

Flexible On-Premises Datenanalyse für KMU

Dr. **G. Steinhagen**, fabforce GmbH & Co. KG, Netphen;

Dr. **M. Banf**, fabforce GmbH & Co. KG, Netphen;

Kurzfassung

Im Zeitalter von Industrie 4.0, dem Aufkommen des Internets der Dinge (IoT) und neuartiger Lernalgorithmen aus dem Bereich des Machine Learnings, erleben wir eine Revolution in Bezug auf die Möglichkeiten in der automatisierten Überwachung von Produktionsprozessen, der Optimierung von Prozessabläufen, bis hin zur assistierten Produktentwicklung.

Auch kleine und mittlere Unternehmen (KMU) können von diesen Entwicklungen profitieren, allerdings fangen die Hindernisse hier häufig schon mit der Erfassung und der Verarbeitung der Daten an. Für die Nutzung von Datenbanktechnologien und Datenanalyse sind in den meisten Fällen keine internen Ressourcen vorhanden. Auf der anderen Seite liegt häufig ein sehr heterogener Maschinenpark vor, der Maschinen aus verschiedenen Generationen vereint.

Dieses Paper stellt eine flexible Architektur vor, die das sichere Sammeln, Verarbeiten und Analysieren von Daten On-Premises ermöglicht. Durch die Flexibilität wird die Anbindung der verschiedensten Maschinen schnell umsetzbar. Außerdem werden verschiedene Analysen gezeigt, die mit begrenzten Ressourcen einer On-Premises Serverlösung stabil funktionieren und nicht die Rechenkapazität einer Cloud benötigen. Dabei handelt es sich um unüberwachte Analysemethoden, Edge-Anwendungen aus der Umformüberwachung und Schwingungsanalysen, sowie innovative Prozessvisualisierungen, die Prozessspezialisten detaillierte Einblicke in die Produktion liefern.

1. Einleitung

Das Thema Künstliche Intelligenz hat viele Hoffnungen auf mehr Effizienz in der Produktion geweckt. Gleichzeitig steigt aber auch der Wettbewerbsdruck, sich mit diesem Thema und der Digitalisierung allgemein zu beschäftigen, um nicht den Anschluss zu verpassen. Insbesondere bei kleinen Unternehmen kommt dabei die Frage auf, wie diese den Einstieg in das Thema finden, ohne einen Locked-In Effekt in die falsche Technologie zu riskieren.

Außerdem sind organisatorische Fragen, wie das Hosting und die Wartung der digitalen Infrastruktur, zu klären.

Zunächst stellt sich die Frage, wo und in welcher Form die notwendige Hard- und Softwarearchitektur verwaltet werden soll. Die beiden großen Kategorien sind hier Cloud basierte oder lokale OnPremises Lösungen. Während bei Cloud basierten Ansätzen jeweils ein Drittanbieter die Serverlandschaft zur Verfügung stellt und verwaltet, bleibt bei OnPremises Lösungen die Hardwarearchitektur - und somit gegebenenfalls sensible Daten - innerhalb des eigenen Unternehmens. Dies bietet nach wie vor, trotz der teilweise vorteilhaften Anreize von Cloud Lösungen im Hinblick auf Hardware- und Verwaltungskosten, einen nicht zu vernachlässigenden Vorteil im Bereich Datensicherheit.

Mit Hinblick auf die Software-Architektur bieten auf Microservices basierende Ansätze die Möglichkeit, Softwarepakete flexibel zu kombinieren und diese auf vielfältigen Systemen zu installieren. Gleichzeitig sind diese Systeme deutlich einfacher erweiterbar und damit zukunftssicherer als eine monolithische Software eines Anbieters. Dies erleichtert den Einstieg in die Digitalisierung.

Schwerpunkte in der produktionsbezogenen Datenanalyse liegen zunächst im Bereich der permanenten Zustandsüberwachung (condition monitoring). Hier können Verfahren aus der Statistik und des Machine Learnings verwendet werden, um z.B. Defekte in Werkstücken zu erkennen (quality inspection) oder die verbleibende Lebensdauer von Werkzeugen und Maschinenbauteilen abzuschätzen (predictive maintenance).

Innerhalb des Machine Learnings selbst lassen sich ebenfalls zwei große Methodenbereiche unterscheiden, das überwachte (supervised) und unüberwachte (unsupervised) Lernen. Beim überwachten Lernen werden Trainingsdaten zur Verfügung gestellt, die im Vorfeld bewertet und kategorisiert (annotiert) wurden. Diese Annotationen ermöglichen es, den Lernalgorithmus und die Rohdaten mit Hinblick auf diese Kategorisierungen hin zu analysieren. Im produktiven Einsatz versucht ein solches System dann neue Daten gemäß ihrer Ähnlichkeit zu den Trainingsdaten zu einer der gegebenen Kategorien zuzuordnen. Auf diese Weise können neben Klassifikations- auch Vorhersagemodelle angelernt werden.

Anwendungen in der Produktion sind beispielsweise Erkennung von Oberflächendefekten [1, 2], die Materialzustandsbestimmung von Getrieben, Kugellagern [3], oder Fräsmaschinen [4]. In Abschnitt 5 wird eine Anwendung zur Klassifikation von Fräsprozessen basierend auf annotierten Schwingungsdatensätzen vorgestellt.

Unüberwachte Algorithmen arbeiten direkt auf den Rohdaten ohne zusätzliche Annotationen. Sie bieten sich im Besonderen an, um einzelne Ausreißer oder Anomalien zu erkennen, wenn keine oder zu wenige Datensätze zum Training eines überwachten Ansatzes zur Verfügung

stehen. Dies ist in der Produktion von Vorteil, wenn das manuelle Annotieren zeit- und kostenintensiv ist bzw. Fehlertypen nicht konkret im Vorfeld definiert werden können oder nur sehr vereinzelt auftreten. Des Weiteren erlauben unüberwachte Ansätze effektive Verfahren zur Reduktion der eigenständigen Clusterbildung und der Visualisierung von Daten. Anwendungen in der Produktion sind zum Beispiel Auffälligkeitenanalyse von Rotationsmaschinen [5] oder innerhalb von Metallumformprozessen [6]. In [7] wurde ein Beispiel auf Basis mehrerer Druck- und Ventilensorsignale gezeigt, die für einen Hydroforming Prozess eingesetzt wurden.

Innerhalb dieser beiden Kategorien hängt die Auswahl des geeigneten Verfahrens dann zusätzlich von den gegebenen Datenquellen - z.B. Vibrations-, Temperatur-, oder Drucksensoren - als auch Datentypen - z.B. Sensordaten, dokumentierte Maschinenhistorie, Wartungspläne etc. ab.

2. Systemarchitektur

Um eine möglichst flexible Software bereitstellen zu können, wurde das System als eine Microservices-Architektur umgesetzt. Zur Implementierung der einzelnen Microservices wird eine Container-Technologie basierend auf dem Docker Framework verwendet. Microservices können sowohl auf lokalen Systemen eingesetzt, als auch in großen Serverarchitekturen verwendet werden. Die verschiedenen technologischen Funktionen sind so in Subsysteme aufspaltbar, die über einheitliche Schnittstellen kommunizieren.

Ein weiterer Vorteil ist, dass verwendete Technologien schneller erweitert oder ausgetauscht werden können. Dies ist insbesondere bei schnellen Entwicklungszyklen sehr wichtig, auf die sonst nur sehr träge reagiert werden könnte.

Die Funktionen die notwendig sind, um Daten effizient analysieren zu können sind das Bereitstellen von Maschinenschnittstellen, das Speichern und Verwalten der Daten sowie die Analyse der Daten. Zudem müssen die Daten für den Nutzer visualisiert werden. Darüber hinaus ist es sinnvoll, die Services möglichst flexibel zu halten und die Parameter über eine zentrale Konfiguration einzustellen. Somit lassen sich Analysen, Schnittstellen und Datenbanken präzise auf individuelle Maschinentypen und Fragestellungen abstimmen.

Wichtig ist auch, dass sich auf diese Weise generische Analysen, die über Konfigurationen individualisiert werden, genauso einbinden lassen, wie individuelle Analysen, die auf proprietären Kundendaten basieren und somit Kern-Know-How dieser Kunden darstellen.

Die Anbindung an weitere Softwarekomponenten einer bestehenden IT-Landschaft ist ebenfalls an verschiedenen Stellen im Informationsfluss möglich. Ein Aufbau des Datenflusses ist in Abbildung 1 dargestellt.

Auf diese Weise können auch schnell vielfältige Maschinen- und IT-Schnittstellen eingebunden werden, ohne große Änderungen an der restlichen Software vornehmen zu müssen.

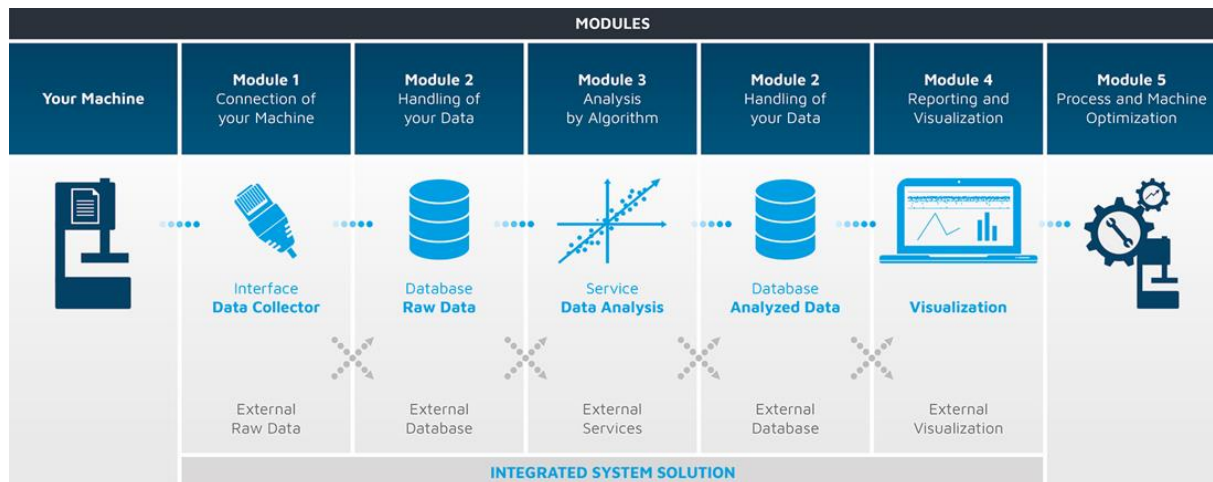


Abbildung 1: Datenfluss des Systems

3. Datenverarbeitung

Die Art der Daten, die verarbeitet werden müssen, lassen sich sowohl nach der Datenstruktur, als auch nach dem Analysegrad unterscheiden. Die in der Automatisierung wohl relevantesten Daten sind Zeitreihendaten; darüber hinaus sind matrixartige Daten, wie Bilder von Kameras oder analysierte 2D oder 3D Daten relevant. Außerdem sind Metadaten zu den genannten Daten wichtig, da über Annotationen ein überwachtetes Lernen möglich wird. Beim Analysegrad kann zwischen Rohdaten und bereits analysierten Daten unterschieden werden. Während bei der Datenstruktur insbesondere die Auswahl des richtigen Datenbankformats wichtig ist, beeinflusst der Analysegrad eher die notwendige Speicherdauer und die Art der Visualisierung.

Es ist nicht sinnvoll große Mengen von Rohdaten, die bereits analysiert sind, langfristig vorzuhalten. Wenn die Analysen bereits Kernaussagen über den Prozess bereitstellen, kann die Datenmenge so deutlich reduziert werden. Abbildung 2 zeigt den Aufbau unserer Datenverarbeitung, welche die oben genannten Anforderungen erfüllt. Die Microservices-architektur ermöglicht es auch hier die vielfältigen Anforderungen in sinnvolle Teilaufgaben und damit verbundene Services aufzuteilen. Um die Daten zu koordinieren, wird dabei ein Integrationservice verwendet, der auf die Datenbanken zugreift. Auf diese Weise lassen sich auch auf einem relativ kleinen System vielfältige Daten verwalten.

Um die Verwaltung auf die individuellen Einsatzfälle anzupassen, wurde ebenfalls eine Schnittstelle zur zentralen Konfiguration geschaffen. So lässt sich zum Beispiel die Datenvorhaltdauer gezielt einstellen. Zusätzlich ist es aber auch von Vorteil die Möglichkeiten zur Datenaufbereitung moderner Datenbanken zu nutzen. So können beispielsweise Rohdaten vor der Übertragung direkt von der Zeitreihendatenbank entsprechend der Anforderungen gesampelt werden. Dies verringert den Analyseaufwand, sowie den Datenverkehr. Außerdem können direkt virtuelle Variablen erzeugt und für die weitere Analyse genutzt werden.

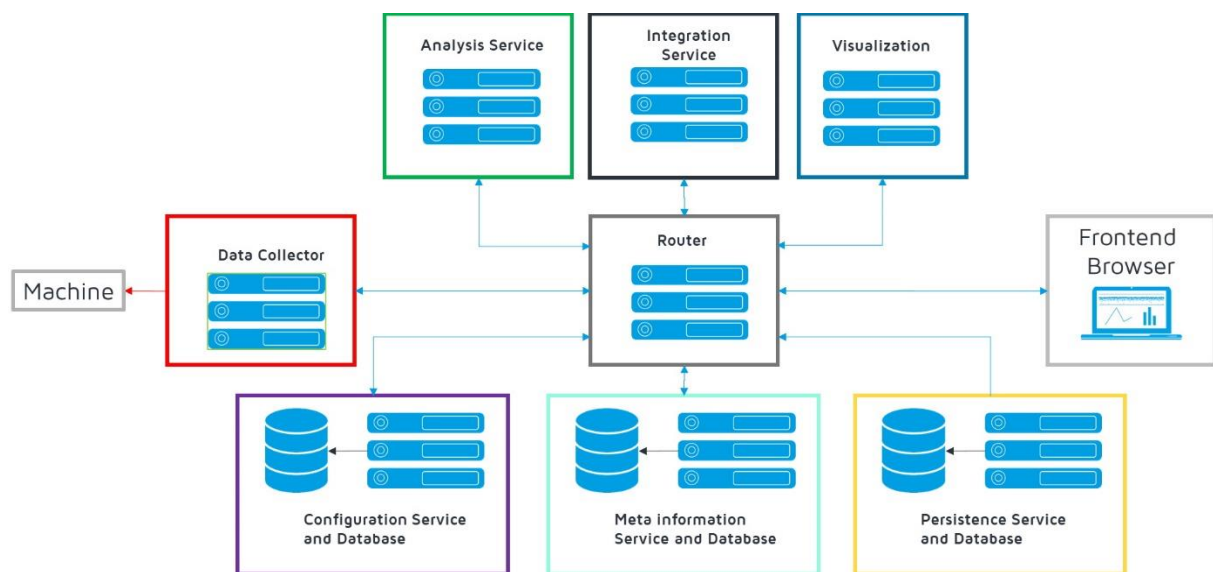


Abbildung 2: Aufbau der Multi-container basierten Microservices-Systemarchitektur

4. On-Premises Datenanalyse

Um die gesammelten Daten möglichst schnell nutzen zu können bieten sich unüberwachte Lernalgorithmen an, da hier lange Anlernphasen der Algorithmen entfallen. Die Strukturierung nach Chargen, Zyklen, Produktarten, Maschinenkomponenten und Fehlerzusammenhängen ermöglicht einen gezielteren Einblick in die Daten. Es entstehen Möglichkeiten analog zum Online Analytical Processing (OLAP) wie es im Bereich Business Intelligence bekannt ist. Im Folgenden werden verschiedene Beispiele vorgestellt, die eine schnelle Nutzung der Daten ermöglichen.

Perzentilen basierte Analyse

Produktionsprozesse unterliegen in der Regel Schwankungen, welche anhand der verschiedenen Sensorwerte einer Maschine erkennbar sind. Meist wird ein Prozess mit

wenigen Probestücken eingerichtet. Eine weitere Analyse in der normalen Produktion findet dann erst im Fehlerfall statt. Auch hier werden, sofern überhaupt vorhanden, die Daten des fehlerhaften Prozessdurchlaufs analysiert. Einige Probleme und Prozessinstabilitäten lassen sich jedoch bereits früher entdecken, wenn die Streuung der Werte betrachtet wird. Eine Möglichkeit hierfür bietet die Analyse der Perzentilverläufe verschiedener Sensordaten [1]. Abbildung 3 zeigt am Beispiel eines Ventilstellwerts dessen Perzentile für eine Produktionscharge. Es sind Signalbereiche zu sehen, die eine sehr breite Streuung zeigen, und Bereiche, die ein sehr homogenes Verhalten aufweisen.

Ausreißer können mit diesem Vorgehen ebenfalls gut und in Echtzeit analysiert werden, da sich der Vergleich der aktuellen Produktionsdaten mit den bereits berechneten Perzentilen einer laufenden Charge bereits nach wenigen Durchläufen durchführen lässt. Der Vorteil ist, dass weder ein Hochleistungsrechner noch aufwendiges, manuelles Annotieren von Daten notwendig sind.

Um ein genaueres Abbild vom Prozess zu bekommen, kann anstatt einzelner Perzentile auch eine kontinuierliche Perzentilverteilung pro Sensor abgebildet werden. Hierdurch zeigen sich noch genauere Einblicke, in welchem Bereich die Werte konzentriert sind.




Abbildung 3: Perzentildarstellungen der Sensorsignale einer Produktionscharge zur Visualisierung der Signalstreuung

Analyse mit Hilfe nicht-parametrischer Verteilungen

Perzentile stellen eine gute Möglichkeit dar, unimodal verteilte Daten darzustellen, also basierend auf der Annahme eines einzigen, dominanten bzw. idealen Prozessverlaufes. Bei komplexeren Verteilungsmustern eines Prozessverlaufes, in denen beispielsweise Nebenmaxima enthalten sind, kann es durch die Perzentildarstellung zu Fehldarstellungen bzw. -interpretationen kommen. Zur Analyse dieser Fälle bieten sich hier nicht-parametrische

Verteilungsfunktionen zur Darstellung und Analyse an. Durch diesen zusätzliche Detailgrad können wertvolle Informationen gewonnen werden. Liegt zum Beispiel ein bistabiler Produktionsprozess vor, der die Gesamtqualität beeinflusst? Handelt es sich um eine spezifische Fehlerhäufung, die näher analysiert werden kann, um eine Vermeidungsstrategie zu entwickeln? Auf dieser Grundlage können zum Beispiel weitere Clusteranalysen für Fehler erstellt werden oder über PARETO Diagramme aus dem Six Sigma Werkzeugkasten die Häufigkeit und Beeinträchtigung durch die auftretenden Fehler analysiert werden.

Abbildung 4 zeigt ein Beispiel mit einem zunächst gleichmäßig verteilten Signal, welches sich dann am Ende in zwei verschiedene, stabile Muster aufspaltet, die sich im Zeitbereich unterscheiden. Die zugrundeliegenden Zustände können damit näher ermittelt werden.




Abbildung 4: Nichtparametrische Verteilung eines Ventilsignals

Qualitätsbewertung einzelner Produktionsdurchläufe

Zur Qualitätsbewertung, sowie deren übersichtlicher Darstellung, einzelner Produktionsdurchläufe z.B. einer Produktionscharge, ist es zunächst hilfreich eine Kennzahl für einen einzelnen Produktionsdurchlauf zu definieren. Hierbei ist die Ähnlichkeit bzw. Abweichung des Produktionsdurchlaufes zum idealen bzw. "mittleren" Produktionsdurchlauf ein sinnvoller Ausgangspunkt. Zunächst kann - ausgehend von der Grundannahme, dass eine Charge deutlich mehr fehlerfreie als fehlerhafte Produktionsdurchläufe beinhaltet - aus sämtlichen Produktionsdurchläufen der Charge ein "idealer" Durchlauf errechnet werden. Dieser kann im Weiteren verwendet werden, um die Abweichung jedes Einzeldurchlaufes zu diesem "idealen" Durchlauf zu ermitteln und in kompakter Form als skalaren Wert pro Durchlauf darzustellen.

Neben der Bewertung und Darstellung der Produktionsdurchlaufbewertungen einzelner Sensoren können so ebenfalls sehr einfach Bewertungshierarchien aufgebaut und visualisiert

werden. So ist es möglich die Durchlaufbewertungen einzelner Sensoren zu physischen oder funktionalen Sensorgruppen oder auch auf Maschinenebene zusammenzufassen und gemeinsam auszuwerten. So können Sensorsignale, welche zu bestimmten Komponenten einer Maschine gehören oder die in bestimmten Fehlerfällen Auffälligkeiten zeigen, zusammen ausgewertet werden. Damit ist es möglich auch bei einer größeren Anzahl von Einzelsensoren eine schnelle und effiziente Fehleranalyse zu gewährleisten. Ein weiterer Vorteil der kompakten visuellen Darstellung ist die Möglichkeit, möglichst schnell Abweichungsmuster, wie zum Beispiel Trends oder phasenweise Abweichungen zu erkennen, so dass frühzeitig reagiert werden kann.

Im folgenden Abschnitt wird ein Beispiel erläutert, wie sich hieraus ein effizienter Drill-Down Ansatz zur Fehlersuche ableiten lässt.

Effiziente Abweichungsanalyse als Drill-Down Ansatz

Die oben genannten einzelnen Verfahren lassen sich zu einem effizienten Drill-Down Ansatz in der Fehleranalyse verknüpfen. Mithilfe eines passenden Frontends lassen sich die Verfahren geschickt kombinieren. Abbildung 54 skizziert dieses Vorgehen für die Analyse mehrerer Prozessdurchläufe einer hydraulischen Presse. Auf der obersten Ebene lassen sich durch die Gruppen der Maschine die Komponenten oder Funktionsgruppen sehr kompakt darstellen. Es ist erkennbar, dass die ersten vier Werkstückedurchläufe pro Sensorgruppe (Stößel, Kraft, Systemdruck) eine deutliche Abweichung im Vergleich zum Rest der Produktionscharge aufweisen (Abb. 5a).

Diese lassen sich auch in den einzelnen Kraftmessungen an den Pressensäulen wiederfinden, die in der Gruppe „Kraft“ zusammengefasst sind (Abb. 5b). Das Frontend bietet die Möglichkeit, mit einem übergreifenden zeitlichen Zoom schnell auf die interessanten Bereiche zu fokussieren. So können schnell die Durchläufe mit den entsprechenden Daten aufgerufen werden. Hier kann die abweichende Gruppe aufgelöst nach Einzelsensoren analysiert werden, um zu überprüfen, für welchen Sensor die relevanten Abweichungen auftreten (Abb. 5c).

Letztendlich können die Rohdaten im Vergleich zu den Perzentilen aufgerufen und für den Abweichungsbereich analysiert werden. Somit ist schnell erkennbar an welcher Stelle im Prozess die Sensorwerte ausbrechen und Prozess- und Maschinenexperten bekommen ein genaues Bild der Störung, ohne manuell nach diesen Abweichungen suchen zu müssen.

Im Beispiel zeigt sich anhand der Abweichung der ausgewählten Werkstückdurchlaufsignale (rot) im Vergleich zu den korrespondierenden Perzentilen eine deutliche Veränderung der Kraftverläufe, was auf ein mechanisches Blockieren oder Abweichungen im Ausgangswerkstück hindeuten könnte. Der Ansatz kann auch insoweit angepasst werden,

dass Sensoren, die Störungen besonders deutlich zeigen oder die Qualität gut repräsentieren, ebenfalls kompakt überwacht werden. So zeigt sich zum Beispiel im Hydroforming, dass insbesondere der Positionswert des Druckübersetzers ein guter Indikator für die Qualität und Störungen im Prozess ist.

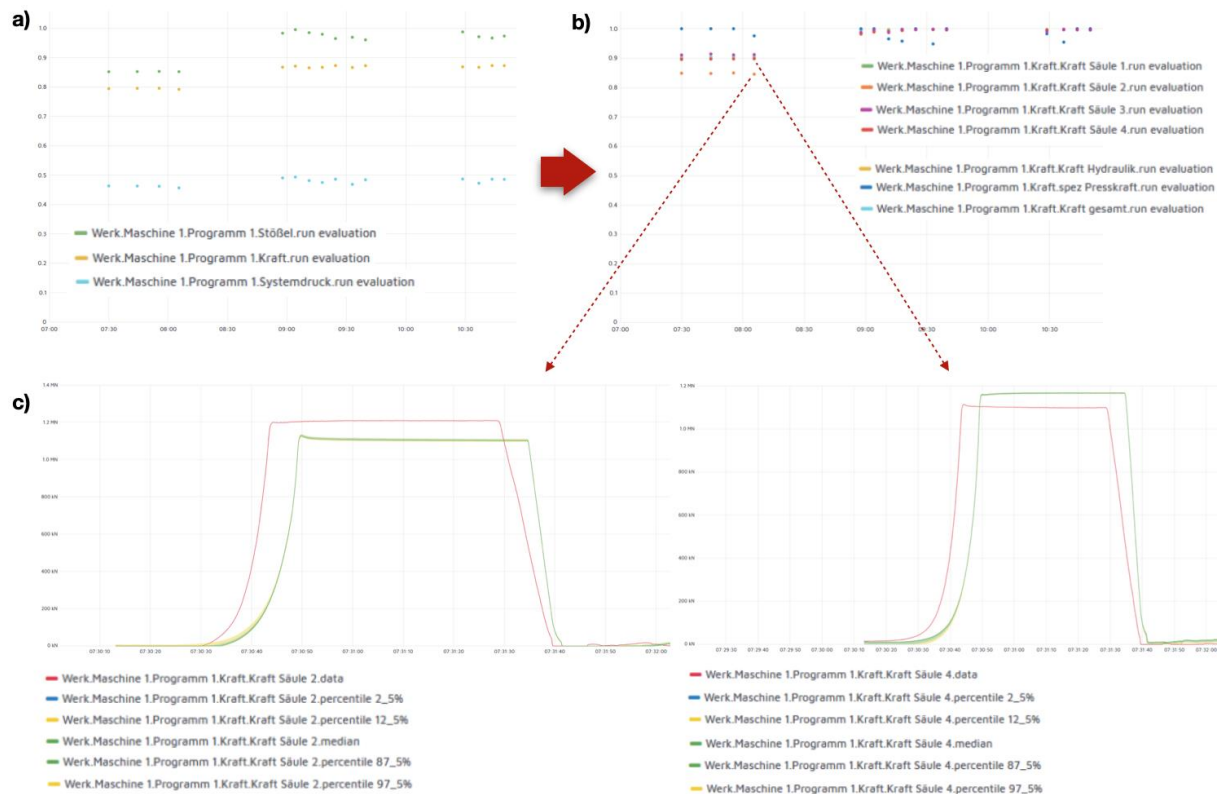


Abbildung 5: Drill-Down Vorgehen für die Abweichungsanalyse mehrerer Prozessdurchläufe einer hydraulischen Presse

5. Edge Computing zur direkten Datenaufbereitung

Statt einer Auswertung im Rahmen des gesamten Systems kann es in verschiedenen Fällen sinnvoller sein, die Daten direkt in einer Edge Computing Anwendung maschinennah auszuwerten. Dies kann beispielsweise der Fall sein, wenn die Daten über eine Livevisualisierung direkt an der Maschine für den Maschinenbediener genutzt werden oder die Menge der Rohdaten eine Vorverarbeitung zur Datenreduktion notwendig macht. Im Folgenden werden aus beiden Bereichen je ein Beispiel vorgestellt, die sich mit dem oben bereits vorgestellten Auswertungskonzepten kombinieren lassen.

Visualisierung für das Schrittbiegen von Rohren

In der Produktion von großen Konstruktions- und Pipelinerohren ist einer der Produktionsschritte das Schrittbiegen der Rohre. Aus einem geraden Blech wird in einem Dreipunktbiegeverfahren schrittweise ein Rohr geformt. Für die Messung in diesem Prozess gibt es zwei Herausforderungen: Es ist jeweils im Werkzeug nur ein Teilausschnitt des ganzen Rohres bzw. Blechs zu sehen und jeder Biegeschritt ist einer Rückfederung unterworfen. Aktuell wird der Soll-Durchmesser des Rohrs mit dem gemessenen Durchmesser beim Einlernen der Biegepositionen anhand einer Schablone manuell vom Bediener der Anlage abgeglichen. Je nach Rohrhersteller werden dann auch die angelegten Positionen des Biegevorgangs teilweise wieder mit der Schablone überprüft, da in Materialchargen Schwankungen der Materialparameter vorliegen können.

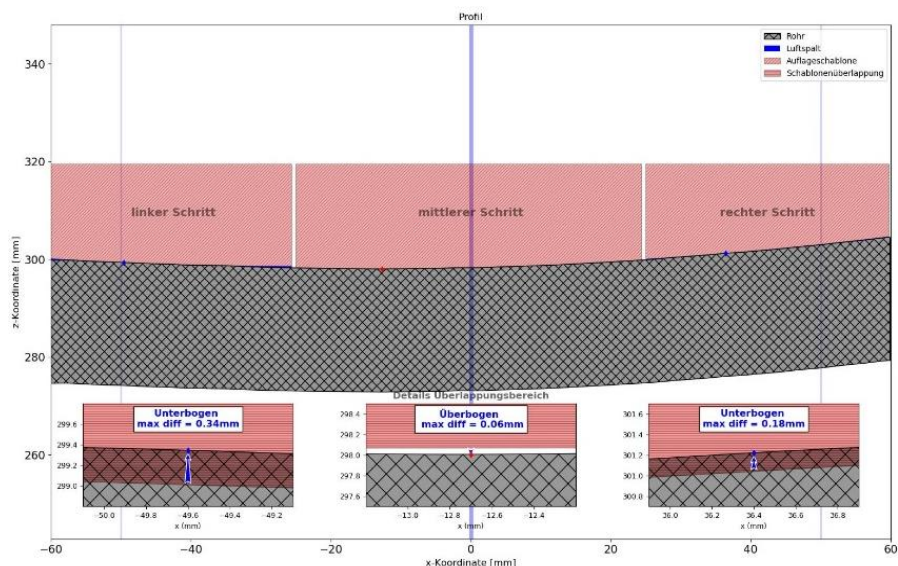


Abbildung 6: Visualisierung mit digitaler Schablone für das Schrittbiegen von Rohren

Um den Bediener ein einfach zu verwendendes Assistenzsystem zu bieten, wird ein Lasersensor verwendet, der die aktuelle Außenkontur des zu biegenden Bleches im Werkzeug misst. Daraus wird der relevante Innenradius berechnet und für den Bediener als Matching mit einer digitalen Schablone je Teilabschnitt dargestellt. In Abbildung 6 ist zu sehen, dass zudem noch eine maximale Abweichung für die Teilabschnitte gegeben ist. Diese Information kann mit den oben vorgestellten Analysen wieder gekoppelt werden.

Darüber hinaus wird für das Rohr die lokale Krümmung berechnet. Diese kann bei Bedarf ebenfalls für den Bediener dargestellt werden. Die Krümmung ist sehr hilfreich, um zum Beispiel die Einflusszonen des Biegeschrittes zu bestimmen und somit ggf. die Schrittweite zu optimieren oder die Rückfederung besser abschätzen zu können. Dadurch kann eine

schnellere Kompensation erreicht werden [8]. Der Verlauf der Krümmung oder deren Maxima sind ebenfalls eine gute Grundlage für nicht überwachte Lernmethoden, um zum Beispiel Rückschlüsse über die Materialqualität oder Informationen für Folgeprozesse zu generieren.

Schwingungsdatenanalyse

Bei der Analyse von Schwingungsdaten, zum Beispiel aufgenommen zur Analyse von Fräsprozessen, treten je nach Frequenzspektrum sehr hohe Datenmengen auf. Beschleunigungssensoren liefern Messwerte beispielsweise im Bereich von 10kHz. Die Übertragung solcher Rohdatenmengen an einen Server ist nicht sinnvoll.

In ersten Untersuchungen der Datenanalyse eines Fräsprozesses hat sich herausgestellt, dass relevante Aspekte wie der Verschleiß der Wendeschneidplatten am Fräskopf, die Spannung von Transmissionsriemen oder auch die Maschinenstabilität erkennbar sind.

Die Detektion ist ebenfalls nach einer Reduktion der aufgezeichneten Vibrationsrohdaten mittels vorausgewerteter statistischer Merkmale, wie zum Beispiel dem quadratischen Mittel (Root Mean Square) oder dem Scheitelfaktor (Crest Factor) des Rohsignals zuverlässig. Diese reduzierte Datenmenge kann dann ebenfalls an den Server weitergeleitet werden, um dort Analysen vorzunehmen.

In den Voruntersuchungen hat sich gezeigt, dass Entscheidungsbaumverfahren (Decision Trees) eine gute Möglichkeit bieten, die Daten überwacht zu analysieren. Der auf dem Server angelernete Entscheidungsbaum kann auch wieder zurück in den lokalen Prozess gespielt werden, um dort anhand der Livedaten relevante Ereignisse im Fräsprozess zu klassifizieren. Darüber hinaus ist die Analyse von zeitkontinuierlichen Verschleißvorhersagemodellen auf Basis der aufgenommenen und annotierten Schwingungsdaten in Planung.

6. Zusammenfassung und Ausblick

Es wurde eine prinzipielle Softwarearchitektur vorgestellt, die es ermöglicht, verschiedene Analysen durchzuführen und diese auch zu erweitern. Mit verschiedenen Beispielen wurde gezeigt, wie sich diese sehr schnell für verschiedene Anwendungsfälle einsetzen lassen. Durch seine Flexibilität ermöglicht der Ansatz insbesondere kleinen Unternehmen einen einfachen Einstieg in die Themen Digitalisierung und Künstliche Intelligenz.

Durch die Einführung eines digitalen Logbuchs wird es einem Kunden zukünftig ermöglicht, wichtige Informationen zum Maschinenstatus schnell zu dokumentieren und in Echtzeit für alle relevanten Personen bereitzustellen. Das integrierte konsistente Labeling der Daten kann dann als Grundlage für kundenspezifische, überwachte Lernalgorithmen verwendet werden.

Die daraus entwickelten Algorithmen können schnell in die bestehende Architektur integriert und die Produktivität weiter erhöht werden.

Literatur

- [1] M. Rudolph, B. Wandt and B. Rosenhahn. "Same same but different: Semi-Supervised Defect Detection with Normalizing Flows." WACV (2021)
- [2] S. Qi, J. Yang, and Z. Zhong. "A Review on Industrial Surface Defect Detection Based on Deep Learning Technology." MLMI, NY, USA, (2020): 24–30
- [3] G.E. Kondhalkar, G. Diwakar. "Crest Factor Measurement by Experimental Vibration Analysis for Preventive Maintenance of Bearing." ICRRM, Springer (2019)
- [4] E. Traini, G. Bruno, G. D'Antonio, F. Lombardi. "Machine Learning Framework for Predictive Maintenance in Milling." IFAC 52 (2019): 177-182
- [5] C. Lu, Z. Wang, W. Qin, J. Ma. "Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification." Signal Processing 130 (2017): 377-388
- [6] B. Lindemann, F. Fesenmayr, N. Jazdi, M. Weyrich. "Anomaly detection in discrete manufacturing using self-learning approaches." Procedia CIRP 79 (2019): 313-318
- [7] G. Steinhagen, A. Hoffmann. "Process surveillance in hydroforming based on machine learning algorithms." Procedia Manufacturing 27 (2019): 57-64.
- [8] G. Steinhagen, F. Kapp. „Neuer Ansatz für das automatische Schrittbiegen von Großrohren.“ 31. ASK Umformtechnik (2018)