



AUTOMATISIERTE ERKENNUNG VON FEHLERKLASSEN IN MESSGERÄTEN

Durch eine automatisierte und echtzeitfähige Erkennung von Defekten und Fehlern in Messgeräten können Ausfälle in kritischen Infrastrukturbereichen und in der industriellen Produktion minimiert werden. Service-Arbeiten können gezielt geplant und somit Kosten eingespart werden.

Eine nicht automatisierte Überwachung beziehungsweise eine Überwachung des Betriebs von Messgeräten auf Basis von Schwellwerten ist aufwendig und ungenau. Die automatisierte Erfassung und Analyse von Sensordaten mit Algorithmen des Machine Learnings in Echtzeit ermöglicht die genaue und zeitnahe Identifikation von Fehlern während des Betriebs.

FÜR FOLGENDE HERAUSFORDERUNGEN

- Automatisierte Erkennung von Fehlfunktionen
- Präzise Klassifizierung von Fehlfunktionen
- Vorausschauende Planung von Wartungsintervallen
- Verkürzung von Wartungsintervallen
- Sicherung von industriellen Produktionsprozessen
- Sicherung von infrastrukturellen Prozessen
- Senkung von Servicekosten

DER ANWENDUNGSFALL

Sowohl im industriellen Bereich als auch im Bereich kritischer städtischer Infrastrukturen werden Durchflussmessgeräte verwendet, beispielsweise zur Messung des Verbrauchs von Trinkwasser, der Last auf Zuleitungen innerhalb eines Versorgungsnetzwerks oder zur Steuerung von Flüssigkeiten innerhalb von industriellen Produktionsprozessen.

Neben akuten elektronischen Defekten innerhalb des Messsystems können auch sich langsam verstärkende Fehlfunktionen auftreten, wie das Verkalken von Verbindungsleitungen oder deren Verstopfung durch Verschmutzung.

Bei Ausfall von Messsystemen oder dem zu späten Erkennen von Defekten in den Zuleitungen kann es im schlimmsten Fall zu stunden- oder tagelangem Ausfall von beispielsweise der Trinkwasserversorgung oder industriellen Produktionsprozessen kommen. Im industriellen Bereich führt dies gegebenenfalls nur zu hohen Kosten durch Produktionsausfälle, in der öffentlichen Infrastruktur sind solche Ausfälle durch eine nicht mehr gesicherte Grundversorgung der Bevölkerung aber als kritisch einzustufen.

Durch bislang meist manuelle Suche von Fehlern können diese nur langsam und mit großem Zeitaufwand behoben werden. Eine automatisierte Lösung in Echtzeit adressiert nun dieses Problem.

DIE LÖSUNG IM DETAIL

Auf Basis von zuvor erhobenen Sensordaten werden verschiedene Machine-Learning-Modelle zur Supervised Classification trainiert. Diese können unterschiedliche Fehlfunktionen der Durchflussmessgeräte auf Basis von Sensordaten in Echtzeit erkennen und voneinander unterscheiden (etwa Kurzschluss der verbauten Spule, Luftblasen im Wasser, Verstopfung der Zuleitung).

Je nach Anforderungen an Präzision und Zeit bis zur Verfügbarkeit von Analyseergebnissen können Vorhersagen zu einzelnen Zeitfenstern aggregiert betrachtet werden.

Für unterschiedliche Anwendungsfälle und neue Fehlerklassen können Modelle neu und nachtrainiert werden, um so ein breites Spektrum an möglichen Anomalien abzudecken.

Sowohl die erfassten Sensordaten als auch die Labels der ermittelten Fehlfunktionen werden übersichtlich in einem Dashboard dargestellt. Dieses erlaubt Servicetechniker*innen, Fehler schnell zu erkennen, gezielt Wartungsarbeiten vorzunehmen, Kosten zu senken und einen möglichst unterbrechungsfreien Betrieb zu gewährleisten.

STATUS IM PROJEKT

Ein Prototyp zur Erfassung, Klassifizierung und Visualisierung von Fehlfunktionen in Echtzeit wurde entwickelt und befindet sich nun in der Evaluations- und Verbesserungsphase.

VORAUSSETZUNGEN

- Es existiert eine Cloud-Infrastruktur, welche eine für Zeitreihen optimierte Datenbank (InfluxDB), ein daran angebundenes Frontend (Grafana Dashboard) und Ressourcen zur Ausführung des trainierten Klassifikationsmodells bereitstellen kann.
- Es müssen definierte Fehlerklassen existieren.
- Spezifische, zuvor ungekannte Fehlerklassen können/müssen nachtrainiert werden.

VERFÜGBARKEIT

Trainierte Modelle und Informationen zur entwickelten Infrastruktur sind auf Anfrage verfügbar und können für den gegebenen Use Case angepasst werden.



ANSPRECHPARTNER:

- Dr. Robert Pesch (inovex, rpesch@inovex.de)
- Dr. Martin Krawczyk-Becker (KROHNE Messtechnik, M.Krawczyk-Becker@KROHNE.com)

SPEZIFIKATION

| | Inputdaten | Preprocessing | Datenspeicher | Algorithmen | Interfaces |
|--|--|---|---|---|--|
| High-Level-Beschreibung | Multivariate numerische Zeitreihe und eine dazugehörige kategoriale Variable | Zeitliche Aggregation der Daten | Speicherung der Sensordaten in einer Time-Series-Datenbank und perspektivisch Off-Loading in Rohdatenarchiv | Automatisierte Defektklassenerkennung mittels Algorithmen des Machine Learnings | Webdashboard mit Markierung der gefundenen Anomalien und Darstellung der Sensormesswerte |
| Konfigurierbarkeit | Selektion der Geräte und relevanter Kanäle | Art der Aggregation | Vorhaltezeit, Datenformat, Speicherort | Evtl. Modellparameter | Art der Visualisierung |
| Technische Umsetzung | Streaming der Sensordaten von Edgegeräten | Python Script ausgeführt über GitLab CI in Kubernetes-Cluster | InfluxDB und Google Buckets | Python Script ausgeführt über GitLab CI in Kubernetes-Cluster | Grafana Dashboard angebunden an die InfluxDB |
| Spezifisches Beispiel aus dem Schnellboot | Anbindung KROHNE Edge über MQTT oder direkt an eine Influx: numerische Messwerte (~ 10) in unterschiedlicher Auflösung | Aggregation der Messwerte auf Sekunden-ebene | Rohdaten werden komplett in der InfluxDB gestreamt; regelmäßiges Off-Loading in Google Buckets in Planung | Erkannte Fehlerklasse für die KROHNE-Messgeräte | Interaktive Darstellung der multivarianten Zeitreihen und Klassifikationsergebnisse |



ANSPRECHPARTNER

- Dr. Robert Pesch (inovex, rpesch@inovex.de)
- Dr. Martin Krawczyk-Becker (KROHNE Messtechnik, M.Krawczyk-Becker@KROHNE.com)