

Predictive Maintenance und Qualitätssicherung mit Machine Learning in der Praxis

Veronika Putz

Team Lead „Data Analysis & AI“
Linz Center of Mechatronics GmbH

17.10.2023

Predictive Maintenance und Qualitätssicherung mit Machine Learning in der Praxis

LCM - Wir über uns

Was ist KI?

Was verspricht man sich vom Einsatz von KI...

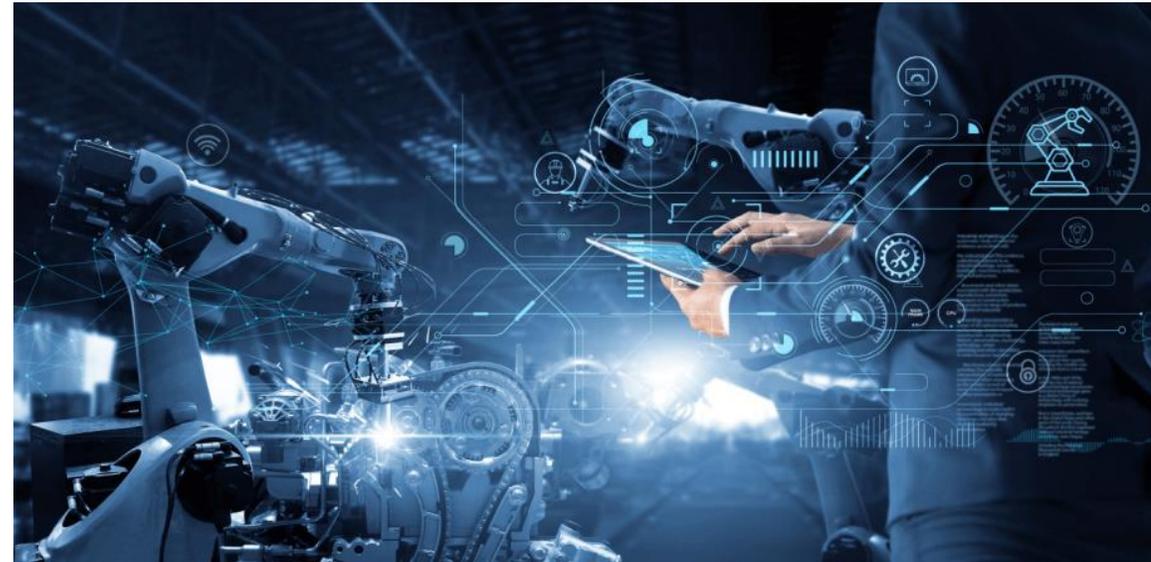
... zur Qualitätssicherung?

... zur Zustandsüberwachung?

KI in der Praxis: Womit/Wie soll man beginnen?

... Pragmatischer Ansatz in 5 Schritten mit Beispielen aus der Praxis

Fazit



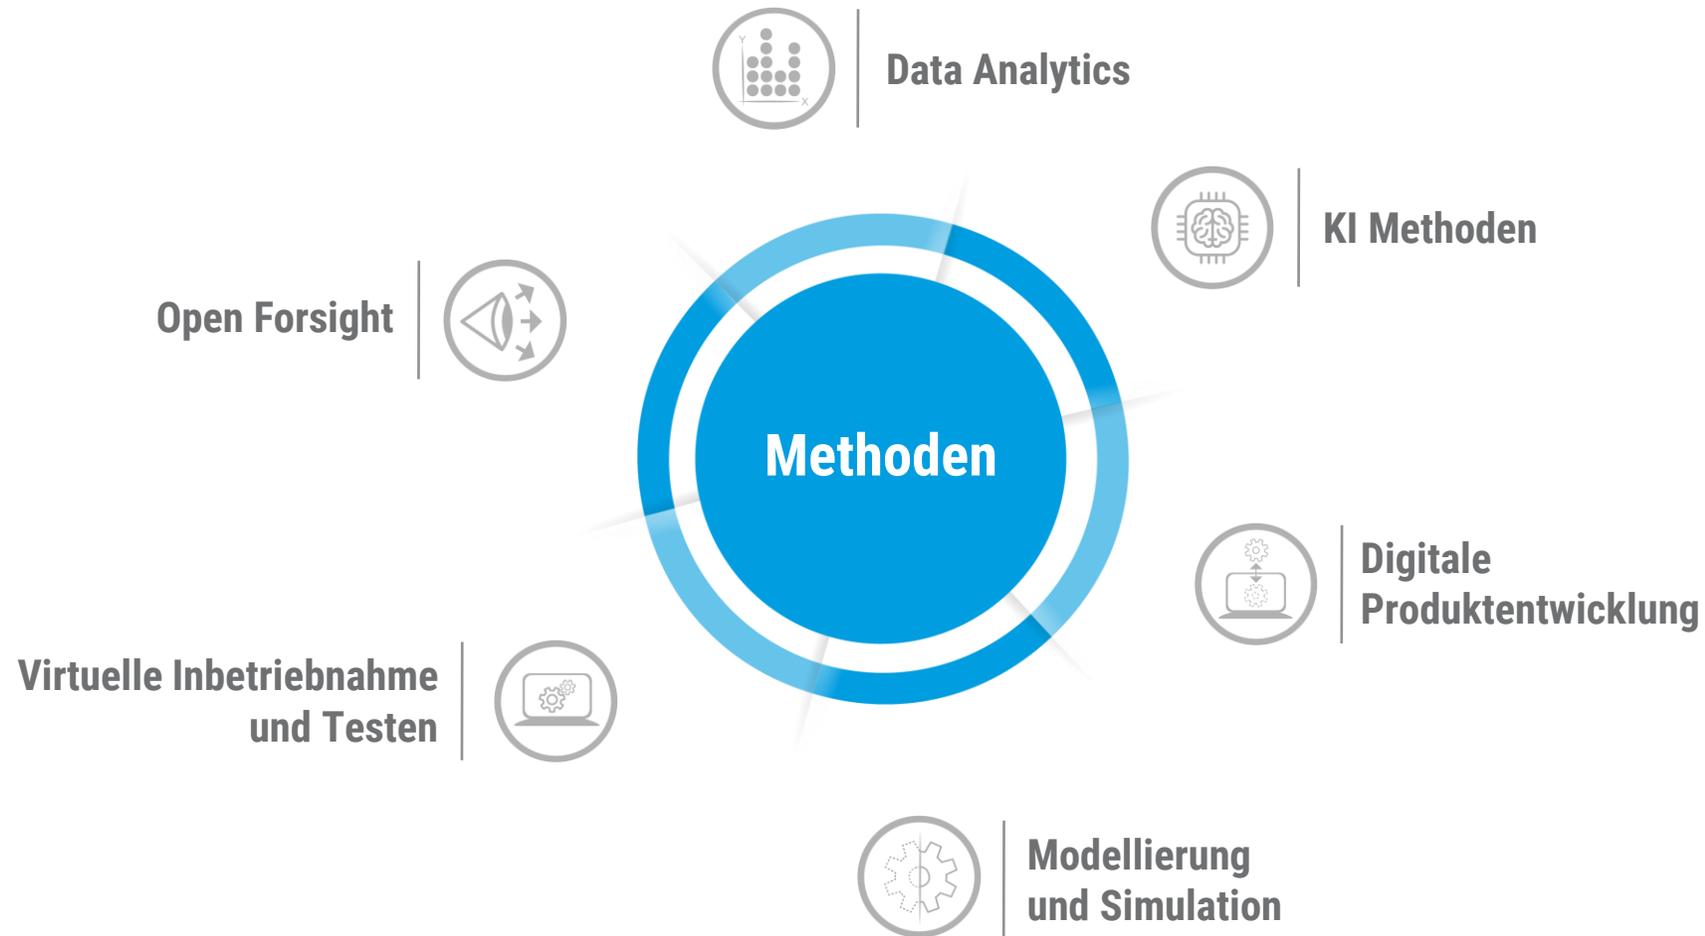
LINZ CENTER OF MECHATRONICS GMBH - WIR ÜBER UNS



LINZ CENTER OF MECHATRONICS GMBH - WIR ÜBER UNS



LINZ CENTER OF MECHATRONICS GMBH - WIR ÜBER UNS



Predictive Maintenance und Qualitätssicherung mit Machine Learning in der Praxis

LCM - Wir über uns

Was ist KI?

Was verspricht man sich vom Einsatz von KI...

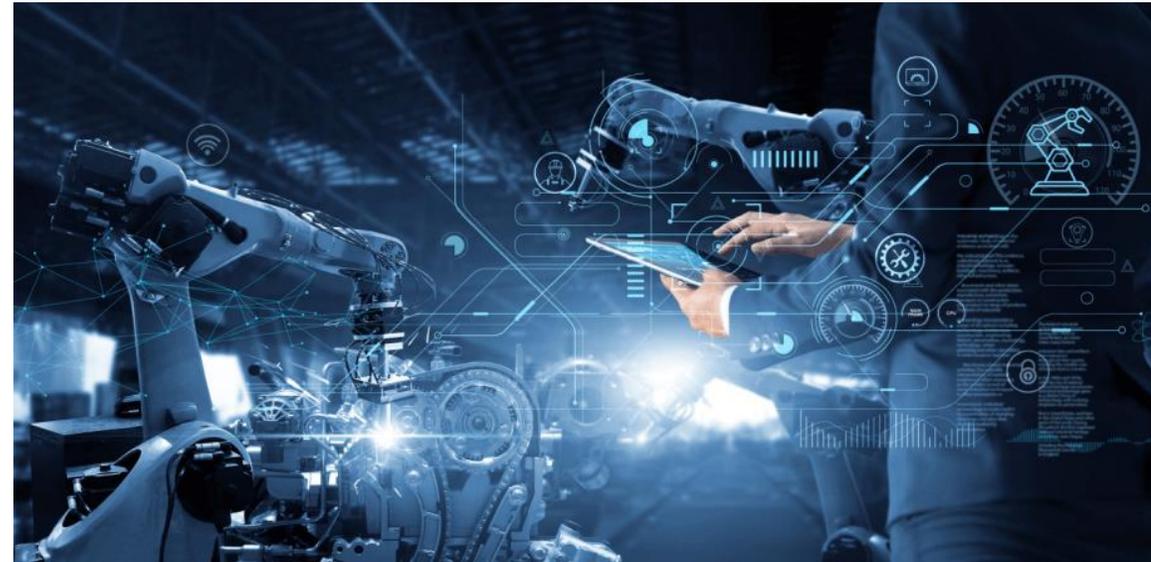
... zur Qualitätssicherung?

... zur Zustandsüberwachung?

KI in der Praxis: Womit/Wie soll man beginnen?

... Pragmatischer Ansatz in 5 Schritten mit
Beispielen aus der Praxis

Fazit

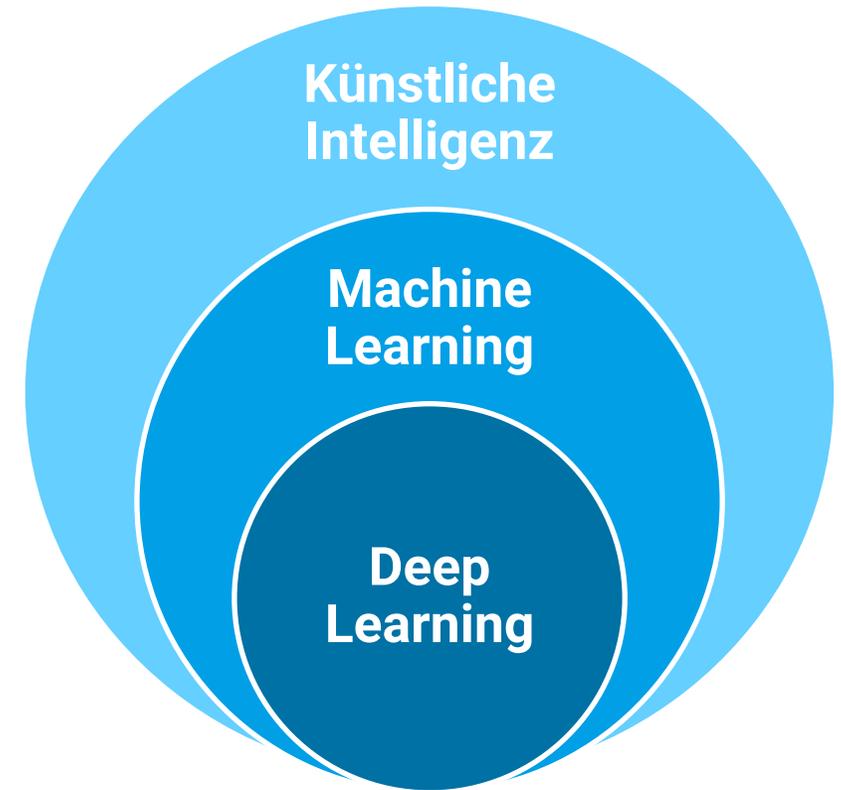


Was ist Künstliche Intelligenz?

Künstliche Intelligenz bezeichnet die Fähigkeit einer Maschine, intelligentes menschliches Verhalten nachzuahmen oder zu übertreffen.

Machine Learning ist ein Teilbereich der KI. Dabei lernt ein System automatisch aus Erfahrungen (=Daten), um Aufgaben zu erfüllen und sich dabei zu verbessern.

Deep Learning ist ein Teilbereich des Machine Learnings, der Algorithmen verwendet, die der Funktionsweise des menschlichen Gehirns ähneln.



Was verspricht man sich vom Einsatz von KI...

... in der Qualitätssicherung und in der automatisierten Zustandsüberwachung?

- 1. Generelle Machbarkeit:** Automatisierte Qualitätssicherung | Zustandsüberwachung wird oft erst durch den Einsatz von KI ermöglicht!
 - Mit KI können große Datenmengen in Echtzeit analysiert werden
 - Mit KI können komplexe Muster erkannt und zugeordnet werden (Stichwort Fehlergeräusch)
- 2. Verbesserte Genauigkeit und Effizienz**
- 3. Robustheit:** Mit KI kann hohe Robustheit bei unbekanntem Rahmenbedingungen erzielt werden:
 - Wechselnde Umgebungsbedingungen (Umgebungstemperatur, Sonneneinstrahlung, unvorhersehbare Störungen, ...)
 - Wechselnde Betriebsparameter
 - Wechselnde unbekannt Parameter (schwankende Rohstoffparameter, ...)

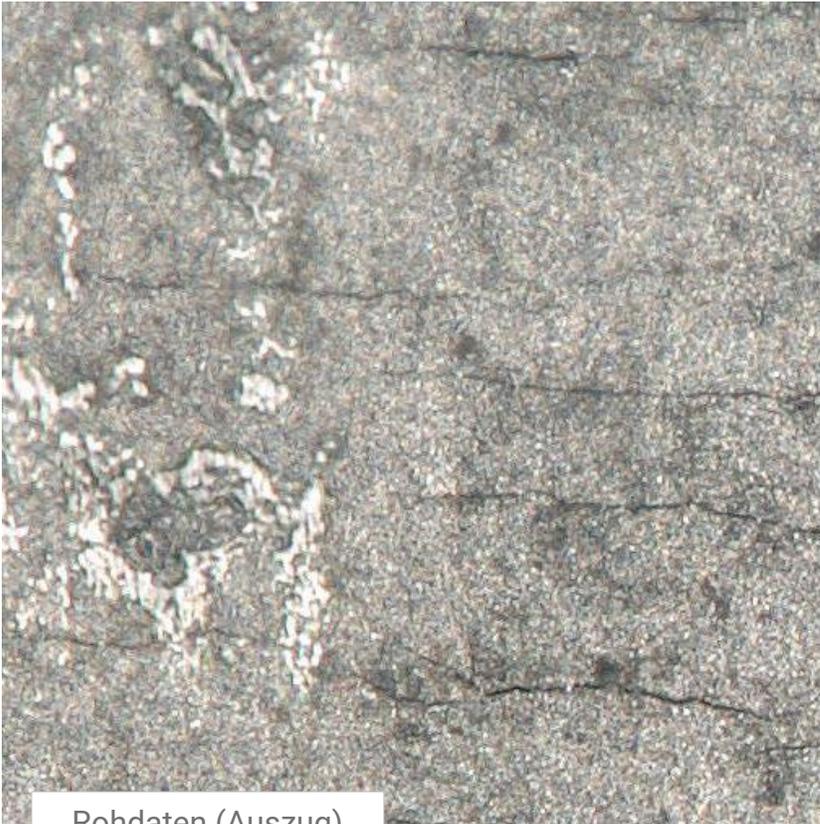
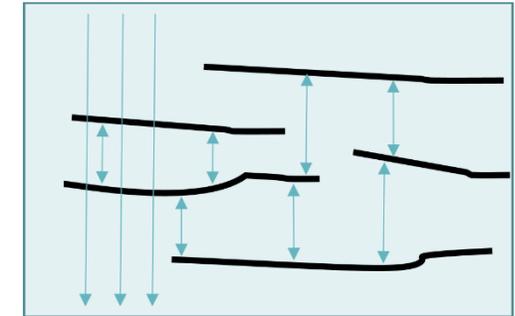


Beispiel zur bildbasierten Qualitätssicherung

Vermessung von Haarrissen mit neuronalem Netz

Anforderungen

- Risse sollen erkannt UND vermessen werden
- Große Datenmenge (400 Mikroskopbilder je Probe)
- Die Risse sind im Bild sehr dünn (Breite ~ 1 px)
- Artefakte erschweren die Risserkennung
- Mit klassischer Bildverarbeitung kann keine exakte und robuste Lösung erhalten werden



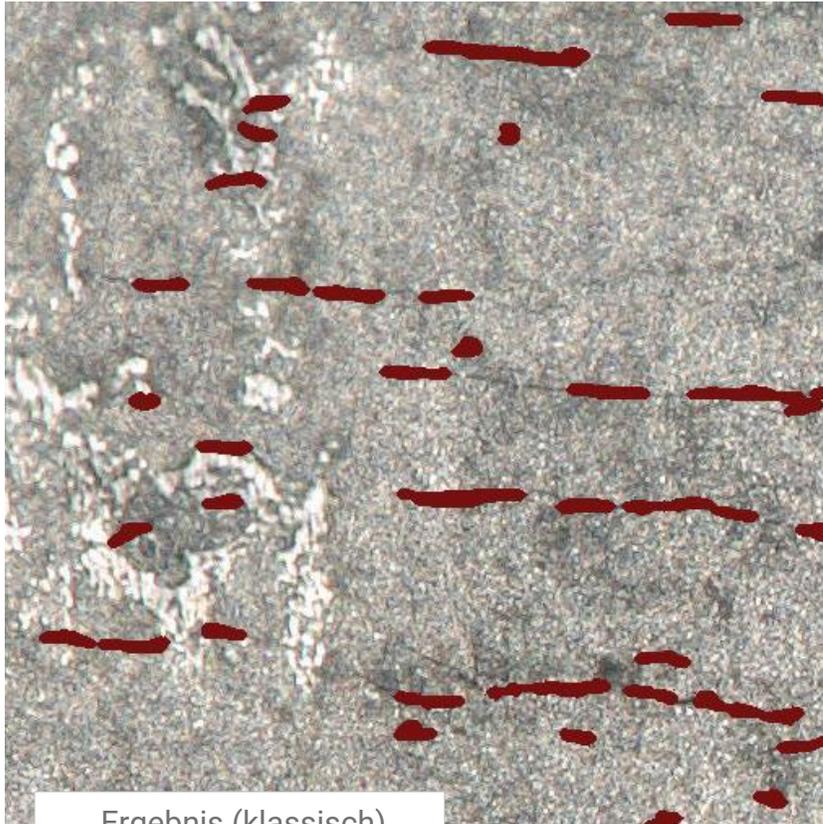
Rohdaten (Auszug)



Sabrina Fleischanderl et al.: "CNN-based crack detection in oxide layers of hot rolled steel sheet samples for the validation of a pickling process model". In Proceedings of 3rd Symposium on Pattern Recognition and Applications (SPRA '22).

Beispiel zur bildbasierten Qualitätssicherung

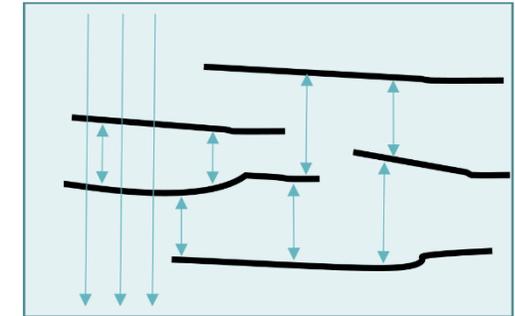
Vermessung von Haarrissen mit neuronalem Netz



Ergebnis (klassisch)

Anforderungen

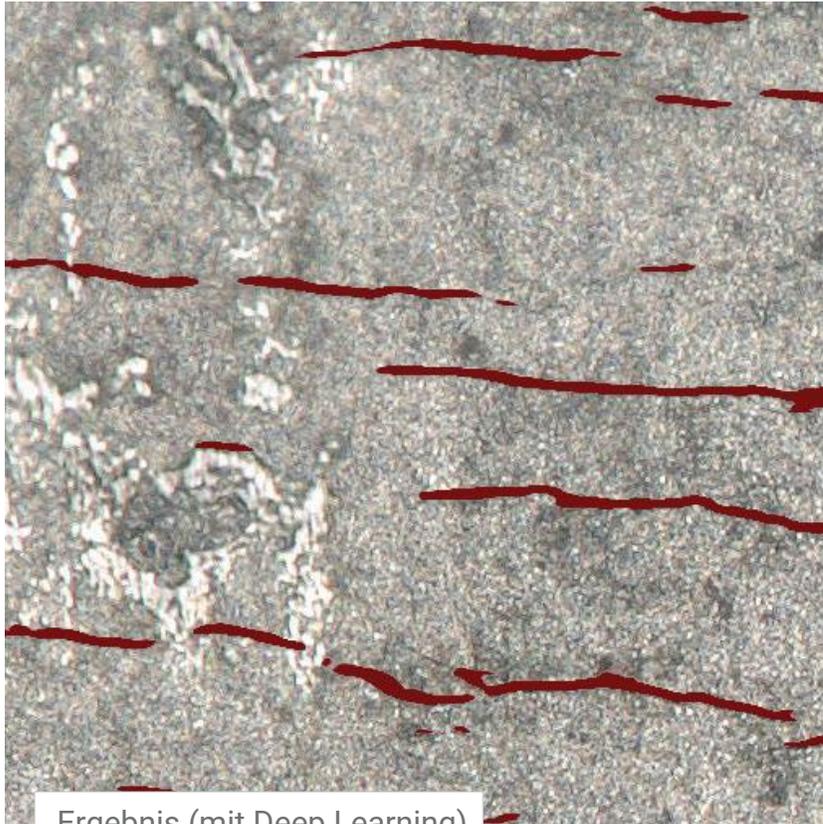
- Risse sollen erkannt UND vermessen werden
- Große Datenmenge (400 Mikroskopbilder je Probe)
- Die Risse sind im Bild sehr dünn (Breite ~ 1 px)
- Artefakte erschweren die Risserkennung
- Mit klassischer Bildverarbeitung kann keine exakte und robuste Lösung erhalten werden



Sabrina Fleischanderl et al.: "CNN-based crack detection in oxide layers of hot rolled steel sheet samples for the validation of a pickling process model". In Proceedings of 3rd Symposium on Pattern Recognition and Applications (SPRA '22).

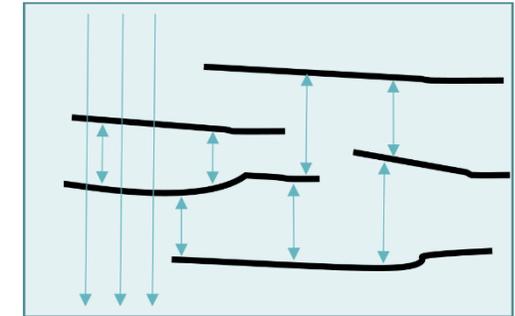
Beispiel zur bildbasierten Qualitätssicherung

Vermessung von Haarrissen mit neuronalem Netz



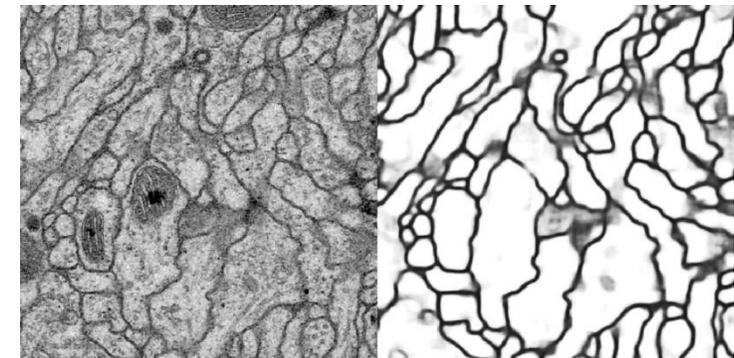
Anforderungen

- Risse sollen erkannt UND vermessen werden
- Große Datenmenge (400 Mikroskopbilder je Probe)
- Die Risse sind im Bild sehr dünn (Breite ~ 1 px)
- Artefakte erschweren die Risserkennung
- Mit klassischer Bildverarbeitung kann keine exakte und robuste Lösung erhalten werden



Lösung mit Deep Learning

- 60 Bilder wurden händisch annotiert
- Zusätzliche Trainingsdaten: Frei verfügbarer Datensatz (ISBI 2012 Challenge, Zellmembrandaten)
- Exakte und stabile Lösung bei minimalem Aufwand



Beispielbild, welches zum Training verwendet wurde

Ergebnis (mit Deep Learning)



Sabrina Fleischanderl et al.: "CNN-based crack detection in oxide layers of hot rolled steel sheet samples for the validation of a pickling process model". In Proceedings of 3rd Symposium on Pattern Recognition and Applications (SPRA '22).

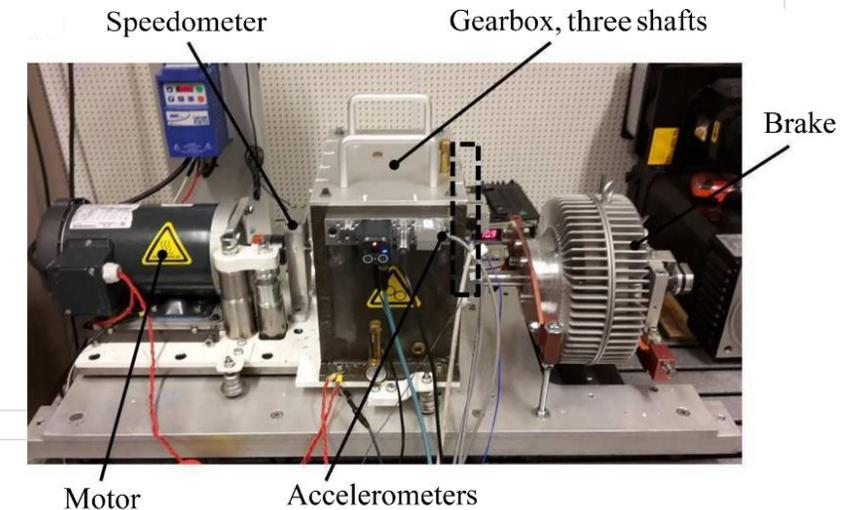
Fehlererkennung an schadhafte Kugellagern

Anforderungen

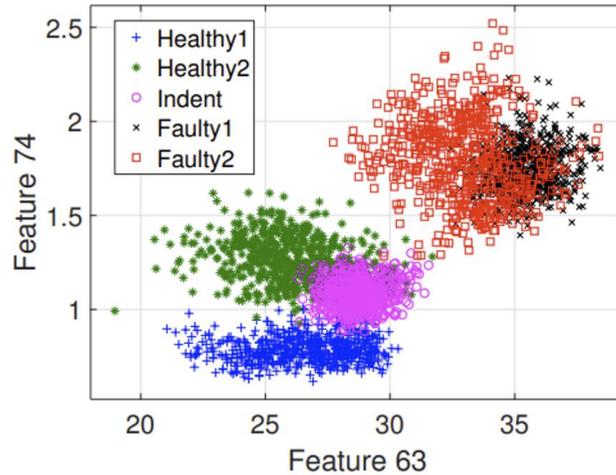
- Fehlererkennung und -Klassifizierung an einem Kugellager (verbaut in einer Getriebebox)
- Beschleunigungssensor am Gehäuse
- Messung von 5 Exemplaren:
2 fehlerfrei, 1 leicht beschädigt,
2 deutlich beschädigt

Lösung mit Machine Learning

- Berechnung von > 80 statistischen Kenngrößen (Features)
- Daraus automatisierte Auswahl der 4 besten Kenngrößen, um die unterschiedlichen Zustände zu unterscheiden
- Klassifizierung



Darstellung von 2 der > 80 berechneten Kenngrößen für 5 Exemplare



Qualitätssicherung mit Vibrationsmessung

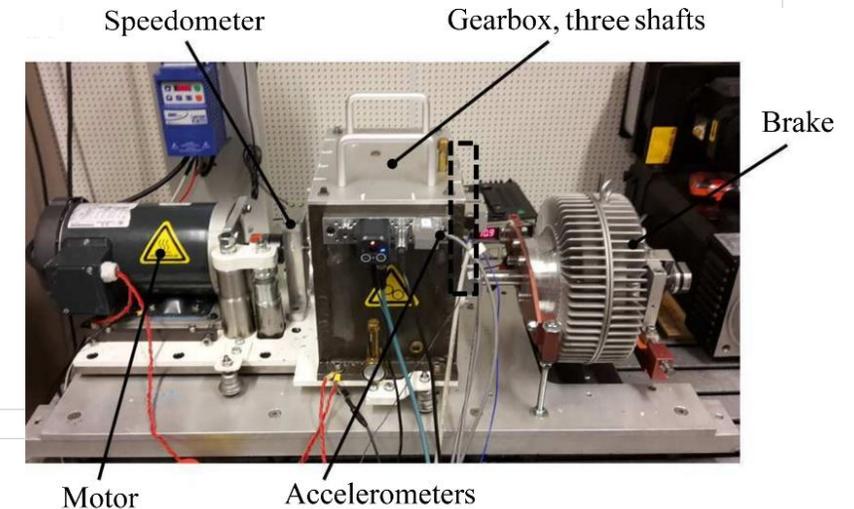
Fehlererkennung an schadhafte Kugellagern

Anforderungen

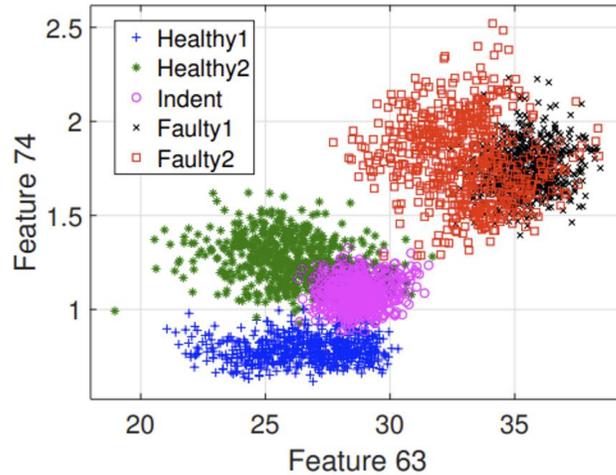
- Fehlererkennung und -Klassifizierung an einem Kugellager (verbaut in einer Getriebebox)
- Beschleunigungssensor am Gehäuse
- Messung von 5 Exemplaren: 2 fehlerfrei, 1 leicht beschädigt, 2 deutlich beschädigt

Lösung mit Machine Learning

- Berechnung von > 80 statistischen Kenngrößen (Features)
- Daraus automatisierte Auswahl der 4 besten Kenngrößen, um die unterschiedlichen Zustände zu unterscheiden
- Klassifizierung



Darstellung von 2 der > 80 berechneten Kenngrößen für 5 Exemplare



Klassifizierungsergebnis

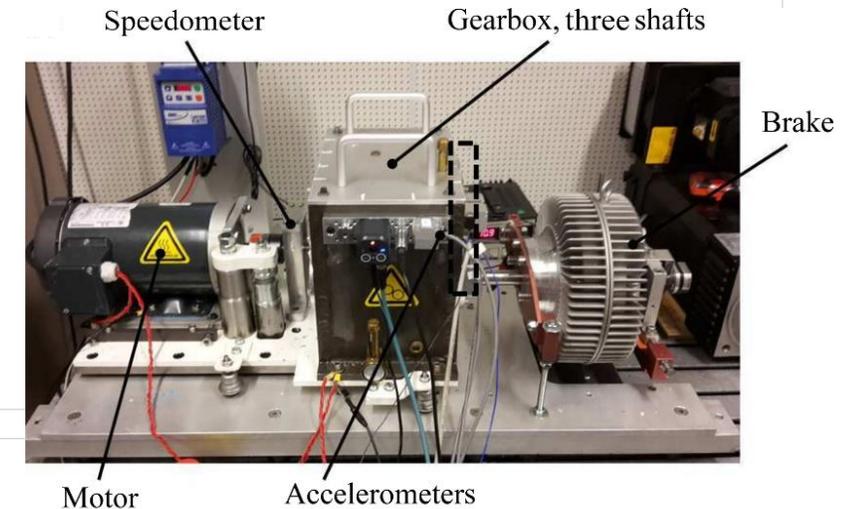
		Estimated State		
		Healthy	Indent	Faulty
True State	Healthy1	177	22	0
	Healthy2	199	0	0
	Indent	0	199	0
	Faulty1	0	0	199
	Faulty2	0	0	199

Qualitätssicherung mit Vibrationsmessung

Fehlererkennung an schadhafte Kugellagern

Anforderungen

- Fehlererkennung und -Klassifizierung an einem Kugellager (verbaut in einer Getriebebox)
- Beschleunigungssensor am Gehäuse
- Messung von 5 Exemplaren: 2 fehlerfrei, 1 leicht beschädigt, 2 deutlich beschädigt



Lösung mit Machine Learning

- Berechnung von > 80 statistischen Kenngrößen (Features)
- Daraus automatisierte Auswahl der 4 besten Kenngrößen, um die unterschiedlichen Zustände zu unterscheiden
- Klassifizierung



Zustandsüberwachung mit Vibrationsmessung

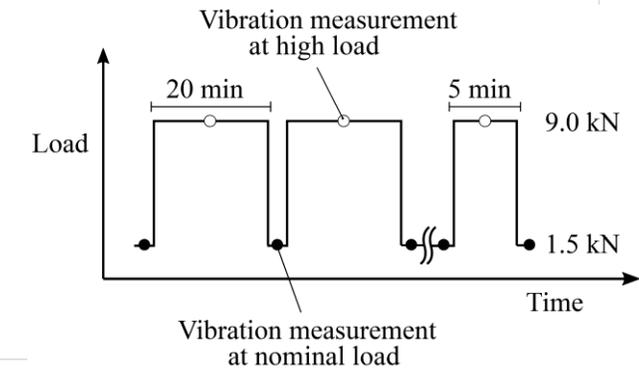
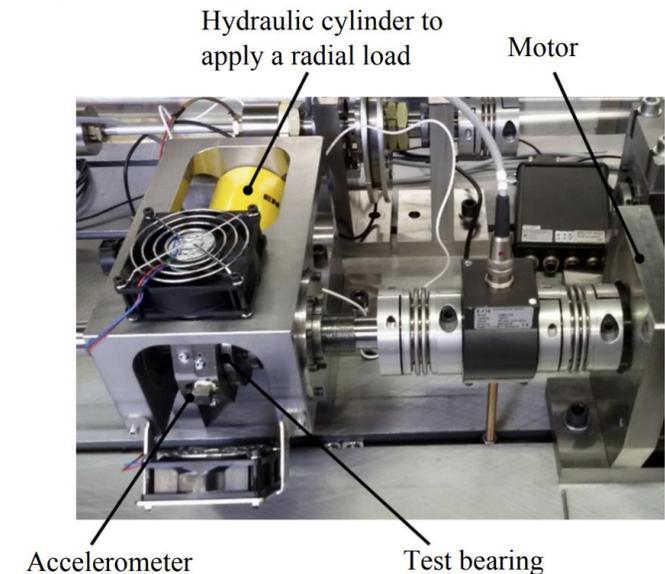
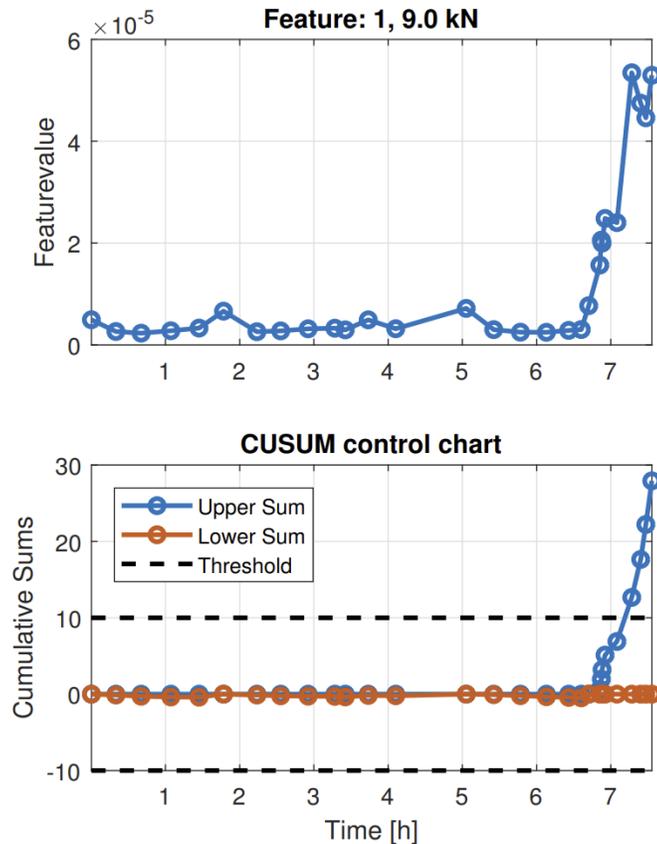
Anomalieerkennung bei Kugellagern

Anforderungen

- Wie erkennt man graduelle Abnutzung?
- Prüfstand ermöglicht Betrieb unter variierender Last und künstliche Alterung (Abnutzung kann innerhalb von 8 Stunden erzeugt werden)
- Messung mit Beschleunigungssensor am Gehäuse
- Keine Trainingsdaten zum Fehlerfall vorhanden

Lösung mit Machine Learning

- Berechnung von geeigneten Kenngrößen (Features)
- Beobachten dieser Features (Methode: CUSUM)
- Ausreißer werden bei der Auswertung unterdrückt
- Schleichende Zustandsänderung ist gut zu erkennen



 Ooijevaar, T., Pichler, K., Di, Y., & Hesch, C. A comparison of vibration based bearing fault diagnostic methods. *Int. Journal of Prognostics and Health Management*, 2019, 10. Jg., Nr. 2

 Pichler, K. et al: *Data-driven vibration-based bearing fault diagnosis using non-steady-state data*. *Journal of Sensors and Sensor Systems*, 2020, Nr. 9.

Predictive Maintenance und Qualitätssicherung mit Machine Learning in der Praxis

LCM - Wir über uns

Was ist KI?

Was verspricht man sich vom Einsatz von KI...

... zur Qualitätssicherung?

... zur Zustandsüberwachung?

KI in der Praxis: Womit/Wie soll man beginnen?

... Pragmatischer Ansatz in 5 Schritten mit Beispielen aus der Praxis

Fazit



KI in der Praxis: Womit/Wie soll man beginnen?

Pragmatischer Ansatz

1. Ein realistisches Bild erhalten - den Hype von realisierbaren Anwendungen trennen.
2. Fachliches Grundwissen zur KI aufbauen
3. Domänenwissen nutzen
4. Frühzeitig Datenbasis aufbauen
5. Schrittweise Umsetzung

KI in der Praxis: Womit/Wie soll man beginnen?

Pragmatischer Ansatz

- 1. Ein realistisches Bild erhalten - den Hype von realisierbaren Anwendungen trennen**
Use Cases formulieren und nach technischer Umsetzbarkeit, Komplexitätsgrad und nach dem möglichen wirtschaftlichen Impact priorisieren (Business Case formulieren)
- 2. Fachliches Grundwissen zur KI aufbauen**
- 3. Domänenwissen nutzen**
- 4. Frühzeitig Datenbasis aufbauen**
- 5. Schrittweise Umsetzung**

KI in der Praxis: Womit/Wie soll man beginnen?

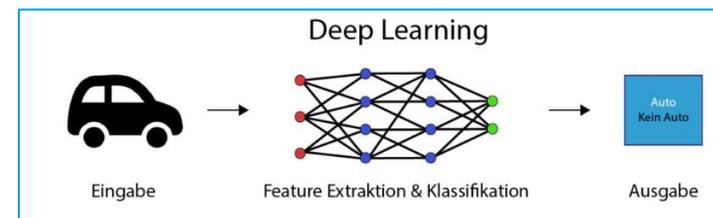
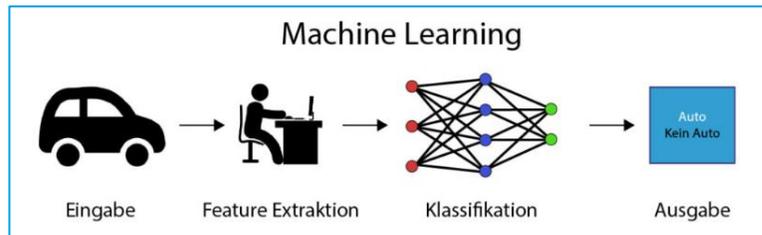
Pragmatischer Ansatz

1. Ein realistisches Bild erhalten - den Hype von realisierbaren Anwendungen trennen.
2. **Fachliches Grundwissen zur KI aufbauen** – innerbetrieblich, aber auch mit Hilfe externer Ressourcen
3. Domänenwissen nutzen
4. Frühzeitig Datenbasis aufbauen
5. Schrittweise Umsetzung

Fachliches Grundwissen aufbauen: Crashkurs

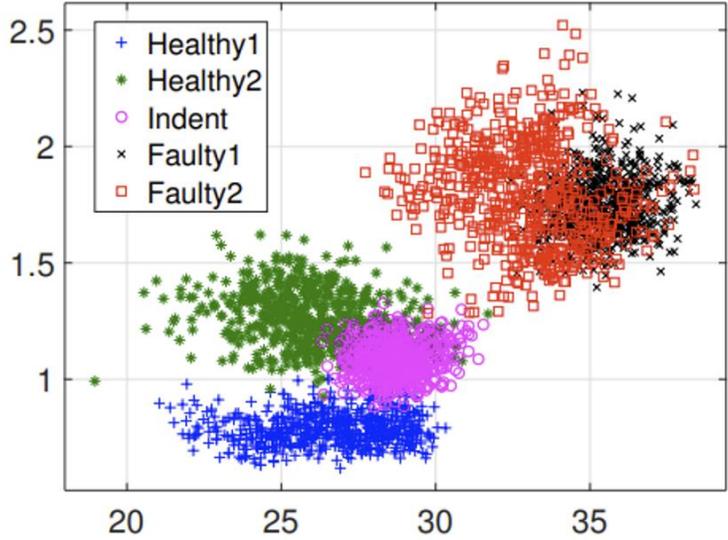
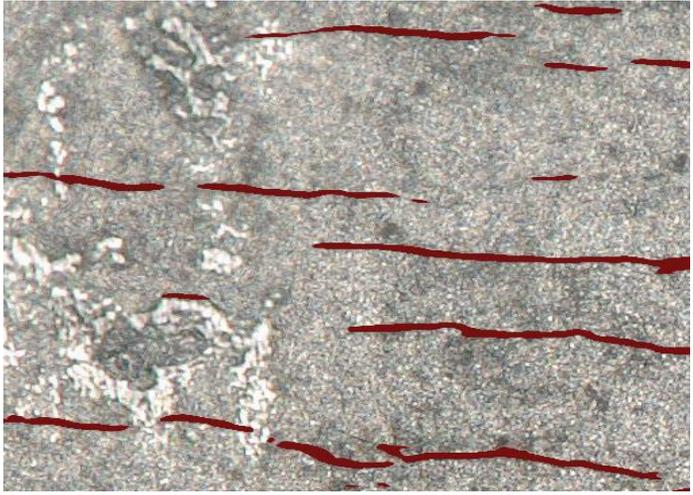
Merkmalsbasiertes Lernen oder Deep Learning?

Merkmalsbasiertes Lernen	Deep Learning
Manuelle Definition von relevanten Merkmalen („Kenngößen“, „Features“)	Automatische Extraktion der relevanten Merkmale („End-to-End learning“)
 Methode ist physikalisch erklärbar Expertenwissen kann eingebracht werden	 „Black-Box“ Funktion
 Zeitaufwändiges „Engineering“, um Features zu definieren und zu generieren  Danach vergleichsweise geringerer Rechenaufwand	 Trainieren des Netzwerks benötigt viel Zeit, aber (z.T.) automatisierbar  Höherer Rechenaufwand in der Anwendung
 Auch für kleinere Datenmengen geeignet	 Ausreichend große Datenmengen nötig



Fachliches Grundwissen aufbauen: Crashkurs

Merkmalsbasiertes Lernen oder Deep Learning?

Merkmalsbasiertes Lernen	Deep Learning
<p data-bbox="377 454 1085 488">Featurebasierte Fehlerklassifizierung</p>  <p>The scatter plot shows five distinct clusters of data points in a 2D space. The x-axis ranges from 20 to 35, and the y-axis ranges from 1 to 2.5. The legend indicates: Healthy1 (blue plus signs), Healthy2 (green asterisks), Indent (purple circles), Faulty1 (black crosses), and Faulty2 (red squares). The clusters are well-separated, indicating good feature-based classification performance.</p>	<p data-bbox="1375 454 2074 488">Risserkennung mit neuronalem Netz</p>  <p>The image shows a grayscale texture of a material surface with several dark, irregular lines representing cracks. These cracks are highlighted with thick, dark red lines, demonstrating the output of a neural network for crack detection.</p>

Fachliches Grundwissen aufbauen: Crashkurs

Welche Daten sind zum Aufbau des Modells erforderlich/verfügbar?

	Supervised Learning	Unsupervised Learning	Transfer Learning
Erforderliche Trainingsdaten	Trainingsdaten sind annotiert und decken alle möglichen Zustände des Systems oder Prüflings ab	Trainingsdaten sind nicht annotiert und decken nicht alle Zustände ab	Training des Modells mit einem Datensatz, Anwendung auf einem anderen Datensatz
Anwendungs-Beispiele	Fehlererkennung Fehlerklassifizierung Bestimmen der Restnutzungsdauer	Anomalie-Erkennung Clustering bei unbekanntem Systemparametern	Anlernen eines KI-Modells mit Daten eines Prüfstands oder einer Simulation

*) Unvollständige Aufzählung, weitere Modellierungs- und Lernstrategien würden hier den Rahmen sprengen

Fachliches Grundwissen aufbauen: Crashkurs

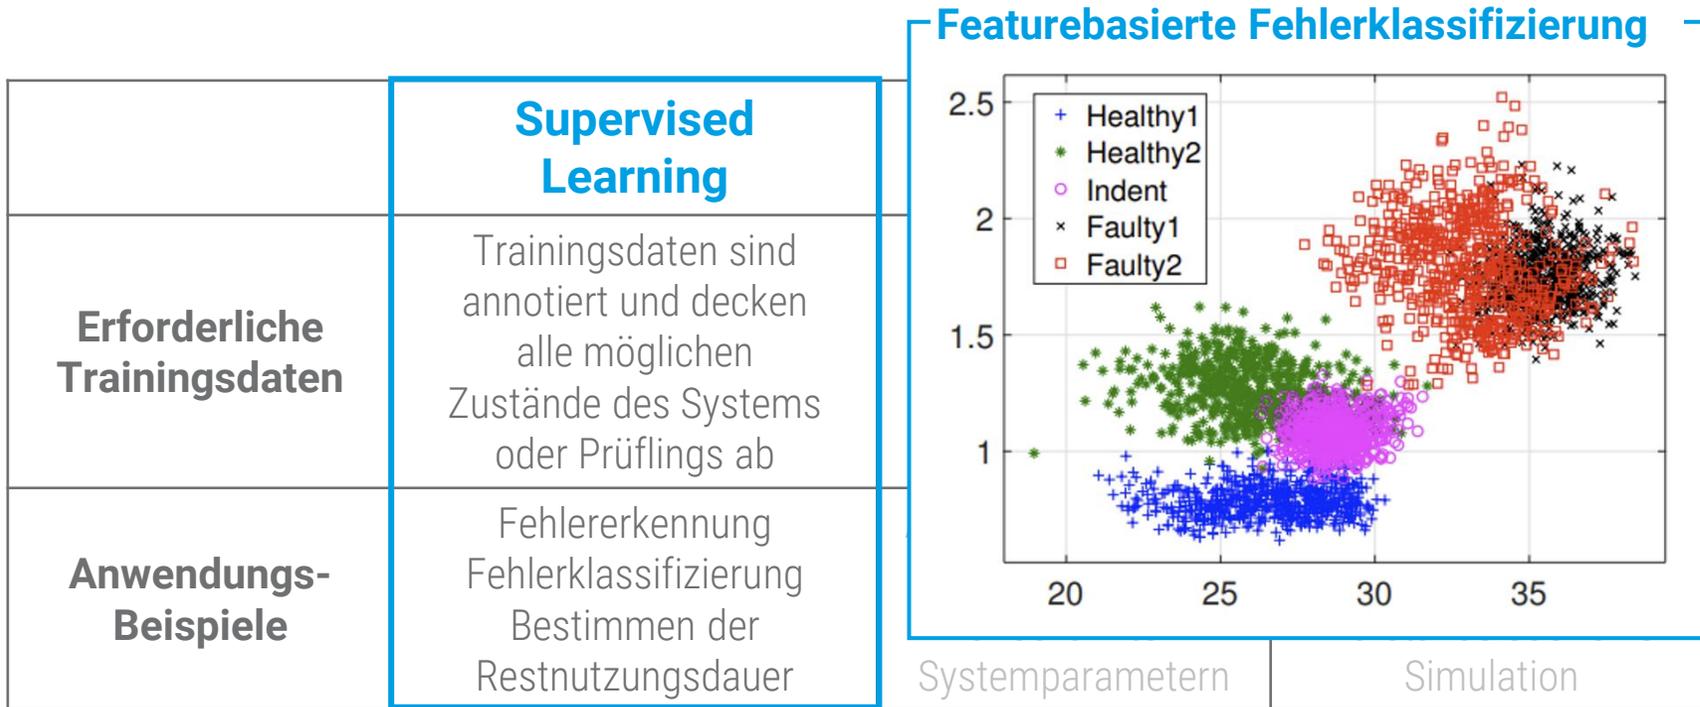
Welche Daten sind zum Aufbau des Modells erforderlich/verfügbar?

	Supervised Learning	Unsupervised Learning	Transfer Learning
Erforderliche Trainingsdaten	Trainingsdaten sind annotiert und decken alle möglichen Zustände des Systems oder Prüflings ab	Trainingsdaten sind nicht annotiert und decken nicht alle Zustände ab	Training des Modells mit einem Datensatz, Anwendung auf einem anderen Datensatz
Anwendungs-Beispiele	Fehlererkennung Fehlerklassifizierung Bestimmen der Restnutzungsdauer	Anomalie-Erkennung Clustering bei unbekanntem Systemparametern	Anlernen eines KI-Modells mit Daten eines Prüfstands oder einer Simulation

*) Unvollständige Aufzählung, weitere Modellierungs- und Lernstrategien (z.B. Reinforcement Learning) würden hier den Rahmen sprengen

Fachliches Grundwissen aufbauen: Crashkurs

Welche Daten sind zum Aufbau des Modells erforderlich/verfügbar?



*) Unvollständige Aufzählung, weitere Modellierungs- und Lernstrategien (z.B. Reinforcement Learning) würden hier den Rahmen sprengen

Fachliches Grundwissen aufbauen: Crashkurs

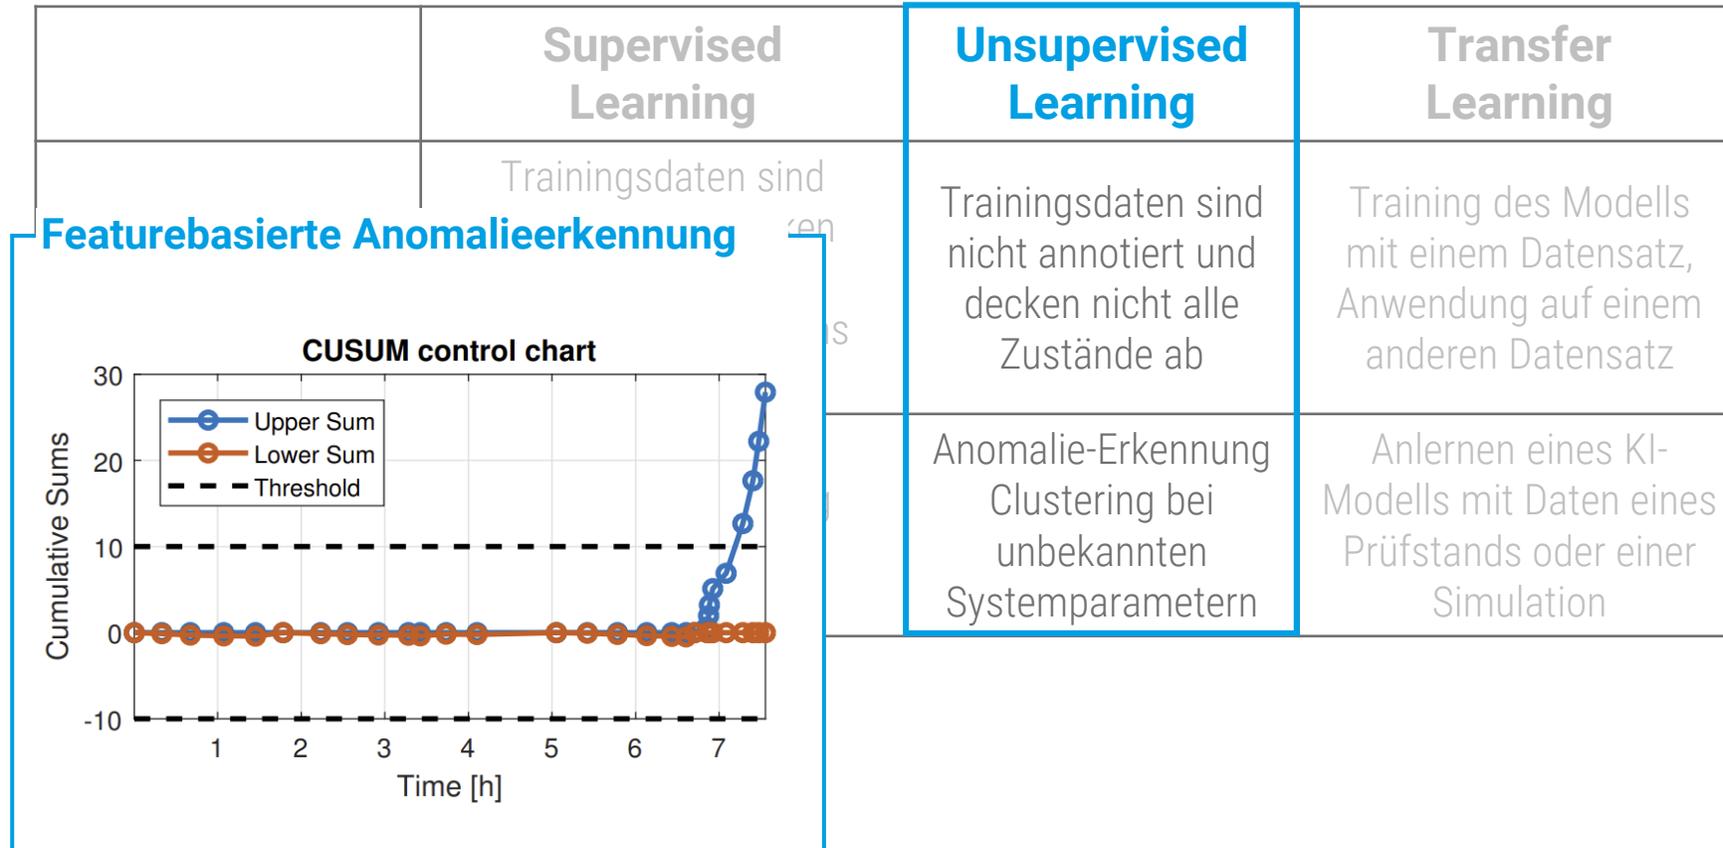
Welche Daten sind zum Aufbau des Modells erforderlich/verfügbar?

	Supervised Learning	Unsupervised Learning	Transfer Learning
Erforderliche Trainingsdaten	Trainingsdaten sind annotiert und decken alle möglichen Zustände des Systems oder Prüflings ab	Trainingsdaten sind nicht annotiert und decken nicht alle Zustände ab	Training des Modells mit einem Datensatz, Anwendung auf einem anderen Datensatz
Anwendungs-Beispiele	Fehlererkennung Fehlerklassifizierung Bestimmen der Restnutzungsdauer	Anomalie-Erkennung Clustering bei unbekanntem Systemparametern	Anlernen eines KI-Modells mit Daten eines Prüfstands oder einer Simulation

*) Unvollständige Aufzählung, weitere Modellierungs- und Lernstrategien würden hier den Rahmen sprengen

Fachliches Grundwissen aufbauen: Crashkurs

Welche Daten sind zum Aufbau des Modells erforderlich/verfügbar?



*) Unvollständige Aufzählung, weitere Modellierungs- und Lernstrategien würden hier den Rahmen sprengen

Fachliches Grundwissen aufbauen: Crashkurs

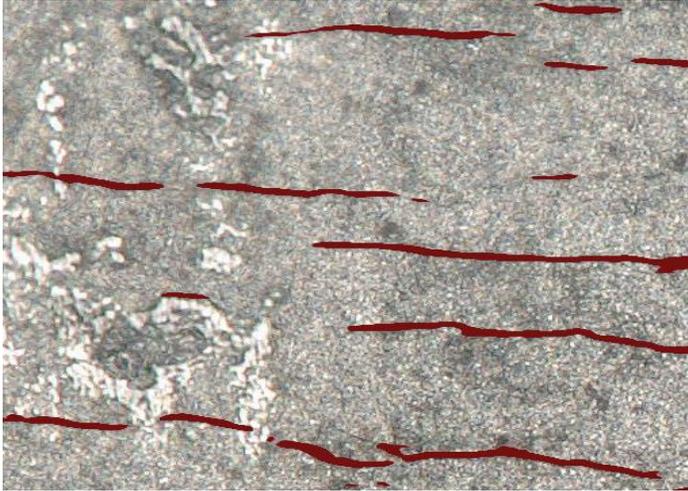
Welche Daten sind zum Aufbau des Modells erforderlich/verfügbar?

	Supervised Learning	Unsupervised Learning	Transfer Learning
Erforderliche Trainingsdaten	Trainingsdaten sind annotiert und decken alle möglichen Zustände des Systems oder Prüflings ab	Trainingsdaten sind nicht annotiert und decken nicht alle Zustände ab	Training des Modells mit einem Datensatz, Anwendung auf einem anderen Datensatz
Anwendungs-Beispiele	Fehlererkennung Fehlerklassifizierung Bestimmen der Restnutzungsdauer	Anomalie-Erkennung Clustering bei unbekanntem Systemparametern	Anlernen eines KI-Modells mit Daten eines Prüfstands oder einer Simulation

*) Unvollständige Aufzählung, weitere Modellierungs- und Lernstrategien würden hier den Rahmen sprengen

Fachliches Grundwissen aufbauen: Crashkurs

Welche Daten sind zum Aufbau des Modells erforderlich/verfügbar?

	„umgelernte“ Risserkennung mit NN		
			
Erforderliche Trainingsdaten			Transfer Learning
			Training des Modells mit einem Datensatz, Anwendung auf einem anderen Datensatz
Anwendungs-Beispiele			Anlernen eines KI-Modells mit Daten eines Prüfstands oder einer Simulation
	Restnutzungsdauer	Systemparametern	

*) Unvollständige Aufzählung, weitere Modellierungs- und Lernstrategien würden hier den Rahmen sprengen

KI in der Praxis: Womit/Wie soll man beginnen?

Pragmatischer Ansatz

1. Ein realistisches Bild erhalten - den Hype von realisierbaren Anwendungen trennen.
2. Fachliches Grundwissen zur KI aufbauen
3. **Domänenwissen nutzen** - zur Beschreibung von Anwendungsfällen und Abhängigkeiten und als Teil des Lösungsansatzes. **Hybride Ansätze** (Daten + Domänenwissen) können die Rechenlast reduzieren, die Leistungsfähigkeit erhöhen und die Zuverlässigkeit steigern.
4. Frühzeitig Datenbasis aufbauen
5. Schrittweise Umsetzung

Objekterkennung
mit
Deep Learning



Objekterkennung
mit
Deep Learning

Kombination
mit
physikalischem
Modell



KI in der Praxis: Womit/Wie soll man beginnen?

Pragmatischer Ansatz

1. Ein realistisches Bild erhalten - den Hype von realisierbaren Anwendungen trennen.
2. Fachliches Grundwissen zur KI aufbauen
3. Domänenwissen nutzen
4. **Frühzeitig Datenbasis aufbauen** – vorhandene Maschinendaten durchgängig aufzeichnen, durch Retrofitting zusätzliche Datenquellen schaffen, aber auch Fehlerfälle dokumentieren, fehlerhafte Teile aufbewahren.
Vorhandene Daten und Fehlerfälle möglichst strukturieren/annotieren.
5. **Schrittweise Umsetzung**



Zustandsüberwachung in der Gesteinsmahlanlage mit Mobilgerät



Betriebsbereite Kugelmühle

Datenbasis aufbauen – Nutzen bestehender Maschinendaten

IloT und Prozessmodellierung Gesteinsmahlanlage

Anforderungen

- Senkung des Anlagen-Energieverbrauchs
- Optimales Mahlprodukt bei schwankender Rohmaterialqualität
- Vernetzte Zustandsüberwachung der Produktionsanlage
- Einfache Nachrüstbarkeit bei Bestandsanlagen



Lösung

- **Messdatenerfassung via Cloud ohne Eingriff in bestehende Automatisierung**
- Erstellung eines physikalischen Modells für Kugelmühle und Mahlprozess
- Modellbasierte Ermittlung der optimalen Prozesszeit für eine gewünschte Produktqualität bei minimalem Energieeinsatz trotz schwankender Rohmaterialqualität



SensorTag für die drahtlose Datenerfassung

Datenbasis aufbauen – Retrofitting mit smarten IOT-Komponenten

Sensortechnik + Künstliche Intelligenz

Anforderungen

- Ausschussreduktion in der Kunststoffverarbeitung
- Anomalie-Erkennung im Produktionsprozess
- Zustands- und Prozessüberwachung in Echtzeit
- Einsatz bei hohen Umgebungstemperaturen in einer Maschinenhalle
- Drahtlose Datenübertragung
- Minimaler Wartungsaufwand



Lösung

- **Design embedded Hardware inkl. Firmware und Funkübertragung via Bluetooth**
- Minimaler Energieverbrauch durch Funkprotokolloptimierung
- Cloudbasierte Datenbewertung mit Künstlicher Intelligenz
- Fertigung Prototyp
- Durchführung von Anwendungstest



Datenbasis aufbauen – Rapid Prototyping

DisDAQ - Distributed DAQ & Algorithms Quiver

Anwendungsfälle

- Schnelle Messkampagnen (Machbarkeitsstudien, z.B. für Algorithmen-Entwicklung, Dimensionierung, Retrofitting, ...)
- Long Term Condition Monitoring mit Visualisierung (Cloud Based, Realtime)
- Aufbau einer Datenbasis
- Echtzeitalgorithmen (Vorverarbeitung, Signalverarbeitung, Machine Learning)
- Steuerungsaufgaben, z.B. für verschiedene Testfälle, Prüfstände

Verfügbare Sensorik

- Optische Sensorik (Video, Wärmebild, Sterokamera, Spektrometer, Pyrometer)
- Schall, Vibration, Beschleunigung, Gyroskop, Wirbelstromsensor, Gyroskop, IMU
- Temperatur, Luftfeuchtigkeit, Niederschlag, Windgeschwindigkeit, CO2-Gehalt
- Position, Entfernung, Radar, Lidar, Distanz, UHF RFID
- ... beliebige Anlogsensorik bis 20 MS/s



KI in der Praxis: Womit/Wie soll man beginnen?

Pragmatischer Ansatz

1. Ein realistisches Bild erhalten - den Hype von realisierbaren Anwendungen trennen.
2. Fachliches Grundwissen zur KI aufbauen
3. Domänenwissen nutzen
4. Frühzeitig Datenbasis aufbauen
5. **Schrittweise Umsetzung** – Kleine, schnell realisierbare Schritte (Pilotprojekte, Simulationen, Testläufe) benötigen oft keine großen Investitionen. Erste Schritte können oft mit vorhandenen Daten und flexibler Sensorik (Retrofitting, Laborsysteme, ...) durchgeführt werden.

Predictive Maintenance und Qualitätssicherung mit Machine Learning in der Praxis

LCM - Wir über uns

Was ist KI?

Was verspricht man sich vom Einsatz von KI...

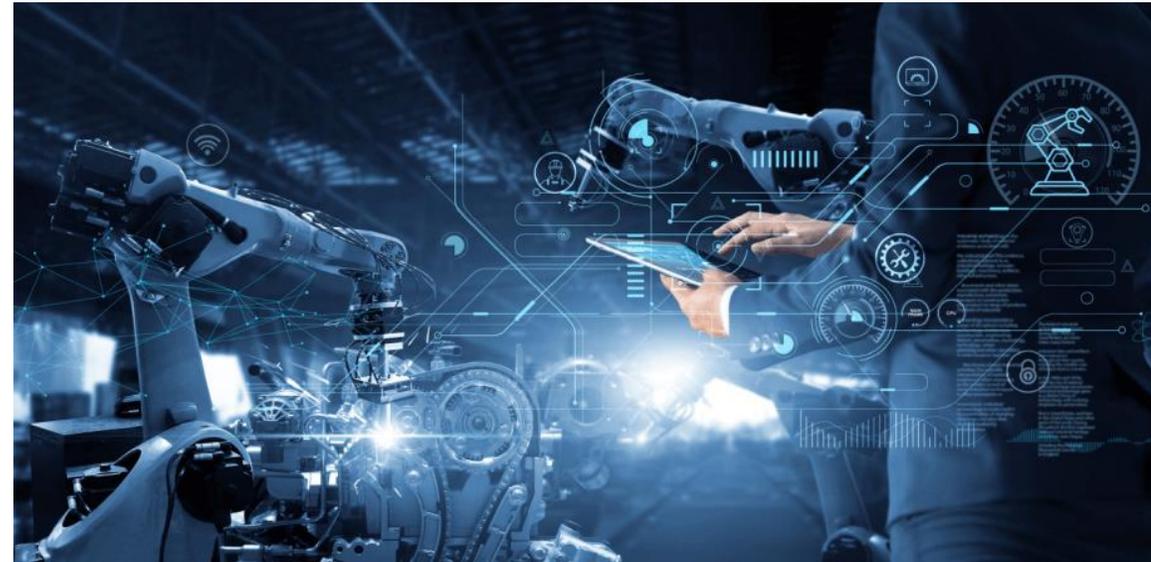
... zur Qualitätssicherung?

... zur Zustandsüberwachung?

KI in der Praxis: Womit/Wie soll man beginnen?

... Pragmatischer Ansatz in 5 Schritten mit Beispielen aus der Praxis

Fazit



Fazit

KI ermöglicht viele neue Anwendungsfälle in Qualitätssicherung und Zustandsüberwachung

Auf dem ersten Blick wird oft überschätzt...

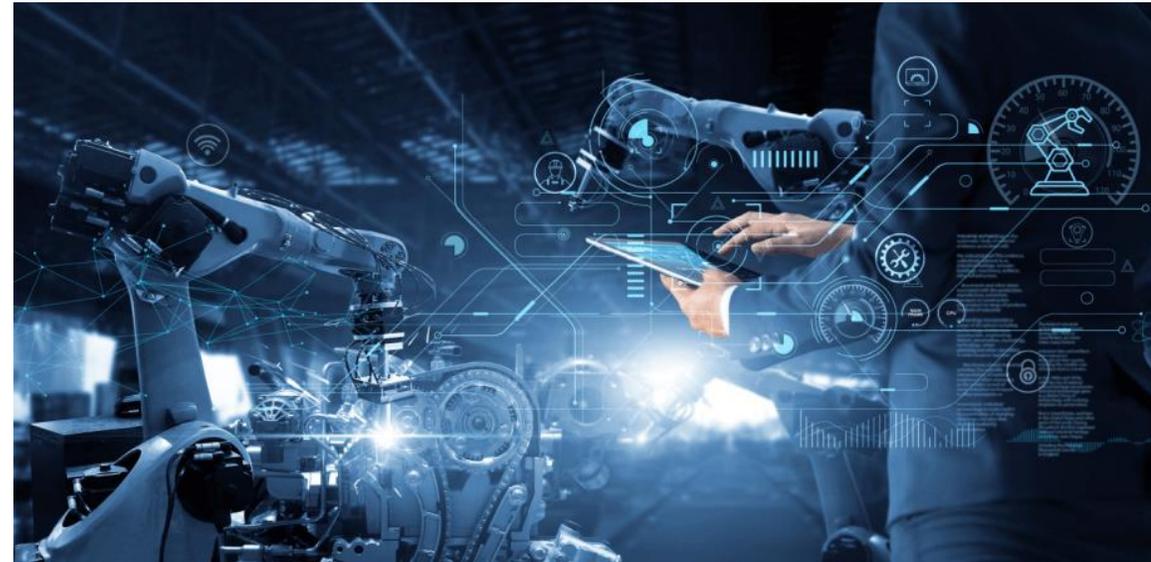
- ... die Leistungsfähigkeit (Hype, Anwendungsfälle werden zu weit gefasst)
- ... die Eintrittshürde für erste Validierungen

Auf dem ersten Blick wird oft unterschätzt...

- ... wie wichtig Domänenwissen ist
- ... wie unterschiedlich leistungsfähig verschiedene Lösungsansätze sein können

Wir würden Ihnen gerne noch mehr erzählen...

- ... Machine Learning mit Embedded Sensorik, Retrofitting, embedded Sensorik, Anomalieerkennung



Stay
Tuned

DI Dr. techn. Veronika PUTZ
Team Leader Data Analytics & AI

T +43 732 2468 6144
E veronika.putz@lcm.at

Linz Center of Mechatronics GmbH, Altenberger Straße 69, 4040 Linz AUSTRIA

 www.lcm.at

 www.linkedin.com/company/linz-center-of-mechatronics

 www.facebook.com/linzcenterofmechatronics