. 1, 2015.
- J. Sun, X. Wang, N. Xiong, and J. Shao, "Learning Sparse Representation With Variational Auto-Encoder for Anomaly Detection," IEEE Access, vol. 6, pp. 33353–33361, 2018.
- V. Flovik, „How to use machine learning for anomaly detection and condition monitoring“, 2018, <https://towardsdatascience.com/how-to-use-machine-learning-for-anomaly-detection-and-condition-monitoring-6742f82900d7>.
- V. Flovik, „Machine learning for anomaly detection and condition monitoring“, 2019, <https://towardsdatascience.com/machine-learning-for-anomaly-detection-and-condition-monitoring-d4614e7de770>.

# Literatur zu ARIMA und RNN

## Weiterführende Literatur:

- M. de Nadai and M. van Someren, "Short-term anomaly detection in gas consumption through ARIMA and Artificial Neural Network forecast," in 2015 IEEE Workshop on Environmental, Energy and Structural Monitoring Systems (EESMS 2015): Trento, Italy, 9 - 10 July 2015, Trento, Italy, 2015, pp. 250–255.
- L. Bontemps, L. van Cao, J. McDermott, and N.-A. Le-Khac, "Collective Anomaly Detection Based on Long Short-Term Memory Recurrent Neural Networks," in Future Data and Security Engineering, 2016, pp. 141–152.
- C. Dabakoglu, „Time Series Forecasting — ARIMA, LSTM, Prophet with Python“, 2019, <https://medium.com/@cdabakoglu/time-series-forecasting-arma-lstm-prophet-with-python-e73a750a9887>.