

Skalierung von KI-basierter Predictive Maintenance in der Produktion

Wie man vom Prototypen
zur skalierbaren Lösung kommt

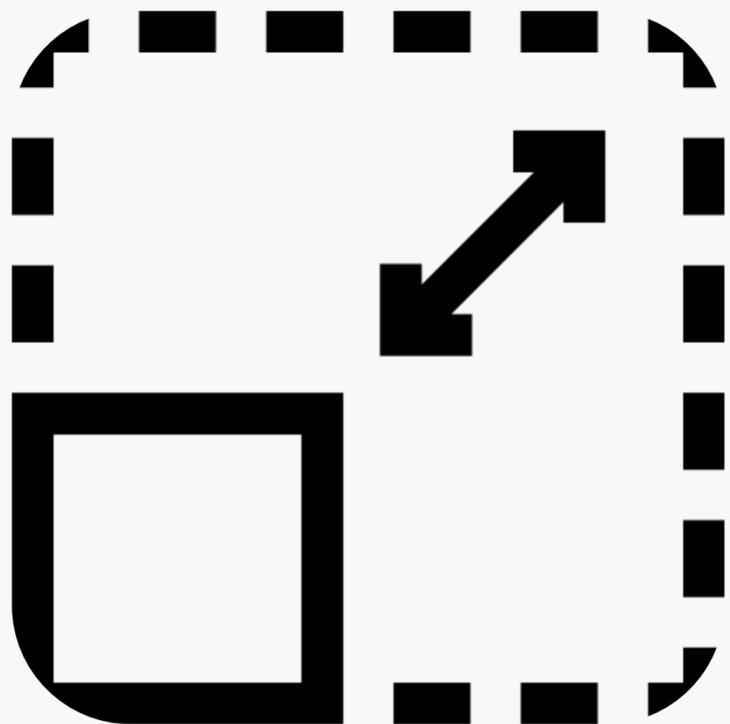
parkside-beyond.com



Agenda

- Warum die Skalierung von Predictive Maintenance oft eine (zu große) Herausforderung ist
- Wie unser Ansatz öfter zum Erfolg führt (anhand eines Projekts in der Pharmaindustrie)

Warum die Skalierung von Predictive Maintenance oft eine (zu große) Herausforderung ist



Fehlende Skalierbarkeit

- **Zu wenige Ausfälle** generell (Ungleichgewicht zwischen false und true-positives)
- **Zu wenige Ausfälle in anderen Maschinen** oder Produktionsstandorten abseits des Prototypen
- **Kein kongruentes Setup** über verschiedene Maschinen/Standorte
- **Zu hohe Kosten** für manuelles Training eines neuen Modells pro Maschine/Standort

Wie unser Ansatz öfter zum Erfolg führt

anhand eines Projekts mit einem unserer Pharmakunden
mit weltweit verteilten Produktionsstandorten

Ausgangssituation in der pharmazeutischen Produktion

Höchste Qualitätsstandards zur Gewährleistung der Patientensicherheit

- Jedes Produktionslos muss bestimmte Qualitätskriterien erfüllen
- Die Produktion sollte sich bei jedem Los genau gleich "verhalten"
- Tausende von Sensoren überwachen den aktuellen Zustand der Produktion (Temperatur, Druck usw.)

Klassische Ansätze der statistischen Prozesskontrolle haben ihre Grenzen

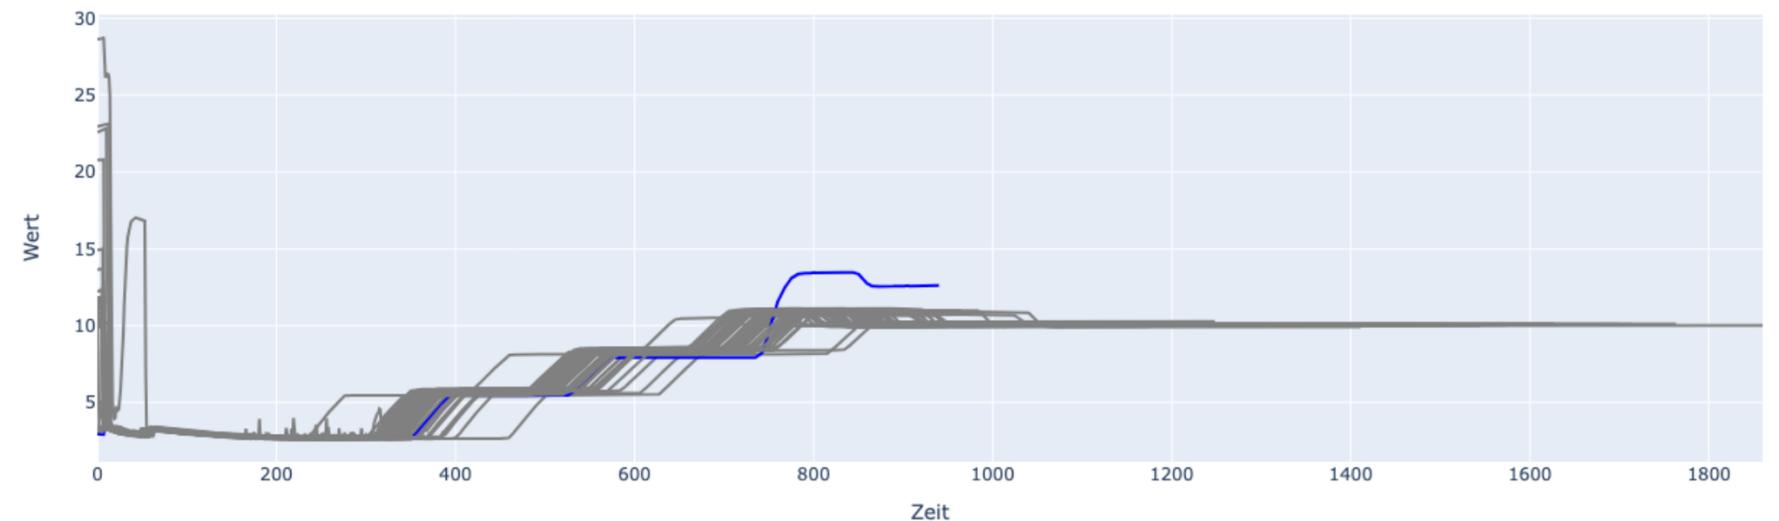
- Meistens wird nur eine Variable gemessen und nicht die Interkorrelation zwischen den Variablen
- Es werden nur feste Grenzen pro Variable definiert, aber kein Verhalten innerhalb dieser Grenzen



Unser Kunde beobachtete Anomalien in einem Los des Herstellungsprozesses

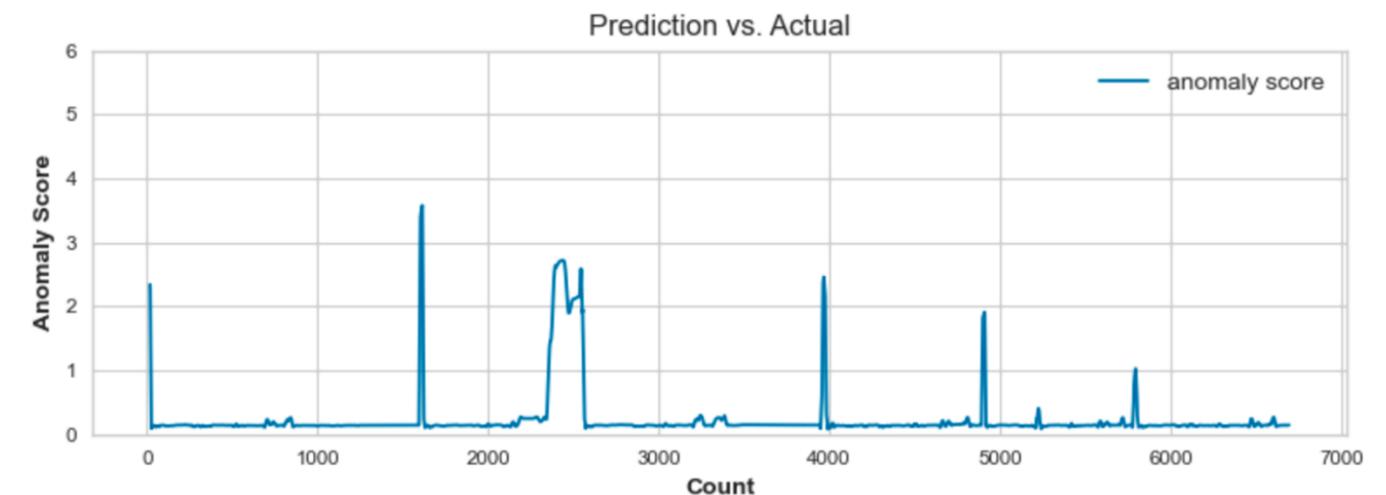
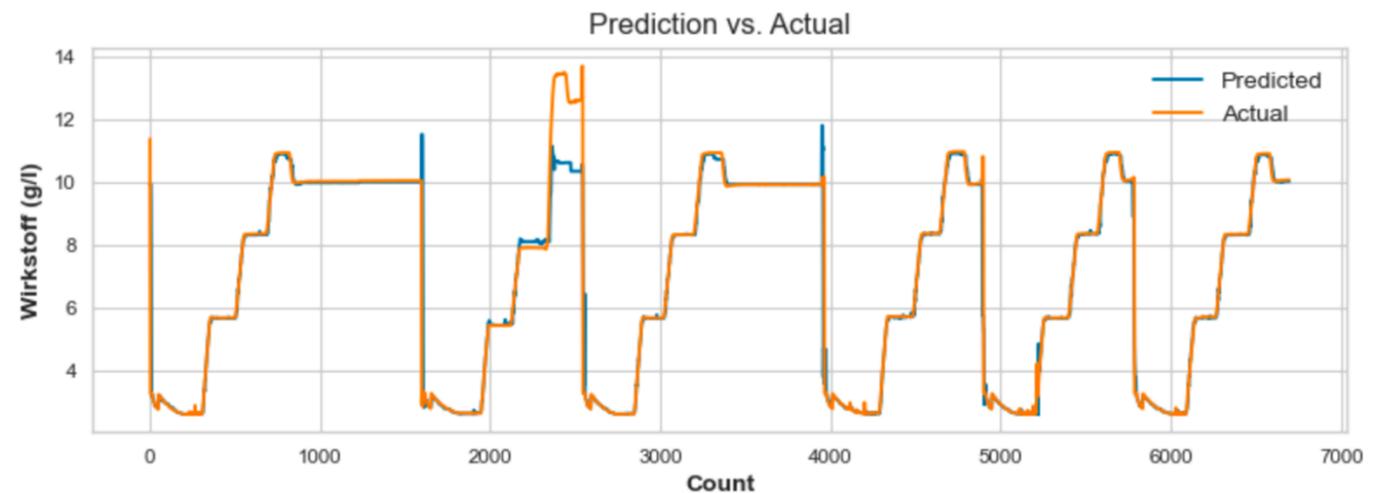
Abweichungen von der Norm

- Los mit **blauer** Farbe zeigt deutliche Abweichung von der Norm
- Diese **Anomalie** war bis zur **Qualitätskontrolle** nach Abschluss der Produktion des Loses **unbekannt**
- Unser Kunde konnte den **Grund für diese Anomalie** nicht aus **einzelnen Messungen** ableiten
- Daraufhin stellte uns einen großen Datensatz mit 100 GB und 500 verschiedenen Sensormessungen über ein Jahr der Produktion zur Verfügung

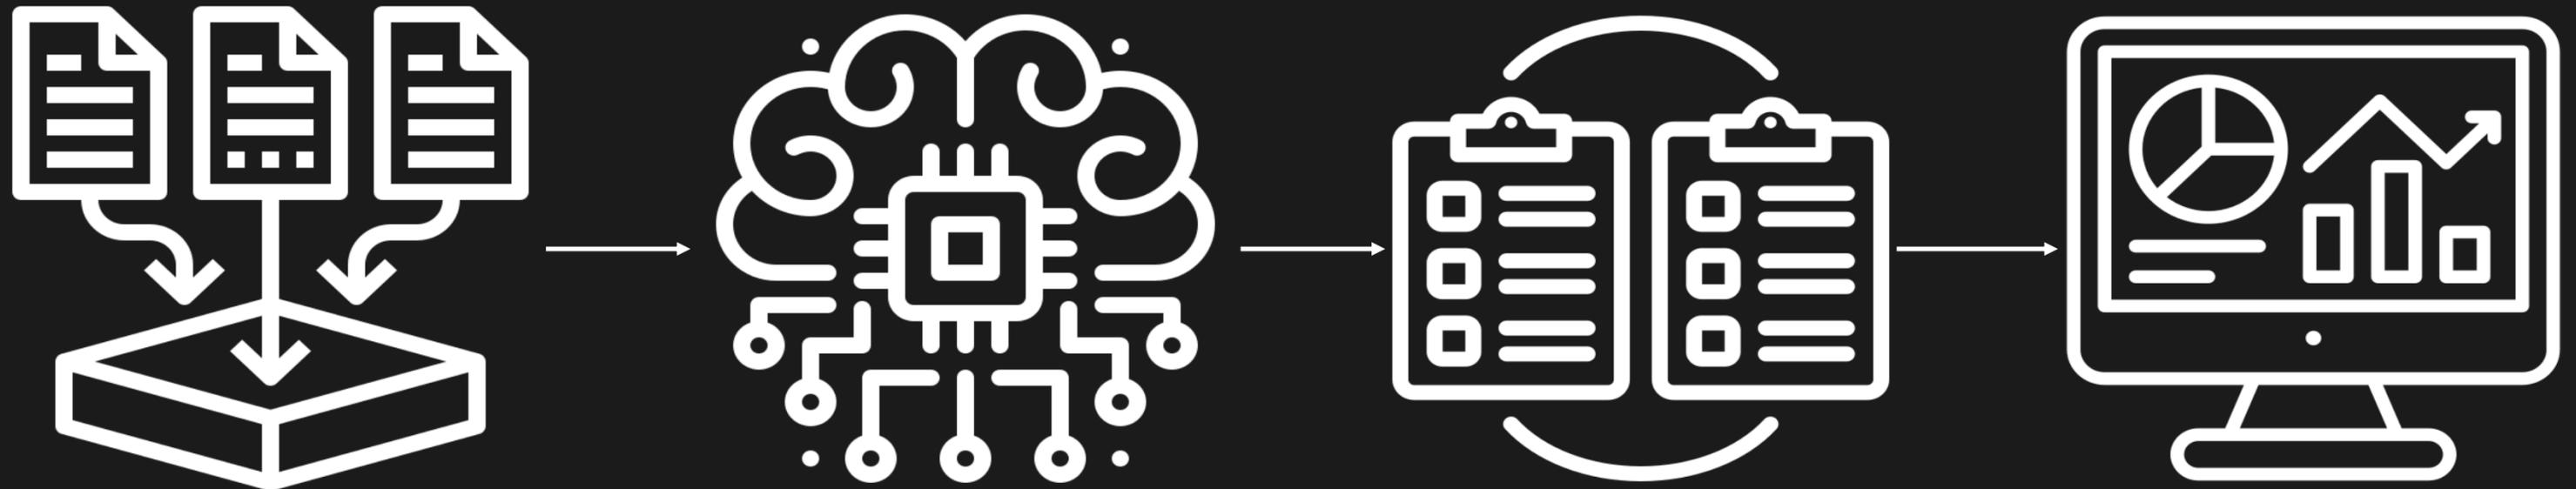


Unser KI-Modell kann Prozessanomalien prädiktiv und in Echtzeit erkennen

- Es sind **keine Anomalien notwendig**, um das Modell zu trainieren (Trainingsdaten 40 unauffällige Lose)
- **Modell lernt den Normalzustand** anhand von mehreren Variablen (u.a. Temperatur in Tanks, Druck etc.)
- Auffällige **Einflussfaktoren** können identifiziert werden (z.B. Temperatur in Tank A unüblich hoch)
- Testdaten mit **sechs unbekanntem Losen** (fünf unauffällig/ eines auffällig)
- Auffälliges Los wurde **in Echtzeit erkannt**
- Anomalie - Score ist für Produktionsmitarbeiter einfach zu verwenden



Prozessablauf



Daten werden während der
Produktion aufgezeichnet

KI-Modell sagt die
erwarteten nächsten
Messungen voraus

Vorhersagen werden mit
den tatsächlichen Werten
verglichen

Anomalien werden den
Produktionsmitarbeitern live
gemeldet

Lessons learned

- Training eines KI-Modells auf dem Normalzustand **ermöglicht erweitertes Monitoring der Produktion**
- Es sind **keine (gemessenen) Maschinenausfälle notwendig** um zu starten
- Dadurch konnte unser Kunde **fehlerhafte Lose frühzeitig erkennen** und damit Kosten einsparen
- Unser Kunde musste **keine große Daten- oder KI-Organisation** aufbauen und implementierte dennoch eine innovative KI-basierte Lösung
- KI-Modell lässt sich auch für Soft-Sensorik verwenden

