

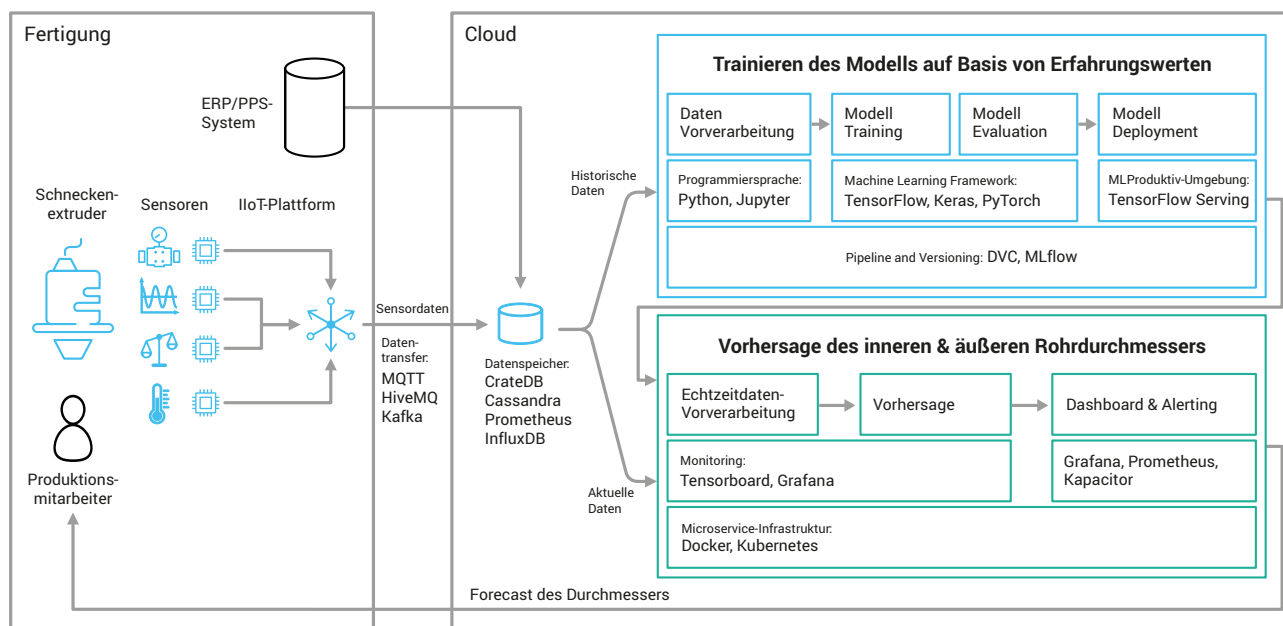
Predictive Quality im produzierenden Gewerbe mit Cloud-native Open Source Software



Jährlich geht dem produzierenden Gewerbe 20 % des Jahresumsatzes verloren. Grund dafür sind fehlerhaft produzierte Produkte. Die vorausschauende Qualitätssicherung nutzt Sensordaten wie Temperatur, Druck oder Schwingungen aber auch Ereignisdaten aus IT-Systemen, Prozessparameter aus Maschinensteuerungen und maschinelles Lernen, um die Wahrscheinlichkeit für Ausschuss oder Gutteil eines Produktes zu prognostizieren. Beispielsweise steht ein Schneckenextruder im Mittelpunkt der Fertigung von Kunststoffkabelschutzrohren für die Elektroinstallation. Seine Aufgabe besteht darin, Kunststoffgranulat einzuschmelzen und durch eine Form zu pressen. In der Produktion nehmen Trichter-temperatur, Rotationsgeschwindigkeit der Schnecke, Schmelztemperatur und andere Prozessparameter Einfluss auf die Produktqualität des Rohres. Aus Qualitätssicherungssicht ist der innere und äußere Rohrdurchmesser eine wichtige Messgröße für die Qualität. Maschinelles Lernen wird dann

dazu eingesetzt, Muster in den Prozessparametern und den zugehörigen Bewertungen als Gutteil oder Ausschuss zu lernen. Die Daten werden von Sensoren im Schneckenextruder erfasst und über IIoT übertragen. In der Produktion werden anschließend die sensorisch erfassten Prozessparameter dauerhaft überwacht. Wird in den Prozessparametern ein gelerntes Muster wiedererkannt, werden Fertigungsmitarbeiter über die drohenden Qualitätsprobleme informiert. Qualitätsprobleme, die nicht auf ein bekanntes Muster in den Daten zurückzuführen sind, werden verwendet, um die Vorhersage zu verbessern.

Die folgende Architektur gibt einen Überblick über Komponenten und Technologien und orientiert sich am Cloud-native Open Source Software Ansatz. Dadurch können Komponenten durch Managed-Services wie beispielsweise Amazon SageMaker oder Azure Machine Learning Studio ersetzt werden. Eine Architektur kann wie folgt aufgebaut sein:



Die technische Umsetzung sowohl der Trainings- als auch der Vorhersagepipeline besteht aus entkoppelten, skalierbaren und austauschbaren Microservices, die beispielsweise mit Docker Containern plattformunabhängig umgesetzt werden. Eine einheitliche Kommunikation über REST-Protokolle gewährleistet das Zusammenspiel. Mit einem Machine Learning Framework wie TensorFlow oder Keras werden tiefe neuronale Netze zusammengestellt, verteilt trainiert, die Ergebnisse ausgewertet und Modelle ausgerollt. Für die Versionierung von Daten und Modellen sowie dem Pipelining wird ein Tool

wie DVC (Data Version Control) genutzt, um damit die Reproduzierbarkeit, Wartbarkeit und Nachvollziehbarkeit des Trainingszyklus zu ermöglichen. In der Trainingspipeline lernt das Modell aus historischen Daten. Die Vorverarbeitung selektiert, standardisiert und normalisiert relevante Daten. Im Betrieb sagt das Modell den inneren und äußeren Rohrdurchmesser auf Basis aktueller Daten vorher. Alle relevanten Sensordaten, Prozessdaten sowie die Vorhersage lassen sich in einem Dashboard wie beispielsweise Grafana visualisieren und überwachen.



Dr.-Ing. Christoph Heger

Head of Practice Area Data Intelligence
Novatec Consulting GmbH

www.novatec-gmbh.de/beratung/predictive-quality/

