



Fehlermanagement 4.0

Effiziente Fehlerabstellung und -vermeidung mittels Künstlicher Intelligenz

Um wettbewerbsfähig zu bleiben, spielt der Umgang mit aufgetretenen Produkt- und Prozessfehlern eine entscheidende Rolle, da diese sowohl zur Verlängerung der Durchlaufzeit als auch zu kostspieliger Nacharbeit führen. Der Lehrstuhl für Fertigungsmesstechnik und Qualitätsmanagement des Werkzeugmaschinenlabors WZL der RWTH Aachen University hat im Zuge des Forschungsprojekts „Learning Failure Management (LeaF)“ den Einsatz von Data Analytics zur Abstellung und Vermeidung von Produktionsfehlern untersucht und einen systematischen Ansatz zur modernen Fehlererfassung und -analyse entwickelt.

Robin Günther, Kai Wangerow, Robert H. Schmitt

Das Auftreten von Produkt- oder Prozessfehlern ist ein Störfaktor bei der Fertigung qualitativ hochwertiger Produkte. Je länger es dauert, diese Fehler zu entdecken und abzustellen,

desto teurer wird der damit verbundene Schaden. So belegen aktuelle Studien, dass die internen und externen Fehlerkosten, denen unter anderem die Kosten sowohl für die Fehleranalyse und -nachbearbei-

tung als auch für die Reklamationsbearbeitung oder Schadenersatzansprüche zugeordnet werden können, einen Großteil der Qualitätskosten im Unternehmen ausmachen. Im Maschinenbau, als ein Beispiel für

das produzierende Gewerbe, machen diese Fehlerkosten durchschnittlich 2,8 Prozent des jährlichen Unternehmensumsatzes aus, was bei einem durchschnittlichen Umsatz von 50 Millionen Euro zu etwas mehr als 115 000 Euro pro Monat führt [1].

Die fortschreitende Digitalisierung in der Industrie eröffnet neue technologische Möglichkeiten, die ebenfalls im Fehlermanagement genutzt werden können. Zum einen ermöglicht der Einsatz von mobilen Endgeräten in der Produktion eine schnelle, digitale und vollständige Erfassung entstandener Fehler (siehe Ergebnisse der Forschungsprojekte „LeaF“ [2] und „SmartFM“ [3]). Zum anderen bieten große, kontinuierlich wachsende Datenbestände die Möglichkeit, Methoden aus dem Bereich Data Analytics zur Untersuchung der erfassten Fehlerdaten einzusetzen. Die genannten Entwicklungen bieten das Potenzial, Produkt- und Prozessfehler im gesamten Produktionsprozess effektiver und effizienter zu erfassen, zu analysieren und abzustellen als zuvor.

Status quo der Fehleranalyse in deutschen Unternehmen

Im Zuge der Projektbearbeitung von „LeaF“ (siehe Infokasten) wurden 30 deutsche Unternehmen unterschiedlicher Größe und verschiedener Branchen des produzierenden Gewerbes dahingehend befragt, wie sie entstandene Produkt- oder Prozessfehler innerhalb ihres Unternehmens erfassen und analysieren.

Im Fokus stand dabei die Aufnahme von Methoden zur Erfassung und Analyse von Fehlern sowie die Ermittlung von Häufigkeit und Zweck der Fehleranalyse. Zu-

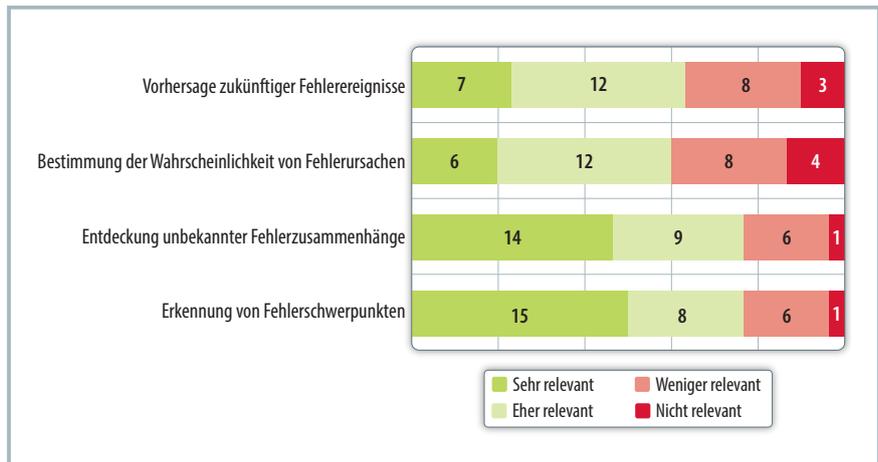


Bild 1. Funktionen eines KI-gestützten Fehlermanagementsystems Quelle: WZL, Grafik: © Hanser

dem wurden die Unternehmen bezüglich verschiedener Funktionen eines KI-gestützten Fehlermanagementsystems befragt (Bild 1). Die Ergebnisse der Befragung stellen dabei insbesondere vier wesentliche Punkte in den Vordergrund:

- Die Erfassung von Produkt- und Prozessfehlern während der Produktion wird teils digital, teils analog durchgeführt. Nur wenige Unternehmen greifen dabei auf eine automatische Erfassung zurück; in den meisten Fällen werden die Fehler manuell dokumentiert.
- Erfasste Fehler werden von allen befragten Unternehmen analysiert, wenn auch nicht immer kontinuierlich. Zurzeit beabsichtigen die meisten Unternehmen damit, die aktuelle Fehlerlage zu beschreiben, Fehlerursachen zu ermitteln sowie Handlungsmaßnahmen abzuleiten. Nur wenige Unternehmen sehen in der Fehlerdatenanalyse momentan den Zweck, zukünftige Fehlerereignisse vorherzusagen.

- Zur Datenanalyse werden aktuell noch deutlich häufiger Visualisierungsmethoden oder einfache statistische Methoden eingesetzt als moderne Ansätze aus dem Bereich Data Analytics.
- Knapp zwei Drittel der Befragten betrachten die Vorhersage zukünftiger Fehlerereignisse für eine relevante Funktion eines KI-gestütztes Fehlermanagementsystems. Zusätzlich betrachtet es die Mehrheit ebenfalls als wünschenswert, die Wahrscheinlichkeit von Fehlerursachen bestimmen zu können, unbekannte Fehlerzusammenhänge zu entdecken und Fehlerschwerpunkte zu erkennen.

Die Befragung verdeutlicht, dass viele Unternehmen die oben genannten Funktionen eines KI-gestützten Fehlermanagementsystems zukünftig für relevant halten, aktuell jedoch noch sehr weit vom Einsatz der hierfür notwendigen, modernen Analysemethoden aus dem Bereich Data Analytics entfernt sind. Dies liegt vor allem darin begründet, dass entsprechendes Methodenwissen nicht verfügbar ist oder die notwendigen Ressourcen, wie beispielsweise Analysesoftware und entsprechende Personalkapazitäten, nicht vorhanden sind [4].

DCMIO-Zyklus für eine effiziente Fehleranalyse und -abstellung

Um dieser Herausforderung gerecht zu werden, wurde im Zuge von „LeaF“ eine Methodik für ein lernendes Fehlermanagement entwickelt. Ziel dieser Methodik ist es, Produkt- und Prozessfehler, die während der Produktion auftreten und im Zuge von manuellen Qualitätsprüfungen er- >>>

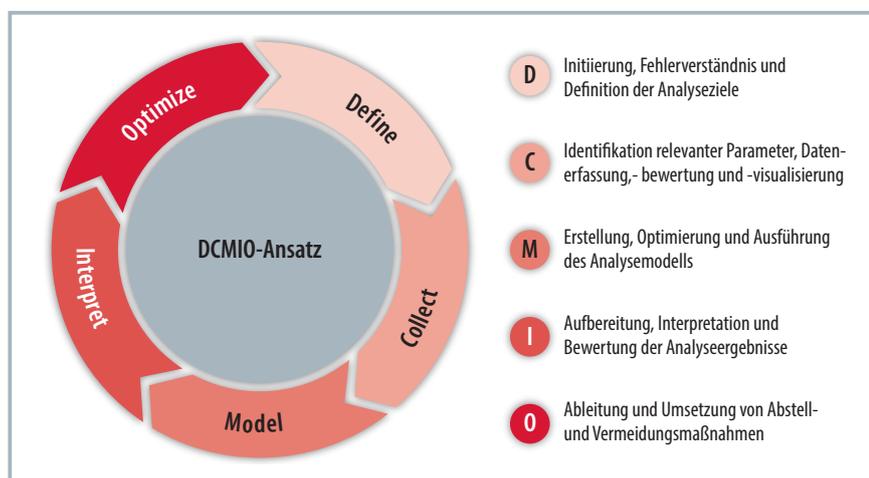


Bild 2. Der DCMIO-Zyklus für eine effiziente Fehleranalyse und -abstellung Quelle: WZL, Grafik: © Hanser

INFORMATION & SERVICE

REFERENZIERTE
FORSCHUNGSPROJEKTE

LeaF (Learning Failure Management) steht für die Verbesserung der Fehlerdatenqualität und -nutzung durch die Etablierung eines lernenden Fehlermanagementansatzes. Durch die bedarfsgerechte, strukturierte Fehlererfassung werden die Anwender zur Nutzung von Data-Analytics-Methoden zur Fehleranalyse befähigt. www.leaf.wzl.rwth-aachen.de

SmartFM wurde im Rahmen des Verbundprojekts „Fehlermanagementintegration in die Smart Factory“ von der PRS Technologie Gesellschaft mbH sowie der izsolutions GmbH als ein Werkzeug zur digitalen Fehlererfassung und -verarbeitung entwickelt. Aus dem Projekt ist das System SmartQM entstanden. www.smart-qm.com

FÖRDERHINWEIS

Die FQS Forschungsgemeinschaft Qualität e. V. (FQS) fördert das IGF-Vorhaben „Learning Failure Management (LeaF)“ über die AiF (AiF-Nr.: 19931N) im Rahmen des Programms zur Förderung der Industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages.

LITERATUR

- 1 **Mertens, H.; Huber, G.:** Methode zahlt sich aus. Deutliche Abhängigkeiten zwischen Qualitätskosten und Qualitätsmethoden. QZ 1/2016, S. 30–33
- 2 **Günther, R.; Schmitt, R. H.:** Digitalisierung des Fehlermanagements – Ein (selbst-)lernender Ansatz für kleine und mittlere Unternehmen (KMU). ZWF 6/2020, S. 391–393
- 3 **Kukulies, J.; Pohlmann, G.; Wangerow, K.:** Fehlermanagement profitiert von Digitalisierung – Fehlermanagement per App und Webbrowser. QZ 10/2019, S. 52–55
- 4 **Grogger, S.; Wenking, M., et al.:** Status Quo and Future Potential of Manufacturing Data Analytics – An Empirical Study. IEEE (Hrsg.): International Conference on Industrial Engineering & Engineering Management, 2017, S. 779–783

Phase	Inhalt	Methoden und Werkzeuge
Define	<ul style="list-style-type: none"> • Zusammenstellung des Analyseteams • Festlegung der Randbedingungen • Schaffung von Fehler-, Produkt- und Prozessverständnis • Festlegung der Analyseziele 	<ul style="list-style-type: none"> • AKV-Modell • 7W-Fragen • SIPOC-Analyse • VOC-Interview
Collect	<ul style="list-style-type: none"> • Identifikation relevanter Parameter • Planung der Datenerfassung • Durchführung der Datenerfassung • Visualisierung der Rohdaten • Beurteilung der Datenqualität • Verbesserung der Datenqualität 	<ul style="list-style-type: none"> • Ishikawa-Diagramm • Liste möglicher Parameter • Grafiken zur Datenvisualisierung (Häufigkeits-, Pareto-, Streu-, Box-Plot-Diagramm) • Übersicht der Datenqualitätsdimensionen
Model	<ul style="list-style-type: none"> • Auswahl einer Analysemodellklasse • Auswahl mehrerer Analysemodelle • Ausführung von Modelltests • Optimierung der Analysemodelle • Auswahl eines Analysemodells • Durchführung der Fehlerdatenanalyse 	<ul style="list-style-type: none"> • Liste zur Zuordnung von Analysemodellklasse und Analysezielen (Beschreibung, Klassifikation, Regression, Clustering, Assoziation, Ausreißerkennung) • Auswahlkriterien für Analysemodelle • Liste möglicher Analysemodelle • Methoden zur Modellvalidierung (Cross Validation, Genauigkeitsdiagramm, Confusion-Matrix, ROC-Graph)
Interpret	<ul style="list-style-type: none"> • Aufbereitung der Analyseergebnisse • Interpretation der Analyseergebnisse • Bewertung der Analyseergebnisse 	<ul style="list-style-type: none"> • Grafiken zur Ergebnisvisualisierung (Häufigkeits-, Streu-, Box-Plot-Diagramm, Entscheidungsbaum, Clusterabbildung, Ausreißervisualisierung) • Liste von Bewertungskriterien
Optimize	<ul style="list-style-type: none"> • Identifikation von Optimierungsmaßnahmen • Bewertung von Optimierungsmaßnahmen • Auswahl einer oder mehrerer Optimierungsmaßnahmen • Umsetzung der Optimierungsmaßnahme(n) • Bewertung der Umsetzung 	<ul style="list-style-type: none"> • Kreativitätstechniken (Brainstorming, Affinitätsdiagramm, 6-3-5-Methode, Morphologischer Kasten, Design Thinking) • Methoden zur Maßnahmenbewertung und -auswahl (paarweiser Vergleich, Ranking, K.O.-Analyse, Pugh-Matrix, Platzzifferverfahren, Nutzwertanalyse)

Bild 3. Inhalte, Methoden und Werkzeuge des DCMIO-Zyklus Quelle: WZL, Grafik: © Hanser

fasst wurden, zu analysieren und nachhaltig abzustellen bzw. präventiv zu vermeiden. Kern der Methodik ist der DCMIO-Zyklus (kurz für: Define, Collect, Model, Interpret, Optimize), der als Rahmenwerk und Vorgehensweise zur strukturierten Fehlerdatenanalyse dient. Dieser vereint die wesentlichen Inhalte des Six-Sigma-DMAIC- und des CRISP-DM-Zyklus und verwendet bzw. kombiniert daher verschiedene Methoden aus den Bereichen Qualitätsmanagement und Data Mining (Bild 2).

In der *Define*-Phase wird zunächst das Projekt initiiert und ein allgemeines Verständnis über das Produkt, den Prozess und entsprechende Fehler geschaffen. Ein wichtiger Schritt ist in diesem Zusammenhang die Definition von Analysezielen, welche das Vorgehen der sich anschließenden Schritte maßgeblich beeinflussen.

Die *Collect*-Phase befasst sich mit der Identifikation relevanter Parameter innerhalb der Fehler-, Produktions- oder Prüfprotokolldaten und stellt die Erfassung der Daten sicher. Zur Vorbereitung der nachfolgenden Phase werden die gesammelten Daten in ihrer Rohform visualisiert, bezüglich ihrer Datenqualität bewertet und, falls nötig, in einer analysefähigen Form aufbereitet.

Zu Beginn der *Model*-Phase erfolgt zunächst die Auswahl einer geeigneten Analysemodellklasse, innerhalb derer im Anschluss mehrere mögliche Analysemodelle anhand definierter Kriterien erstellt und ausgeführt werden. Die gewählte Klasse und folglich zu berücksichtigende Modelle hängen hierbei in großem Maß von den initial definierten Analysezielen ab. Durch eine Validierung können Aussagen über die Genauigkeit und Interpretierbarkeit der Modelle getroffen und bedarfsgerecht Modell- oder Datensatzoptimierungen durchgeführt werden. Anschließend erfolgt eine Entscheidung für eines der Modelle, mit dem die eigentliche Fehlerdatenanalyse durchgeführt wird.

Die Ergebnisse werden in der *Interpret*-Phase grafisch aufbereitet und von einem heterogenen Team aus Qualitätsingenieuren, Datenanalysten und Prozessverantwortlichen interpretiert.

Sollten die Ergebnisse Aufschluss über die Fehlerursachen geben, werden in der *Optimize*-Phase mögliche Optimierungsmaßnahmen identifiziert, bewertet, priorisiert und umgesetzt. Abschließend wird im Sinne eines Vorher-Nachher-Vergleiches bewertet, ob die Maßnahmen zum gewünschten Erfolg geführt haben. Das im



Bild 4. Zuordnung der Analyseziele zu den Analysemodellklassen und beispielhafte Analysemodelle Quelle:

WZL, Grafik: © Hanser

Zuge der Fehlerdatenanalyse gewonnene Wissen sollte zudem als Teil des Wissensmanagements der Fehlerdatenbasis zugeführt werden, um auch zukünftig von den Arbeitsergebnissen profitieren zu können. Bild 3 fasst die Inhalte der einzelnen Phasen sowie die verwendbaren Methoden und Werkzeuge zusammen.

In 5 Schritten zu einer modernen Fehleranalyse mittels KI

- 1. Stellen Sie ein heterogenes Team aus Qualitätsingenieuren, Datenanalysten, Prozessverantwortlichen und Projektmanagern zusammen und beschaffen Sie sich eine geeignete Software für Data-Mining-Anwendungen.
- 2. Legen Sie sinnvolle Ziele für Ihre Fehlerdatenanalyse fest. Greifen Sie dabei auf die SMART-Logik zurück.
- 3. Erfassen Sie relevante Fehler- und Produktionsdaten mit einer geeigneten Software direkt in strukturierter, digitaler Form. Im Zuge der Forschungsprojekte „Leaf“ und „SmartFM“ ist jeweils ein solches Werkzeug entstanden (siehe Infokasten). Beurteilen und verbessern Sie gegebenenfalls die Datenqualität.
- 4. Wählen Sie eine geeignete Analysemodellklasse entsprechend der von Ihnen festgelegten Analyseziele aus.
- 5. Bereiten Sie die Analyseergebnisse grafisch auf und interpretieren Sie diese. Leiten Sie aus den Ergebnissen mit Hilfe von Kreativitätstechniken Maßnahmen zur Optimierung ab.

Fazit: Zeit und Kosten durch KI bei der Fehleranalyse

Durch ein Umdenken deutscher Unternehmen und einen Wandel hin zur Digitalisierung in der Produktion und im Qualitätsmanagement lassen sich sowohl Zeit als auch Kosten einsparen. Mithilfe einer KI-basierten Fehleranalyse lassen sich Produkt- und Prozessfehler effektiver und effizienter abstellen als zuvor. Dieser Artikel zeigt die ersten Schritte auf, um sich mit den Themen Digitalisierung und Künstlicher Intelligenz im Rahmen eines effizienten Fehlermanagements auseinanderzusetzen. ■

INFORMATION & SERVICE

AUTOREN

Robin Günther, M.Sc., ist wissenschaftlicher Mitarbeiter in der Gruppe Process Insights am Werkzeugmaschinenlabor WZL der RWTH Aachen.

Kai Wangerow, M.Sc., ist Projektingenieur und Assistent der Geschäftsführung bei der PRS Technologie Gesellschaft mbH in Aachen. Die PRS überführt innovative Lösungsansätze aus dem Hochschul Umfeld in praxisnahe Lösungen, Produkte und Dienstleistungen.

Prof. Dr.-Ing. Robert Schmitt ist Inhaber des Lehrstuhls für Fertigungsmesstechnik und Qualitätsmanagement am Werkzeugmaschinenlabor WZL der RWTH Aachen.

KONTAKT

Robin Günther
 T 0241 80 28221
 r.guenther@wzl.rwth-aachen.de