

Ausschussreduktion durch Kombination von Daten aus dem Gießprozess und der automatischen Röntgenprüfung

Thomas STOCKER¹, Julius MEHRINGER², Frechen HENNING², Frank SUKOWSKI¹, Felix SCHÄFER³, Dennis FREIER³, Christian SCHUSTER¹

¹ Fraunhofer-Entwicklungszentrum Röntgentechnik EZRT, Fürth

² Arbeitsgruppe für Supply Chain Services des Fraunhofer-Instituts für Integrierte Schaltungen IIS, Nürnberg

³ RONAL GROUP, Forst

Kontakt-E-Mail: thomas.stocker@iis.fraunhofer.de

Kurzfassung. Die automatische Röntgenprüfung von Gussteilen ist bei sicherheitsrelevanten Teilen oder Teilen mit hohen Qualitätsanforderungen weit verbreitet. Automatisch bedeutet hierbei, dass sowohl die Bildaufnahme als auch die Auswertung der Bilder vollautomatisch erfolgt. Heute werden in den meisten industriellen Anwendungen die erzeugten Daten, die eine Größe von bis zu mehreren Gigabyte pro Teil haben können, auf eine einfache Gut- oder Schlecht-Entscheidung reduziert. Alle anderen Informationen in den Daten werden verworfen, obwohl diese wertvoll sein können, um Produktionsprozesse zu optimieren und damit den Ausschuss zu reduzieren.

Dieser Beitrag gibt einen Überblick über die Ergebnisse des Projekts Cast Control, eine Zusammenarbeit des Fraunhofer-Entwicklungszentrums Röntgentechnik EZRT, der Arbeitsgruppe für Supply Chain Services (SCS) des Fraunhofer-Instituts für Integrierte Schaltungen IIS und des Industriepartners RONAL GROUP. Die RONAL GROUP ist ein großer Hersteller von Aluminiumrädern, hauptsächlich für den OEM-Markt. Im Rahmen des Projekts kombinierten wir Serienproduktionsdaten aus dem Niederdruckgussverfahren einer Gießerei der RONAL GROUP mit den Daten aus der automatischen Röntgenprüfung. Auf einer umfangreichen Basis von Beispieldaten aus der realen Produktion, konnten wir ein neuronales Netz trainieren, das Gießfehler, die später bei der Röntgenprüfung detektiert werden, vorhersagen kann. Die Visualisierung der erlernten Zusammenhänge des neuronalen Netzes zwischen den Prozessdaten der Gießmaschinen und den Qualitätsdaten aus der Röntgenprüfung, ermöglicht es Handlungsempfehlungen für eine Prozessoptimierung abzuleiten.

Mit diesen Informationen ist es möglich, den Gießprozess in einem frühen Stadium anzupassen - noch bevor Ausschuss entsteht. Dadurch kann die Gießerei ihre Ausschussrate reduzieren, was Kosten und Energie spart und zu einer besseren Wettbewerbsfähigkeit führt.

Einführung

Die Senkung der Personalkosten durch die Verringerung des Aufwandes den Produktionsprozess zu überwachen ist besonders in Europa notwendig. Darüber hinaus machen es die stark gestiegenen Energie- und Rohstoffpreise in Verbindung mit dem Ziel



einer klimaneutralen Produktion erforderlich, den Energieverbrauch für die Produktion so weit wie möglich zu reduzieren. Das Projekt Cast Control leistet einen direkten, bedeutenden Beitrag zu der letztgenannten Herausforderung und einen indirekten Beitrag zu der erstgenannten. Bei der Produktion von Leichtmetallrädern liegen die prozessbedingten Ausschussraten derzeit im einstelligen Prozentbereich. Ausschuss bedeutet immer einen höheren Energieverbrauch und zusätzliche Kosten. Die Ausschussquote konnte in den letzten Jahren durch verschiedene Maßnahmen stetig gesenkt werden. Eine weitere Verbesserung mit herkömmlichen Methoden wird jedoch immer schwieriger.

Das Projekt Cast Control zielt darauf ab, den Ausschuss bei der Produktion von Leichtmetallrädern weiter zu reduzieren, indem Daten aus der Gießerei mit Daten aus der Röntgenprüfung kombiniert werden. Dazu wenden wir eine Kombination aus Layer-wise relevance propagation und Dimensionalitätsreduktion an, um Korrelationen zwischen den beiden Datenquellen zu finden.

In Zukunft planen wir, unser Verfahren an andere Gießereiprodukte und andere Produktionsmethoden anzupassen.

1. Datengenerierung

1.1 Sensoraufzeichnungen des Gießvorgangs

Für jedes gegossene Rad erhalten wir Messdaten von 20 verschiedenen Standardsensoren, die in die Gießmaschinen integriert sind, mit einer zeitlichen Auflösung von einem Datenpunkt pro Sekunde. Zu den Aufzeichnungen gehören die Temperatur der geschmolzenen Legierung, der während der Formfüllung aufgezeichnete Druck und einige Messdatenreihen des Luftstroms der Kühlungen, die während der Abkühlphase an verschiedenen Stellen der Form aufgenommen wurden. Abbildung 1 zeigt als Beispiel die Werte einer Teilmenge der Sensoraufzeichnungen während eines einzelnen Gießvorgangs.

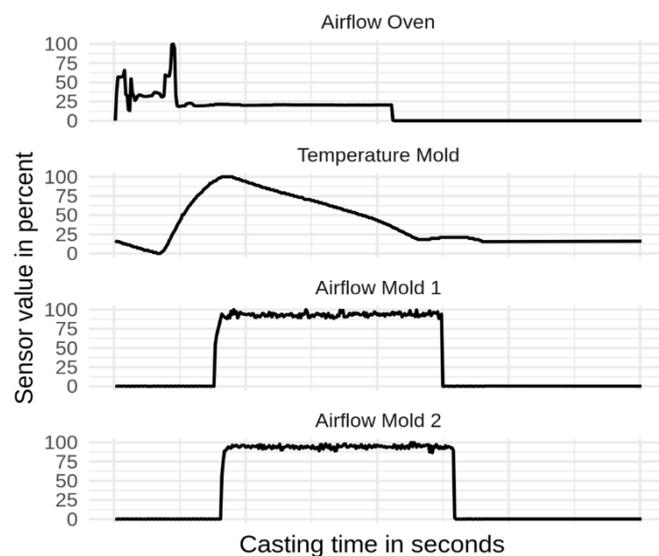


Abb. 1. Typische Sensoraufzeichnungen aus einem Gießprozess

1.2 Ergebnisse der Röntgenprüfung

Zusätzlich zu den Messungen, die während des Gießprozesses durchgeführt werden, verwenden wir die Ergebnisse der Röntgenprüfung, die jedes Rad nach dem Gießprozess durchläuft. Ein System für die Röntgenprüfung von Leichtmetallrädern ist das Intelligente

System zur automatischen Röntgenprüfung (ISAR), das vom Fraunhofer EZRT entwickelt und gepflegt wird. Jeder Röntgenprüfvorgang liefert eine Vielzahl von Ergebnisdaten, Fehlerbeschreibungen und eine endgültige Entscheidung darüber, ob das Rad ausgesondert werden soll oder nicht.

Es wird eine punktbiseriale Korrelationsanalyse durchgeführt, um diejenigen Röntgenfehlermerkmale auszuwählen, die die höchste Korrelation mit der endgültigen IO/NIO-Entscheidung aufweisen. In unserem Datensatz ist dies die Fläche des größten Defekts in Quadratmillimetern (bezeichnet als max_A_sqmm).

1.3 Beschreibung und Bearbeitung des Datensatzes

Wir bereinigen den Datensatz im Hinblick auf Sensorwerte, die wahrscheinlich fehlerhaft sind und lassen selten verwendete Radformen weg, so dass der endgültige Datensatz 16262 eindeutige Einträge enthält. Jeder Eintrag ist durch eine eindeutige Identifikationsnummer gekennzeichnet, um Sensordaten und Röntgendaten miteinander zu verknüpfen. Die 20 Sensordatenreihen aus den Produktionsprozessen dienen als Eingaben in das Modell. Auf der Ausgabeseite verwenden wir die Fläche des größten Defekts max_A_sqmm , wie oben erläutert, die als Ziel für unsere Machine-Learning-Modelle fungiert.

Wenn in einem Rad kein Defekt festgestellt wird, setzen wir den Zielwert auf null. Als zusätzlichen Vorverarbeitungsschritt, um das Lernen des Modells zu erleichtern, standardisieren wir die Originaldaten, indem wir den Mittelwert abziehen und die Varianz auf Eins skalieren. Außerdem verwenden wir eine logarithmische Transformation der Zieldaten, um den Trainingsprozess zu erleichtern.

2. Methodik

Neuronale Netze eignen sich als universelle Funktionsapproximatoren [1] besonders gut für die vorliegende Vorhersageaufgabe. Um die von einem neuronalen Netzwerk gelernten Repräsentationen zu überprüfen, wurden Methoden zu deren Interpretation entwickelt. Eine weitverbreitete Möglichkeit, um die Eingaben zu erkennen, auf deren Basis ein neuronales Netzwerk seine Entscheidungen trifft, ist die Layer-wise relevance propagation, (LRP). Diese wird z. B. in den Klimawissenschaften [2] benutzt. Da unser Ziel darin besteht, Empfehlungen für die Einstellungen von Gießmaschinen abzuleiten, ist ein sehr gutes Verständnis der Repräsentationen des neuronalen Netzwerks entscheidend. Daher werden wir die LRP verwenden, um das neuronale Netzwerk zu untersuchen und zu verstehen, welche Eingaben für die Entscheidung am wichtigsten sind, und die LRP verwenden, um visuelle Erklärungen zu erstellen. Schließlich werden wir die Erklärungen von der LRP mit einer Sensitivitätsanalyse vergleichen, bei der wir die partiellen Ableitungen der Vorhersage eines neuronalen Netzwerks in Bezug auf seine Eingaben berechnen.

Eine Beschreibung der Architektur des neuronalen Netzes, des Modelltrainings, der Hyperparameter-Optimierung und der Post-hoc-Methoden zur Erklärung der Vorhersagen des Netzes finden Sie in [3].

3. Ergebnisse

3.1 Vorhersage-Genauigkeit

Abbildung 2 vergleicht die Vorhersagen unseres Ensemble-Modells mit den echten Zielwerten, die in der Testreihe gefunden wurden. Im linken Teil der Abbildung steht jede Kreuzmarkierung für ein einzelnes Gussrad (oder einen beobachteten Gießprozess) und zeigt

dessen Vorhersagegenauigkeit. Bei einem perfekten Prädiktor würden alle Vorhersagen mit den entsprechenden Zielwerten übereinstimmen, so dass alle Markierungen auf der roten Diagonale liegen würden. Die Abbildung zeigt, dass unser Modell aufgrund der Komplexität der Vorhersageaufgabe kein perfekter Prädiktor ist. Wenn wir uns jedoch die Residuen unserer Vorhersage ansehen, sehen wir, dass sie fast normal verteilt sind, wobei die meisten Werte nahe bei null zentriert sind (rechts). Das bedeutet, dass unser Modell die Gesamtfehlergröße weder über- noch unterschätzt. Zusammenfassend lässt sich sagen, dass das Ensemble-Modell in der Lage ist, Beispiele, die es noch nicht gesehen hat, angemessen vorherzusagen, auch wenn es manchmal versagt, Extremwerte zu erfassen.

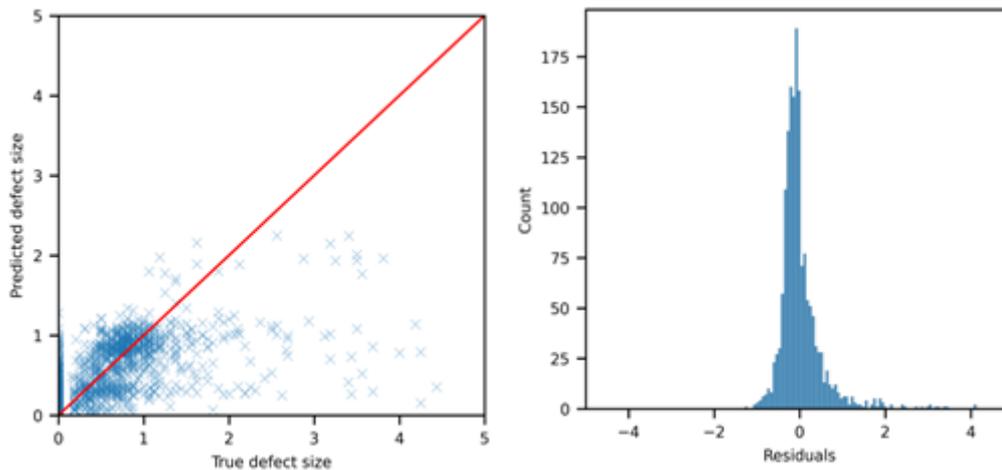


Abb. 2. Verteilung der mittleren quadratischen Abweichung auf dem Testdatensatz

3.2 Post-hoc-Erklärungen

Da wir zuversichtlich sind, dass unser Ensemble-Modell in der Lage ist, die maximale Fehlergröße in einem Rad zufriedenstellend vorherzusagen, können wir die Entscheidungen des Modells post hoc analysieren. Dafür berechnen wir die Sensitivität sowie die LRP-Werte für unser Ensemble-Modell für einen Radtyp (bzw. einer Gießform). Abbildung 3 zeigt Heatmaps für die durchschnittlichen Ergebnisse der Sensitivität (oben) und der LRP (unten). Die erste Dimension (x-Achse) unserer Abbildung stellt die Gießzeit mit einer Auflösung von 1 Sekunde dar. Auf der y-Achse zeigen wir den Namen jedes spezifischen Sensors, der als Input für unser Modell verwendet wird. Die Abkürzungen stehen für: Formtemperatur (TC), Luftstrom im Ofen, Druck und Temperatur (OAF, OP, OT) und Kühlluftstrom (AF1-AF16).

Auf den ersten Blick vermittelt die LRP-Visualisierung ein klareres Bild der Merkmale, die für den Gießprozess wichtig sind. Bereiche, die das Modell für seine Vorhersage als wichtig erachtet, sind stärker hervorgehoben als in der Sensitivitätsdarstellung. Die LRP-Methode selbst wurde jedoch ursprünglich für Klassifizierungsaufgaben, typischerweise von Bildern, entwickelt und ist nicht vollständig auf unsere Regressionsaufgabe anwendbar. Bei Bildklassifizierungsaufgaben gibt uns die LRP die Zuordnung von Teilen des Eingabebildes zu einer bestimmten Klassenbezeichnung als Referenz. In unserem Regressionsfall haben wir keine solche Referenz, was die Interpretation der Ergebnisse erschwert. Das bedeutet, dass der absolute Wert der Zuordnung uns keine Informationen darüber gibt, wie stark wir unsere Eingabe ändern müssten, um eine bestimmte Ausgabe zu erhalten. In unserem Fall können wir ihn als qualitatives Maß verwenden, um festzustellen, welcher Sensor zu welchem Zeitpunkt für die Modellvorhersage von Bedeutung ist, z. B. im Durchschnitt für alle Räder eines bestimmten Designs.

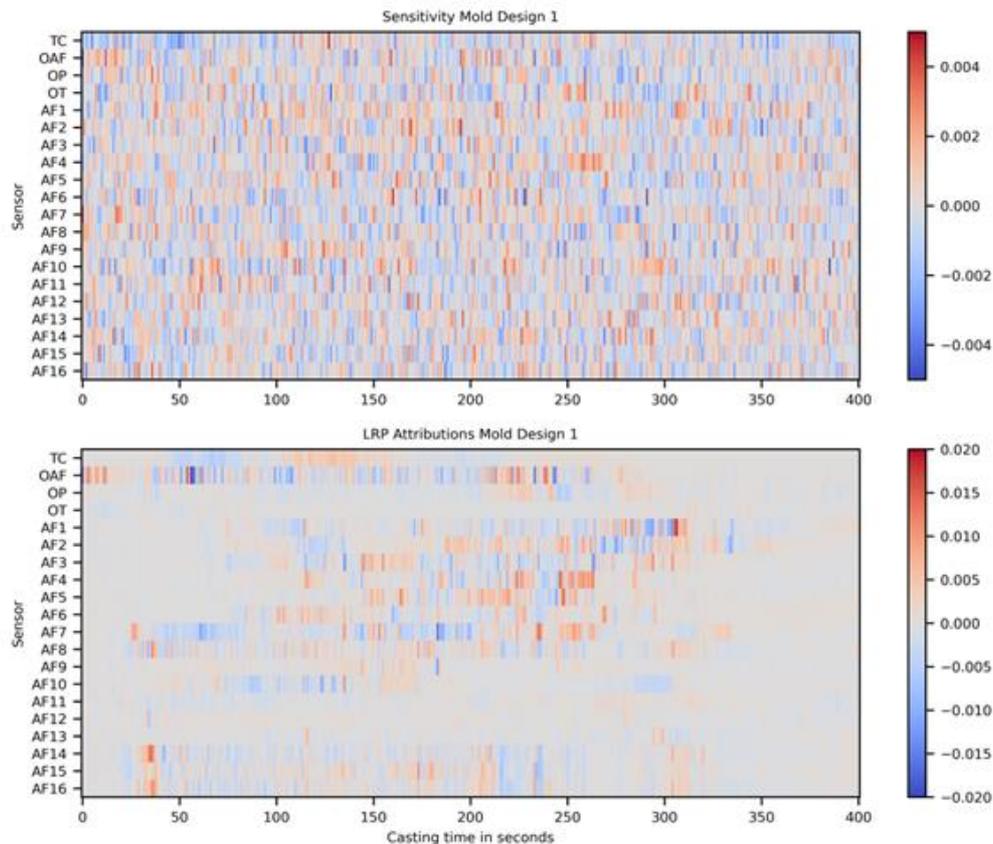


Abb. 3. Mittelwert der Sensitivitäts- (oben) und LRP-Attribute (unten) des Ensembles pro Zeit und Eingabeknoten für eine Gießform

Das Sensitivitätsdiagramm ermöglicht es uns, direkt eine Input-Output-Beziehung abzuleiten und diese als quantitatives Maß zu verwenden. Das heißt, wenn wir einen dunkelblauen Bereich in der Heatmap haben, würde eine Erhöhung dieses spezifischen Sensorwerts zu diesem bestimmten Zeitpunkt dem Modell zufolge zu einem Rückgang der Fehlergröße führen. Umgekehrt würde bei dunkelroten Bereichen eine Erhöhung des Sensorwerts zu einer Zunahme der Defektgröße führen.

Das Sensitivitätsdiagramm ist jedoch sehr verrauscht, und die Änderung der Sensorwerte von einer Sekunde zur anderen ist technisch nicht machbar. Daher glauben wir, dass es besser ist, beide Diagramme zusammen zu betrachten, um die Erklärungen des Modells zu interpretieren. Zum Beispiel sind die ersten ~20 Sekunden der Ofenluftstromreihe (OAF) in der LRP-Zuordnungsgrafik rot gefärbt, was bedeutet, dass dieser Bereich für die Modellentscheidung von Bedeutung zu sein scheint. Gleichzeitig ist auch die Sensitivitätsdarstellung rot gefärbt, was bedeutet, dass wir den Luftstrom zu Beginn des Gießprozesses reduzieren sollten, um die Fehlergröße zu verringern. Die Durchführbarkeit einer solchen Änderung und die Zuverlässigkeit dieser Erklärungsmethode müssen in Zukunft mit Gießereiexperten diskutiert werden.

4. Schlussfolgerungen

Aufgrund der Komplexität einer Produktionsumgebung ist es nach wie vor schwierig, die Auswirkungen mehrerer Sensoraufzeichnungen auf den Erfolg eines Produktionsprozesses abzuschätzen. Es ist möglich, dass es mehrere Effekte gibt, die in den verfügbaren Sensordaten nicht enthalten sind, aber dennoch einen erheblichen Einfluss haben. Zum

Beispiel hatten wir zum Zeitpunkt dieser Arbeit keinen Zugang zu Metadaten wie Umweltdaten in der Gießerei oder der Qualität der Aluminiumlegierung.

Dennoch ist der vorgeschlagene Ansatz eine vielseitige Methode, um alle verfügbaren Sensoraufzeichnungen zu nutzen und so die bestmögliche Abstraktion der Produktionsumgebung mit künstlichen neuronalen Netzen zu konstruieren. Wie wir gezeigt haben, ist das Modell in der Lage, die Größe des größten Fehlers in einem Rad vorherzusagen. Wir sind auch in der Lage, Einschätzungen darüber zu geben, welche Sensorwerte einen Einfluss auf die Größe der Defekte haben. Diese Informationen können zur Optimierung der Produktionsparameter verwendet werden, um den Ausschuss zu reduzieren.

Der nächste Schritt in unserem Projekt ist die Implementierung eines Prototyps, der während der Produktion Empfehlungen in Echtzeit ausspricht.

Referenzen

- [1] K Hornik, M Stinchcombe and H White, “Multilayer feedforward networks are universal approximators.”, *Neural Networks*, Volume 2, Issue 5, pp 359–366, 1989.
- [2] EA Barnes, B Toms, JW Hurrell, I Ebert-Uphoff, C Anderson and D Anderson, “Indicator patterns of forced change learned by an artificial neural network.”, *Journal of Advances in Modeling Earth Systems*, Volume 12, Issue 9, 2020.
- [3] J Mehringer, H Frechen, N Beck, F Sukowski, T Stocker, D Freier and F Schäfer, “Cast Control: AI-based Explanations of Casting Defects Linking Process and Quality Inspection Data”, *Proceedings of the 2nd Congress for intelligent Combining of Design, Casting, Computer Simulation, Checking and Cyclic Behaviour for efficient Cast Components*, 2023.