




Methoden der Künstlichen Intelligenz (KI) unterstützen Gießereien, Ausschuss proaktiv zu minimieren.

Nutzung von Laufzeitdaten

Proof of Concept für die automatisierte Gussfehlerprognose

Die Qualität von Gussteilen hängt von einer Vielzahl an Einflussparametern ab, die sich zudem häufig gegenseitig beeinflussen, sodass kleinste Einzelabweichungen in der Summe zu erheblichen Einbußen führen können. Über die Echtzeiterfassung und -auswertung der wichtigsten Prozessdaten sollen Abweichungen direkt erkannt und reguliert werden.


VON DANIEL BEGERT, SIMONA BURRI,
MARKUS KRACK, FABIAN HAAG

Ein Dauerthema in fast jeder Gießerei ist die "Reduktion von Schlechteilen" durch Verbesserung der Prozessstabilität. Oftmals stehen dabei die verschiedenen Einflussparameter eng in Wechselwirkungen zueinander, sodass auch jeweils kleine Schwankungen zu signifikanten Abweichungen in der Guss-

teilqualität führen können. Im beschriebenen Forschungsprojekt zwischen der Fachhochschule Nordwestschweiz und der Georg Fischer JRG AG (GF JRG) wurden die wichtigsten Parameter des Gießprozesses erfasst und mittels Algorithmen in Echtzeit ausgewertet. Ziel war es, Abweichungen schon während des Gießprozesses zu erkennen und Maßnahmen zur Prozessstabilisierung sofort einzuleiten.

Prozessdatenerfassung in der Gießerei

Die in der Gießerei von GF JRG installierten Produktionsanlagen inkl. Schmelz- und Gießöfen sind mit modernen Steuerungen ausgestattet, die über eine bereits gute Prozessdatenerfassung verfügen. Diese sind jedoch dezentral in den jeweiligen Anlagensteuerungen abgelegt und nicht miteinander verknüpft. Kommt es



zu Abweichungen in der Gussteilqualität, wird dies in der Regel erst nach dem Gießprozess bemerkt. Die Verantwortlichen müssen dann aufgrund der vorhandenen Prozessdaten die Fehlerursache eruieren. Dies ist ein zeitraubender und aufwendiger Prozess, der zwar die Fehlerursache klärt, den Prozess aber nicht stabilisiert oder gar den Gussfehler rückgängig macht.

Eine weitere Herausforderung ist die Rückverfolgbarkeit der einzelnen Chargen. Das Qualitätsmanagement erfolgt vor der Nachbearbeitung der Teile, wobei die Teile manuell aussortiert und die Fehlerarten bestimmt werden. Die Anzahl der Ausschussteile pro Fehlerart und Auftrag wird am Ende des Prozesses erfasst und ebenfalls in einer Datenbank hinterlegt. Dadurch stehen sowohl die Prozessparameter als auch die Ausschusszahlen pro Fehlerart und Auftrag zur Verfügung. Eine Zuordnung der einzelnen Gussteile zum jeweiligen Gießvorgang ist jedoch nur sehr schwer möglich. Um hier Verbesserungen zu erreichen, wurde ein System gesucht, bei dem man Abweichungen von Parametern bereits während des Gießprozesses erkennen und frühzeitig Maßnahmen ergreifen kann, um Ausschuss zu vermeiden. Ebenso mussten Überlegungen zur Verknüpfung der Prozess- mit Auftrags- und Qualitätsdaten erfolgen, was sich als eine sehr große Aufgabe herausstellte.




Bild 2: Korrelationsmatrix: Korrelation der Features gegenüber der Zielvariablen.

Aufgrund dieser Ausgangslage wurde beschlossen, ein Proof of Concept durchzuführen, mit der Zielsetzung, die Daten der verschiedenen Produktionssysteme in der Gießerei zusammenzuführen, diese in Echtzeit zu visualisieren sowie mittels Algorithmen auszuwerten, um mögliche Gussfehler schon während der Produktion zu erkennen.

Vorgehenssystematik

Gussteilauswahl für das Proof of Concept

Für die Untersuchung wurde mit dem Gussteil Dosenbogen bewusst ein häufig produziertes Teil (high runner) ausgewählt, da hierfür zahlreiche Daten verfügbar sind, die eine fundierte Analyse

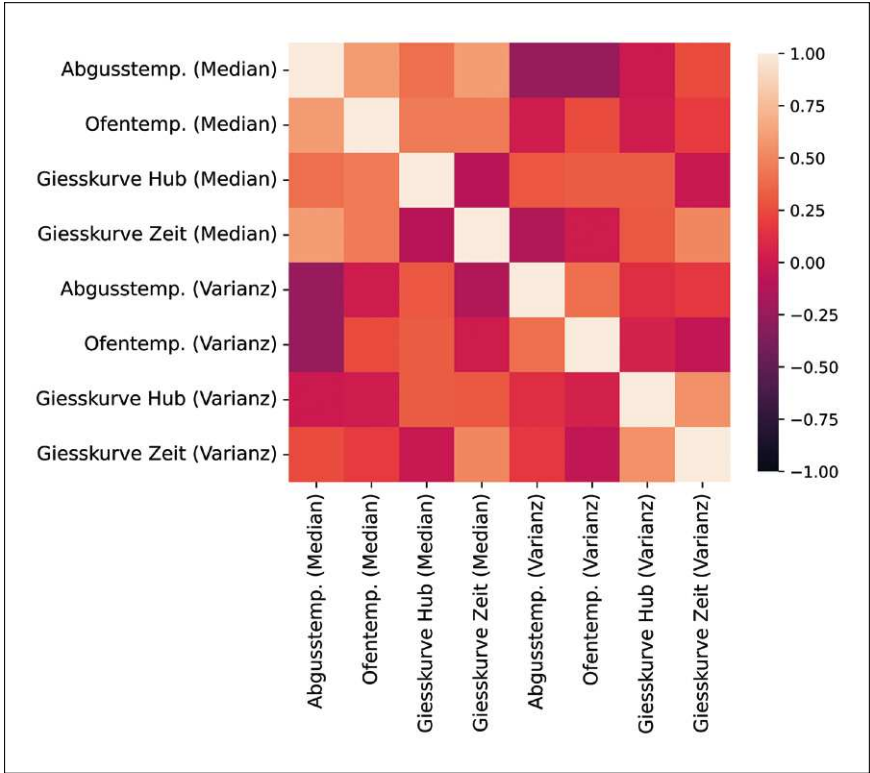


Bild 3: Korrelationsmatrix, Beziehungen der Features untereinander.

Tabelle 1: Klassifizierungsregeln der verschiedenen Features		
Klassifizierung	Name	Wert
1	sehr gut	Ausschuss < 2%
2	gut	Ausschuss 2% - 4%
3	mittel	Ausschuss 4% - 8%
4	schlecht	Ausschuss < 8% - 12%
5	sehr schlecht	Ausschuss > 12%




Bild 4: Vergleich der Klassifikatoren.

ermöglichen. Um die Untersuchung gezielt zu gestalten, wurde festgelegt, welche speziellen Fehlerarten betrachtet werden sollen. Diese sind Kaltlauf, Rauheit und Penetration sowie Makroporosität, wobei sich die nachfolgenden Ausführungen in dieser Publikation auf die Fehlerart Kaltlauf beziehen. Ein wesent-

licher Bestandteil zu Beginn des Projekts war es, die zu analysierenden Fehlerarten so zu beschreiben, dass das Verständnis für die Einflussparameter geschaffen wurde.

Die bewusste Wahl der zu analysierenden Fehlerarten ist entscheidend, um eine präzise Klassifizierung zu erreichen.

Denn ein wesentlicher Bestandteil der Untersuchung ist die physikalische Beschreibung der Fehlerarten, um die Qualität und Zuverlässigkeit der produzierten Gussteile nachhaltig zu verbessern.

Erfassung der Datenentstehungspunkte

Grundlage für Smart Factory-Anwendungen ist eine solide Datenbasis. Im Vorfeld wurden bereits zahlreiche Daten gesammelt und in verschiedenen Datenbanken abgelegt. Mithilfe von Interviews und Auszügen aus den Datenbanken wurden ca. 120 verknüpfbare Parameter identifiziert. Jedem Parameter wurden eine Einheit und ein Datentyp zugeordnet. Um geeignete Änderungen am System vorschlagen zu können, muss zunächst ein umfassendes Systemverständnis erreicht werden. Hierfür wurde eine Prozesslandkarte auf Basis des Materialflusses erstellt. Dabei wurde sowohl der Weg der Schmelze als auch der des Formsandes nachgezeichnet. Diese Karte wird dann durch den Datenfluss und die entsprechenden Datensenzen ergänzt.

Die beziehbaren Parameter sind ihren Entstehungspunkten zugeordnet, wobei Parameter mit gleichen Entstehungspunkten und Informationswegen zu Datenpaketen zusammengefasst wurden. Diese Datenpakete wurden den Verbindungen zwischen den Anlagen und den verschiedenen Datensenzen zugeordnet. Des Weiteren werden Daten von den Datensenzen in das System übertragen, auch dieser Datentransfer wurde erfasst und visualisiert. Das Ergebnis dieses Schrittes ist eine Darstellung, in der jeder Parameter auf seinen Entstehungspunkt und seinen Weg durch die Informationssysteme zurückverfolgt werden kann.

Bildung von mathematischen Modellen und Verknüpfung der Daten

Auf Grundlage der physikalischen Gesetzmäßigkeiten der Gießereitechnik und Metallurgie wurden mathematische Modelle zu den zuvor genannten Gussfehlern erstellt. Diese Modelle zeigen die für die Fehlererkennung relevanten Parameter auf. Anhand der geschaffenen Systemlandschaft mit den Daten- und Informationsflüssen wurden die Entstehungspunkte im System evaluiert. Dadurch konnte analysiert werden, welche Daten für ein erfolgreiches System zusammengeführt werden müssen.

Für die betrachteten Gussfehler sind Daten aus der Sandaufbereitung, dem Schmelzofen, dem Gießofen und dem eigentlichen Gießvorgang relevant. Eine besondere Schwierigkeit bei der Modellie-

rung ist das Zusammenführen der Sand- und Gießdaten. Gründe hierfür sind die unterschiedlichen Chargengrößen in den Prozessen, der Zeitpunkt der Ermittlung der Sanddaten und das Fließverhalten des Sandes im Silo (Bild 1). Um die Gießdaten mit dem erkannten Austausch zu verknüpfen, werden in der Produktion den Gießparametern und der Ausschusserkennung eindeutige Chargen zugeordnet. So aufbereitet, sind die Daten bereit für die weitere Sichtung.

Systemaufbau und Entwicklung der Algorithmen zur Auswertung

Datensichtung

Um die mathematischen Modelle zu verbessern, wurden sie mittels maschinellem Lernen (Machine Learning) trainiert. Ein wesentlicher Schritt in der hierfür notwendigen Datenvorverarbeitung ist die gründliche Sichtung und Analyse der Rohdaten. Hierzu wurde ein spezielles Datensichtungstool entwickelt, das die interessanten Prozessdaten und Einflussparameter pro Gussfehler detailliert visualisiert, um ein besseres Verständnis der zugrundeliegenden Daten zu erlangen. Ausreißer und andere signifikante Ergebnisse werden effizienter erkannt, was ent-




Bild 5: Güte der Klassifikatoren.

scheidend ist, um die Datenqualität zu verbessern und die Daten für die nachfolgenden Schritte der Datenvorverarbeitung vorzubereiten.

Auf Grundlage dieser Erkenntnisse wurde die Datenvorverarbeitung implementiert. Darin werden Ausreißer gefiltert und alle Aufträge mit kleineren Stückzah-



InCeight
Casting C⁸



Secure your participation at the interdisciplinary congress for high-performance cast components.

March 5 to 6, 2025 at the COREUM
Stockstadt (Rhine), Germany

Visit our website for program information and
register now for the InCeight Casting C⁸ →

www.inceight-casting.com



len für das Trainingsdatenset vernachlässigt, da der relative Ausschuss ansonsten das Bild verzerren würde.

Feature Engineering und bestimmen der Klassifizierung

Feature Engineering ist ein entscheidender Schritt im maschinellen Lernen und der Datenvorverarbeitung. Es umfasst die Erstellung, Auswahl und Transformation von Datenmerkmalen (Features), um die Leistung eines Modells zu verbessern. Eine der größten Herausforderungen im Feature Engineering besteht darin, dass Prozessdaten nicht direkt mit der Klassifizierung in Verbindung gebracht werden können.

In diesem konkreten Fall kann anhand der Prozessdaten nicht direkt auf den Ausschuss geschlossen werden. Dies ist dadurch bedingt, dass die Prozessdaten keine direkte Verbindung zu der Klassifizierung "gut / schlecht" haben. Es müssen entsprechend Features generiert werden, die möglichst gut mit dem Ausschuss korrelieren. Dies bedeutet, dass die Daten als Gesamtheit zu betrachten sind, um aussagekräftige Merkmale zu extrahieren.

Neue Features werden auf Grundlage der physikalischen Beschreibung der Fehlerarten geschaffen. Beispielsweise kann die Gießtemperatur, die einen großen Einfluss auf die Fehlerarten Kaltlauf hat, als relevantes Feature genutzt werden. Mit Hilfe statistischer Eigenschaften werden aus den Temperaturdaten pro Auftrag Median und Varianz berechnet. Die Median-Temperatur gibt einen Anhaltspunkt darüber, ob die Gießtemperatur im gewünschten Bereich ist, ohne Verfälschung durch Ausreißer. Die Varianz ist ein Maß der Streuung und gibt einen Anhaltspunkt über Temperaturschwankungen. Beide statistischen Werte können für die Gesamtheit aller erfassten Parameter berechnet werden und sind geeignet, um mit diesen als neue Features zu arbeiten. Um nicht zu viele Features zu berücksichtigen, können sie gegeneinander geprüft und in Korrelationsmatrizen dargestellt werden.

Bild 2 zeigt die Korrelation der Features gegenüber der Zielvariablen Ausschuss in einer Korrelationsmatrix. Es ist zu sehen, dass keine direkte starke lineare Beziehung besteht (Werte < 0,8). Das deutet darauf hin, dass der Einfluss der beschriebenen Parameter nicht linear ist. Diese Erkenntnis ist für die Wahl des Klassifikators entscheidend. In der Korrelationsmatrix der verschiedenen Features untereinander (Bild 3) können deren Beziehungen betrachtet und redundante

Features für die Klassifikation ausgeschlossen werden. Wie zu erwarten, korrelieren beispielsweise die Gieß- und die Ofentemperatur sehr stark. Für den Algorithmus kann also die Ofentemperatur vernachlässigt werden. Für die Klassifizierung soll nach Tabelle 1 unterschieden werden.

Wahl des Klassifikators

Mit den neu geschaffenen Features sollte der beste Klassifikator für die Anwendung ermittelt werden. Zur Bewertung der Leistungsfähigkeit der verschiedenen Klassifikatoren wurden die Daten in Trainings- und Testdatensätze aufgeteilt, wobei die Methode der k-fachen Kreuzvalidierung zum Einsatz kam, die die Daten in k gleiche Teile unterteilt. Jeder Klassifikator durchlief k Trainings- und Testphasen, wobei jedes Mal ein anderer Teil der Daten als Testdatensatz diente und die restlichen Teile für das Training genutzt wurden. Der quadratische Mittelwert des Fehlers (RMSE) wurde berechnet, um die Differenz zwischen den vorhergesagten und tatsächlichen Werten zu quantifizieren. Zur Visualisierung der Verteilung der Fehlerwerte für jeden Klassifikator sind die RMSE-Werte im Boxplot (Bild 4) dargestellt. Diese Analyse zeigt, dass der Klassifikator Decision Tree die besten Ergebnisse liefert. Seine Güte wird in der Konfusionsmatrix (Bild 5) dargestellt, die die Anzahl der korrekt und falsch klassifizierten Instanzen im Vergleich zu ihren tatsächlichen Klassen zeigt.

Validierung und Nutzung

Resultate des Proof of Concept

Das bei der Georg Fischer JRG AG durchgeführte Proof of Concept hat das Potenzial der Nutzung von Verdichten und Verknüpfen von Echtzeitdaten mittels Algorithmen und Machine Learning sehr gut

Industriepartner Georg Fischer JRG AG

Das Unternehmen mit Sitz in Sissach in der Schweiz ist spezialisiert auf die Produktion von hochwertigen Trinkwasser- und Armaturensystemen. Die Produktion mit einer hohen Fertigungstiefe umfasst neben der mechanischen Bearbeitung und Montage eine moderne Sandgießerei. In dieser werden aus Rotgusslegierungen Armaturen- und Verrohrungsteile verschiedenster Art gegossen.

www.gfps.com/jrg

aufgezeigt. Die durchgeführten Arbeiten sorgten dafür, dass Dateninseln konsolidiert wurden. Aus diesem untersten Level der Smart Factory Maturität "Monitoring von Daten" konnte für die Verantwortlichen ein großer Nutzen im Bereich der Fehlererkennung und Prozessüberwachung erkannt werden.

Weiterentwicklung zu einem Digitalen Zwilling

Auf Basis des jetzigen Standes des Proof of Concept könnte die Weiterentwicklung in Richtung eines Digitalen Zwillings der logische nächste Schritt sein. Ein Digitaler Zwilling stellt eine virtuelle Repräsentanz eines physischen Objektes dar. Beide sind miteinander verbunden und tauschen in Echtzeit bidirektional Daten / Informationen aus. Daten die vom realen Objekt, z.B. dem Schmelzofen geliefert werden, werden im Digitalen Zwilling mittels Algorithmen und Künstlicher Intelligenz zu Entscheidungen verarbeitet und das reale Objekt entsprechend beeinflusst. Hierfür müssten jedoch weitere Parameter und Fehlerarten in das System aufgenommen und entsprechende Versuche zum Trainieren der Machine Learning-Modelle durchgeführt werden. Auch die bidirektionale Anbindung von Anlagensteuerungen an den Digitalen Zwilling dürften noch einiges an Arbeit erfordern.

Die Rolle der Menschen in der digitalen Welt

Bei letzteren Ausführungen zum Thema Digitaler Zwilling, wie auch beim durchgeführten Einsatz von Machine Learning-Technologien im Rahmen des Projekts, war bei einigen Mitarbeitenden bereits eine gewisse Zurückhaltung zu spüren. Ängste, dass Algorithmen nun ihr Fachwissen übernehmen und direkt den Anlagen weitergeben, waren vorhanden.

Die Digitale Welt ist ohne Menschen und sein Fachwissen nicht möglich! Nur die Rolle des Menschen hat eine neue Bedeutung. Sie verschiebt sich vom Macher zum Gestalter. Aus dieser Warte sehen wir die Entwicklung als positiv und nutzen die Unterstützung der digitalen Welt auch in traditionellen Industrien, wie den Gießereien.

www.fhnw.ch/technik,
www.gfps.com

Daniel Begert, Simona Burri, Prof. Markus C. Krack, Fachhochschule Nordwestschweiz, Hochschule für Technik und Umwelt, Windisch, Schweiz, Dr. Fabian Haag, Leiter Gießerei, Georg Fischer JRG AG, Sissach, Schweiz.