

(Selbst-)lernendes Fehlermanagement

Expertise der Fehlerbearbeitung systematisch nutzbar machen

Der Einsatz moderner Analysemethoden bietet das Potenzial zur effizienten Abstellung von Produkt- und Prozessfehlern. Eine wesentliche Voraussetzung ist die strukturierte Pflege und systematische Nutzung einer Wissensbasis, die sowohl das historische Fehleraufkommen als auch die zugehörigen Maßnahmen der Problemlösung einschließt. Im Rahmen des IGF Verbundprojektes „LeaF – Learning Failure Management“ (AiF-Nr.: 19931N) wurde ein (selbst-)lernender Fehlermanagementansatz entwickelt, welcher insbesondere KMU dazu befähigt, unternehmerisches Fehlerwissen nutzbar zu erfassen, aufzubereiten und entsprechende Erkenntnisse für die künftige Fehlerbehebung abzuleiten.

Robin Günther, Sebastian Beckschulte, Nicolas Bennerscheid und Robert H. Schmitt

Als Teil des Qualitätsmanagements stützt das Fehlermanagement die Erreichung von Leistungs- und Qualitätszielen des Unternehmens. Das Auftreten von Fehlern stellt einen Störfaktor dar, welcher begrenzte Produktionsressourcen bindet. Je mehr Zeit vergeht, bis Fehlerursachen identifiziert und abgestellt werden, desto höher werden die hieraus resultierenden Kosten. Die Dauer von der Identifikation bis zur Abstellung der Fehlerursache verhält sich dabei progressiv zu den daraus resultierenden Fehlerkosten [1]. Aus diesem Umstand folgt das unternehmerische Bestreben, den Prozess der Fehlerbeseitigung mithilfe übergeordneter Maßnahmen des Fehlermanagements zu stützen und die damit einhergehenden Fehlerkosten deutlich zu reduzieren.

Erhebliche Potenziale ergeben sich in diesem Zusammenhang insbesondere durch die zunehmende Digitalisierung und der damit einhergehenden Chance zur Analyse stetig wachsender Datenmengen. Untersuchungen im Rahmen des Projektverlaufs zeigen jedoch auf, dass eine Diskrepanz zwischen der Erkenntnis der Relevanz und der tatsächlichen Implementierung moderner Analysemethoden in das Portfolio des Fehlermanagements vorliegt [2]. Zum einen ist dies auf die geringe Vorer-

fahrung im Umgang mit datenbankbasierten Analyseverfahren zurückzuführen. Zum anderen verhindern häufig vorliegende, heterogene Fehlerbeschreibungsstrukturen sowie das Fehlen umfänglicher Mechanismen zur Fehlerfassung und -dokumentation den zielführenden Einsatz der Methoden bzw. resultieren in hohen Aufwänden im Rahmen der Datenaufbereitung [3]. Aufgrund der genannten Hürden können auch bei aktivem Betreiben eines Fehlermanagements weder ein systematischer Lerneffekt erzielt werden, noch lassen sich entstehende Fehlerkosten langfristig reduzieren. In Zusammenarbeit mit KMU verschiedener Branchen wurde vom Werkzeugmaschinenlabor WZL der RWTH Aachen ein umfassender Ansatz entwickelt, welcher die zuvor ermittelten Herausforderungen adressiert.

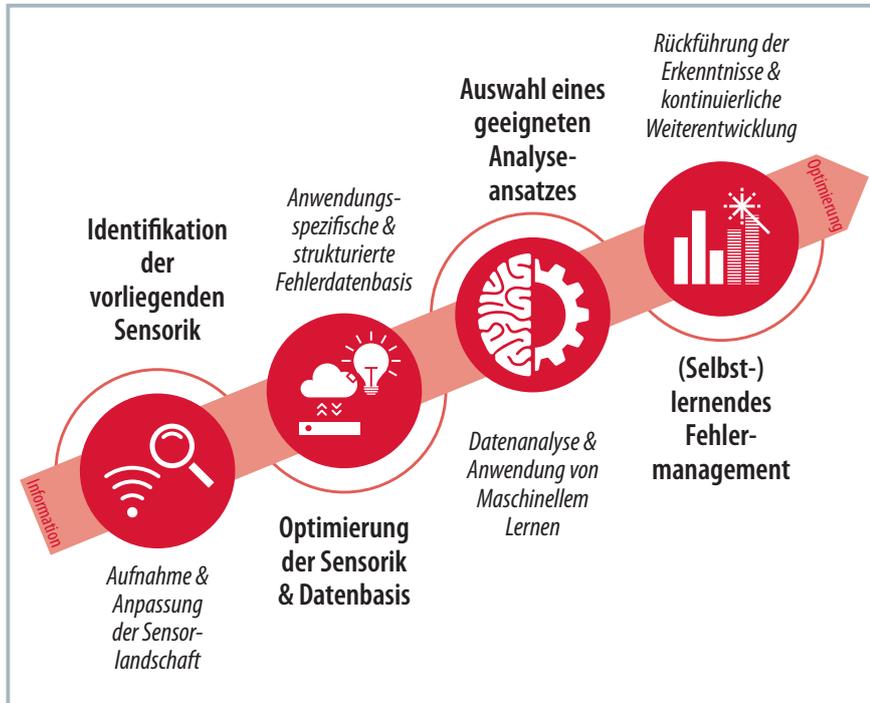
Das A und O eines jeden erfolgreichen Fehlermanagements: Eine valide Datenbasis

Der erste Schritt auf dem Weg hin zu einer validen Analyse des unternehmerischen Fehlergeschehens besteht in der Absicherung der Verfügbarkeit und Vollständigkeit des vorhandenen Fehlerwissens. Eine Datenbasis über vergangene Fehler ermöglicht einen Zugriff auf bereits erarbeitetes

Wissen im Umgang mit Fehlerfällen – beispielsweise in Form erfolgreich umgesetzter Lösungen. Weiterhin sichern Unternehmen den Erfahrungsschatz ihrer Mitarbeitenden digital ab und mindern die Abhängigkeit von einzelnen Wissensträgern.

In erster Instanz sind hierzu die im Unternehmen vorliegenden Sensoriken und Mechanismen der Datenaufnahme zu prüfen und notwendige Erweiterungspotenziale zu evaluieren. Bei Lücken in der Datenerfassung in Arbeitsschritten mit einem hohen menschlichen Anteil, lässt sich die Datenverfügbarkeit bereits durch einfache organisatorische Maßnahmen steigern. Zu beachten ist jedoch, dass einfache Lösungen Nachteile hinsichtlich der Analysefähigkeit verursachen und zum Teil aufwendige Überführungsarbeiten in die digitale Form mit sich bringen. Aber auch digitale Varianten mit der Option zur individuellen, verbalen Fehlerbeschreibung können zu größeren Aufbereitungsaufwänden führen und, in Abhängigkeit der unternehmerischen Präferenz, die Einführung weiterer strukturierender Erfassungsmechanismen notwendig machen.

Zur Auswahl steht eine große Varianz an Detektions- und Erfassungswerkzeugen unterschiedlichen Digitalisierungsgrades, deren Anschaffung und Einsatz unter Be-



Entwicklung hin zum (selbst-)lernenden Fehlermanagement
 Quelle: Werkzeugmaschinenlabor WZL der RWTH Aachen ©

© Hanser

INFORMATION & SERVICE

REFERENZIERTES FORSCHUNGSPROJEKT

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.
<http://www.leaf.wzl.rwth-aachen.de>

FÖRDERHINWEIS

Das IGF-Vorhaben „LeaF – Learning Failure Management“ (19931 N) der Forschungsvereinigung Forschungsgemeinschaft Qualität e.V. (FQS), August-Schanz-Straße 21A, 60433 Frankfurt am Main wurde über die AiF im Rahmen des Programms zur Förderung der Industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages gefördert.

LITERATUR

- 1 **Mertens, H.; Huber, G.:** Methode zählt sich aus. Deutliche Abhängigkeiten zwischen Qualitätskosten und Qualitätsmethoden. QZ 1/2016, S. 30–33.
- 2 **Günther, R.; Wangerow, K., Schmitt, R. H.:** Fehlermanagement 4.0. Effiziente Fehlerabstellung und -vermeidung mittels Künstlicher Intelligenz. QZ 12/2020, S. 18–21.
- 3 **Günther, R.; Schmitt, R. H.:** Digitalisierung des Fehlermanagements – Ein (selbst-)lernender Ansatz für kleine und mittlere Unternehmen (KMU). ZWF 6/2020, S. 391–393.
- 4 **Frydman P. J.; Cantú O. F.; Sierra C. J.; Morales-Menéndez R.:** Model Selection Data Mining: An statistical approach. Research on Computing Sciences. 16/2005, S. 65–74.
- 5 **Ding J.; Tarokh V.; Yang Y.:** Model Selection Techniques: An Overview. IEEE Signal Process. Mag. 2018;35(6), S. 16–34.

achtung von Kosten-Nutzen-orientierten Gesichtspunkten zu bewerten ist. So können vor allem die Anschaffungskosten eines Sensors sowie dessen Fähigkeit hinsichtlich der Entdeckungsgeschwindigkeit und -wahrscheinlichkeit in die Entscheidung einfließen. Weiterhin kann ebenfalls der Einfachheit, der Verifizierbarkeit und der Unabhängigkeit von anwender- und umgebungsbezogenen Einflüssen eine Bedeutung im Rahmen der Beurteilung zugeschrieben werden.

Im Hinblick auf die Analysefähigkeit sollte jedoch insbesondere die Struktur und Qualität der generierten Informationen eine entscheidende Rolle spielen. Einerseits werden hierdurch die Validität der Analyseergebnisse gesteigert und andererseits die Aufwände der Datenvorverarbeitung reduziert. Dokumentationsstrukturen sollten dementsprechend die eindeutige Erfassung und Verknüpfung von Prozess-, Produkt-, Fehler- sowie zugehöriger Ursachen- und Maßnahmeninformationen gewährleisten. Ein möglicher Lösungsansatz stellt beispielsweise eine unternehmensspezifische Fehlerbaumstruktur dar, welche Produkt und Prozessinformationen berücksichtigt und zudem die Informationskette Fehler-Ursache-Maßnahme abbildet (vgl. [3]). Hierbei können beschränkte Freiheitsgrade der Beschreibung systemisch realisiert werden, welche die Eindeutigkeit der Fehlerdaten absichert und somit

eine strukturierte Dokumentation gewährleistet. Die genannten Aspekte dienen als Orientierung zum Aufbau einer strukturierten Fehlerdokumentation, welche die notwendige Voraussetzung für die anschließende Analyse schafft.

Die effiziente Abstimmung von Produkt- und Prozessfehlern: Systematisches Lernen aus Fehlern

Zur Umsetzung der Fehleranalyse ist ein geeignetes Analyseverfahren beziehungsweise ein spezifischer Algorithmus auszuwählen. Die hierbei zu beantwortende Fragestellung kann wie folgt formuliert werden: „Welcher Algorithmus liefert bei der Analyse des vorliegenden Datensatzes die besten Ergebnisse in Bezug auf die verfolgte Zielsetzung?“ [4]. Diesbezüglich besteht eine starke Abhängigkeit zum festgelegten Betrachtungsfokus und zum verfolgten Analyseziel. Wählt man beispielsweise ein unpassendes Verfahren aus, besteht die Gefahr unvollständiger Vorhersagen und irreführender Schlussfolgerungen [5]. So können Clusterverfahren zur Identifikation unbekannter Zusammenhänge und Schwerpunkte herangezogen werden, liefern jedoch keinen Mehrwert für die Ableitung zum Fehlerbild zugehöriger Ursachen- oder Maßnahmeninformationen. Auch innerhalb einer „Verfahrensklasse“ können Unterschiede zwischen den Algorithmen im Hinblick auf die Leistungsfähigkeit und Aussagekraft ausge-

macht werden, die bei der Festlegung auf ein Analyseverfahren zu berücksichtigen sind.

Um insbesondere KMU die Umsetzung einer intelligenten Fehleranalyse zu ermöglichen, wurde bereits ein Vorgehensmodell vorgestellt, welches in fünf Schritten an eine KI-gestützte Fehleranalyse heranführt [2]: Define, Collect, Model, Interpret und Optimize. Im Weiteren wird insbesondere der Modellierungs- und Interpretationsphase eine besondere Aufmerksamkeit geschenkt.

Der Fokus des Forschungsprojektes liegt auf der Realisierung eines (selbst-)lernenden Fehlermanagementansatzes, welcher KMU dazu befähigt, mögliche Ursachen und geeignete Maßnahmen auf Basis historischer Fehlerdaten systematisch zu identifizieren. Für diese Fragestellung zeigen sich insbesondere „Klassifikationsalgorithmen“ als besonders fähig. Durch die Festlegung auf eine „Verfahrensklasse“ wird die Anzahl der Algorithmen bereits frühzeitig eingeschränkt und vereinfacht die Identifikation des geeignetsten Ansatzes. Zur weiteren Befähigung des Nutzers wurde ein Selektionsmodell erarbeitet, welches die Festlegung auf einen Algorithmus durch Einbezug datenseitiger und nutzerbedingter Entscheidungskriterien unterstützt.

Die datenseitigen Kriterien evaluieren die Leistungsfähigkeit des Verfahrens für den vorliegenden Anwendungsfall. Hierzu wird jeder der betrachteten Klassifikationsalgorithmen auf Basis eines verfügbaren Datensatzes getestet und eine leistungsorientierte (unter anderem Vorhersagegenauigkeit) Rangfolge erstellt. Als zusätzliche Entscheidungsperspektive dienen die Nutzerpräferenzen, welche beispielsweise die Anpassungsfähigkeit des Algorithmus, die Interpretierbarkeit der resultierenden Ergebnisse und die Erfahrung des Nutzers im Umgang mit einem Verfahren einbeziehen.

Nach der Auswahl kann der Ansatz für den Anwendungsfall optimiert und im Sinne einer lernenden Fehleranalyse angewendet werden. In der praktischen Umsetzung wird der Fehlerabstellprozess durch das Auftreten eines Fehlers ausgelöst. Die Aufnahme der Fehlerdaten sowie zugehöriger Prozess- und Produktinformationen sollte gemäß den initiierten, strukturierten Erfassungsmechanismen erfolgen.

Anhand dieser Daten sowie deren Abgleich mit der verfügbaren Wissensbasis ermittelt der Klassifikationsalgorithmus

geeignete Fehlerabstellmaßnahmen inklusive einer zugehörigen Wahrscheinlichkeit des Zutreffens. Auf Basis dieser Informationen kann der Nutzer eine Entscheidung für das weitere Vorgehen treffen. So kann dem System vertraut und die wahrscheinlichste Fehlerabstellmaßnahme unmittelbar umgesetzt werden.

Alternativ ist es möglich das System aufgrund der Expertise des Anwenders zu überstimmen. Die abschließende Aussage über den Erfolg der initiierten Maßnahme und folglich der Eignung des Analyseverfahrens, lässt sich in der Praxis mit der Abstellung der Fehler und Wiederholfehler bestätigen. In jedem Fall sollte das im Zuge der Datenanalyse sowie der praktischen Umsetzung gewonnene Wissen in die Fehlerdatenbank überführt werden. Hat beispielsweise eine alternative Maßnahme zum gewünschten Ergebnis geführt, sollte diese Information in der Wissensbasis ergänzt werden. Der angestrebte Lerneffekt entsteht folglich durch die kontinuierliche Erweiterung und Bereinigung der zugrundeliegenden Datenbasis. Die Klassifikationsalgorithmen sind entsprechend in regelmäßigen Abständen zu bewerten und zu adaptieren, um den lernenden Fehlermanagementansatz robust zu realisieren.

Fazit

Die Schaffung einer verlässlichen Datenbasis stellt die erforderliche Voraussetzung zur Implementierung datenbankbasierter Analysemethoden hin zu selbstlernenden Algorithmen dar. Hierbei gilt es zu beachten, dass unterschiedliche Analyseverfahren in Abhängigkeit des vorliegenden Anwendungsfalls sowie Untersuchungszwecks infrage kommen.

Die untersuchten Analyseansätze ermöglichen Unternehmen, die Identifikation von Handlungsalternativen zu auftretenden Fehlern auf Basis des verfügbaren Fehlerwissens. Das Selektionsmodell unterstützt den Anwender bei der Erstausswahl eines Verfahrens. Das erarbeitete Analysekonzept ist dabei mittels frei zugänglicher Softwarelösungen umsetzbar. ■

INFORMATION & SERVICE

AUTOREN

Robin Günther M.Sc. ist wissenschaftlicher Mitarbeiter im Bereich Quality Intelligence – Quality Insights am Lehrstuhl für Fertigungsmesstechnik und Qualitätsmanagement des WZL Werkzeugmaschinenlabor der RWTH Aachen University.

Sebastian Beckschulte M.Sc. ist wissenschaftlicher Mitarbeiter im Bereich Quality Intelligence – Quality Insights am Lehrstuhl für Fertigungsmesstechnik und Qualitätsmanagement des WZL Werkzeugmaschinenlabor der RWTH Aachen University.

Nicolas Bennerscheid M. Eng. ist kfm. Geschäftsführer bei der TUEG Schillings GmbH und Gastwissenschaftler im Bereich Quality Intelligence – Technology Transfer am Lehrstuhl für Fertigungsmesstechnik und Qualitätsmanagement des WZL Werkzeugmaschinenlabor der RWTH Aachen University.

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

KONTAKT

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