

INN im Spritzgießen

Vorhersage von Einstellparametern

Zur effizienten Parametrierung von Spritzgießprozessen können invertierbare neuronale Netze (INN) eingesetzt werden, um auf Basis von Qualitätsvorgaben global optimale Maschineneinstellungen zu identifizieren. Hierfür werden praktische Spritzgießversuche durchgeführt, um einen initialen Datensatz bestehend aus Einstellparameterkombinationen und gemessenen Qualitätsgrößen zu generieren. Dieser Datensatz bildet die Grundlage für das Training der INN. Die INN erreichen hohe Prognosegüten und praktische Validierungsversuche bestätigen die hohe Vorhersagegenauigkeit.

KI4KI – AI for the Plastics Industry



Abstract

Die wirtschaftliche Herstellung komplexer Kunststoffbauteile durch Spritzgießen steht zunehmend unter dem Druck wachsender Qualitätsanforderungen bei gleichzeitigem Fachkräftemangel. Um Prozesse unabhängig vom Erfahrungswissen einzustellen, eignen sich Methoden Künstlicher Intelligenz. Während klassische neuronale Netze nur begrenzt zur rückwärtigen Vorhersage nutzbar sind, bieten invertierbare neuronale Netze (INN) einen innovativen Ansatz: Sie ermöglichen die Ableitung möglicher Maschineneinstellungen auf Basis gegebener Qualitätsziele.

Problem

Im Spritzgießen können nahezu beliebig komplexe Formteile wirtschaftlich und in hohen Stückzahlen hergestellt werden. Aufgrund steigender Produkthanforderungen und engerer Toleranzen sind Kunststoffverarbeiter gezwungen, ihre Prozesse zu optimieren. In vielen Unternehmen werden die Prozesseinstellung und -optimierung basierend auf dem Erfahrungswissen langjähriger und erfahrener Mitarbeiter angepasst.

Da viele Unternehmen mit dem Problem des Fachkräftemangels und den stetig steigenden Qualitätsforderungen an die hergestellten Formteile unter Druck stehen, sind sie bestrebt, die Einstellungen für den Spritzgießprozess auch losgelöst vom Erfahrungswissen der Mitarbeiter zu wählen. So eignen sich beispielsweise Künstliche Neuronale Netze (KNN), um den nichtlinearen Charakter des Spritzgießprozesses abzubilden und die Qualitätsgrößen der hergestellten Formteile in Abhängigkeit der

Maschineneinstellungen vorherzusagen.

Während die Vorhersage der Qualitätsgrößen in Abhängigkeit der Einstellparameter leicht umgesetzt werden kann, stellt die umgekehrte Vorhersage der Einstellparameterkombinationen für vorgegebene Qualitätswerte eine Herausforderung dar, die klassische Feed Forward KNN aufgrund deren Architektur nicht bewältigen können. Zur Ermittlung geeigneter Einstellwerte werden daher üblicherweise evolutionäre Algorithmen wie genetische oder Partikelschwarm-Optimierungsalgorithmen verwendet. Mit diesen zweistufigen Modellen können jedoch nur einzelne und diskrete lokale Lösungen für bestimmte Qualitätsparameter gefunden werden. Eine vollständige Auswertung aller möglichen Lösungen ist nicht möglich. Als alternative Herangehensweise zur Vorhersage sämtlicher möglicher Maschineneinstellungen für vorgegebene Qualitätsparameter bieten sich Invertierbare Neuronale Netze (INN) an.

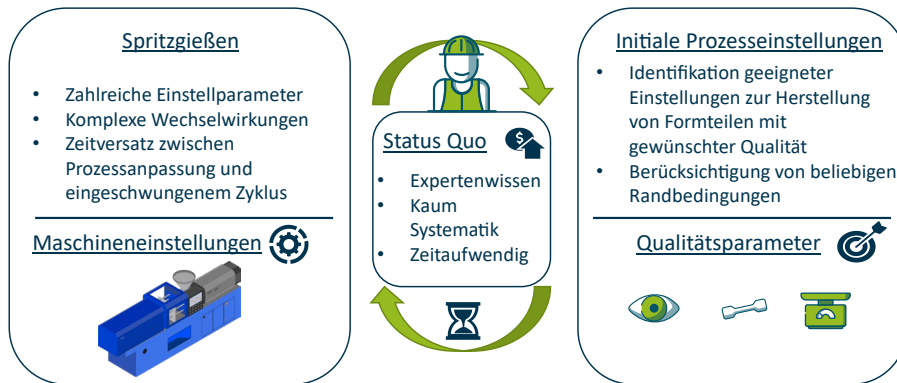


Abb. 1: Der Einrichtprozess im Spritzgießen zur Identifikation der initialen Prozesseinstellungen ist ein komplexer Prozess aufgrund der Vielzahl der möglichen Kombinationen und basiert auf dem Wissen von erfahrenem Personal.

Lösung

INN ermöglichen es, aus bekannten Ergebnissen wie den gemessenen Qualitätsmerkmalen eines Bauteils die möglichen Maschineneinstellungen zu berechnen, die zu diesen Ergebnissen führen können. Dazu wird eine sogenannte bijektive Abbildung trainiert. Jeder Punkt im Eingaberaum (z. B. Maschineneinstellungen) wird eindeutig einem Punkt im Ergebnisraum (z. B. Bauteilgewicht und -maße) zugeordnet. Bijektive Abbildungen setzen jedoch voraus, dass sowohl die Anzahl der variierten Maschineneinstellungen als auch die Anzahl der vorherzusagenden Qualitätsmerkmale identisch sind. Ist dies nicht der Fall, können keine eindeutigen Schlüsse für die Vorhersage von Einstellparametern aus der Vorgabe definierter Qualitätsparameter gezogen werden.

Um dieser Problematik zu begegnen, werden die Parameterräume bei INN durch sogenannte latente Parameter erweitert, um auf beiden Seiten des Modells die gleiche Anzahl an Größen vorliegen zu haben. Da diese latenten Parameter nicht direkt

gemessen werden können, werden diese für das Modelltraining aus statistischen Verteilungen ermittelt.

Der Vorteil dieser Methode liegt darin, dass neben den konkreten Lösungen auch die gesamte Verteilung möglicher Einstellungen sichtbar wird. Dadurch können Unsicherheiten quantifiziert und alternative Einstellparameterkombinationen identifiziert werden, die bei herkömmlichen Verfahren oft verborgen bleiben.




Abb. 2: Während das Formteilgewicht für beliebige Kombinationen aus Nachdruckhöhe und Nachdruckzeit vorhergesagt werden kann, existieren für die Vorgabe eines Formteilgewichts beliebig viele Kombinationen aus Nachdruckzeit und Nachdruckhöhe, die zu diesem Ergebnis führen. Für eine eindeutige Vorhersage ist es erforderlich, die Qualitätsparameter, um einen latenten Parameter zu erweitern.

Use Case am IKV

Am IKV konnte die Eignung der INN zur zuverlässigen Vorhersage von Maschineneinstellparametern erfolgreich nachgewiesen

werden. Da INN darauf ausgelegt sind, komplexe Zusammenhänge zwischen unterschiedlichen Verteilungen der Eingabe- und Zielparameter zu erlernen, ist eine umfangreiche Datengrundlage notwendig, um eine robuste Modellbildung zu ermöglichen.

Allerdings ist die Erzeugung von großen Datensätzen im Spritzgießen mit mehr als 1000 Versuchspunkten zeitaufwendig und unwirtschaftlich, weshalb auf der Grundlage eines kleineren experimentellen Datensatzes zunächst KNN trainiert werden, die dann zur Erstellung eines größeren

synthetischen Datensatzes von 100.000 Kombinationen aus Einstellparameterkombinationen und prognostiziertem Formteilgewicht für das Training der INN genutzt werden. Für die praktischen Versuche werden als Einstellparameter die Einspritzgeschwindigkeit, die Nachdruckhöhe, die Nachdruckzeit, die Schmelze- sowie Werkzeugtemperatur und Restkühlzeit variiert. Als Qualitätsparameter wird das Formteilgewicht ermittelt. Für die Untersuchungen wird das Formteil des komplexen Kästchens als Use-Case untersucht.




Abb. 3: Zur Generierung der Daten für das Training der INN werden zunächst KNN für die Vorhersage des Formteilgewichts in Abhängigkeit der Einstellparameterkombinationen trainiert. Über diese Modelle können dann beliebig komplexe und große Datensätze für das Training der INN generiert werden.

Vorhersage von Einstellparametern

Zur Validierung der hier vorgestellten Methodik werden für vorgegebene Zielwerte für das Formteilgewicht mögliche Kombinationen der Maschineneinstellungen mit dem INN prognostiziert und in weiteren praktischen Versuchen validiert.

Als Zielgewichte für die Validierungsversuche werden 52,8 g; 54,0 g; 55,5 g; 57,0 g und 58,6 g gewählt. 55,5 g stellt den Mittelwert des für den Trainingsdatensatz

verwendeten DoE-Plans dar, während 52,8 g und 58,6 g in der Nähe der minimalen und maximalen Probengewichte von 52,67 g bzw. 58,69 g liegen. Die maximalen und minimalen Probengewichte sind für die Vorhersage von Maschineneinstellparametern nicht geeignet, da die daraus resultierenden Vorschläge fast ausschließlich außerhalb des ursprünglichen Einstellparameterbereichs und somit außerhalb der DoE-Grenzen liegen.

Diese Vorhersagen liegen jedoch nicht innerhalb des validen Vorhersagebereichs der

INN, da diese ähnlich wie KNN nicht für die Extrapolation außerhalb der Trainingsdatenräume eingesetzt werden sollten. Für jedes der Zielgewichte mit Ausnahme von 58,6 g und 52,8 g werden fünf Maschineneinstellparameterkombinationen berechnet und validiert. Für die Vorhersage der Einstellparameter, die ein minimales Bauteilgewicht von 52,8 g beziehungsweise ein maximales Bauteilgewicht von 58,6 g ermöglichen, unterscheiden sich die prognostizierten Parameter nur geringfügig voneinander.

Die Standardabweichung des Formteilgewichts für die identifizierten Einstellungen mit dem Zielwert 55,5 g ist mit 0,04 g am geringsten. Bei der Betrachtung von allen untersuchten Einstellparameterkombinationen und den resultierenden Formteilgewichten divergieren die erzielten Gewichte im Mittel um lediglich 0,24 % (0,09 g). Hierdurch kann die Anwendbarkeit der INN für die direkte Vorhersage der Einstellparameter für beliebige Vorgaben des Zielgewichts eindrucksvoll demonstriert werden.

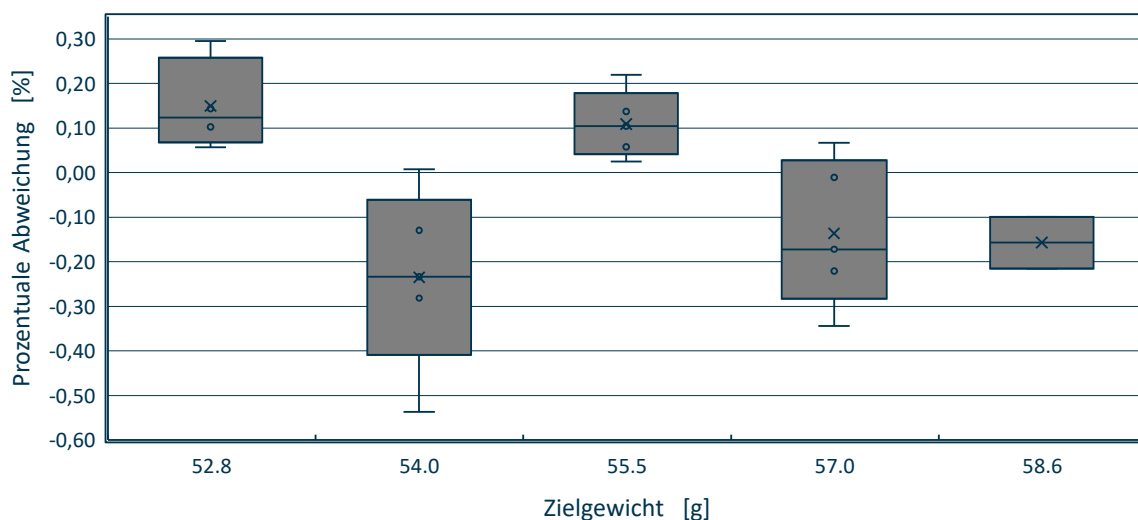


Abb. 4 Boxplot-Diagramme der prozentualen Abweichungen zwischen dem erzielten Gewicht der mit den INN identifizierten Einstellparameter nach den praktischen Validierungsversuchen und der Zielvorhabe.

Zusammenfassung

INN ermöglichen die effiziente Generierung zahlloser Maschineneinstellparameter auf Basis vorgegebener Qualitätsmerkmale in sehr kurzer Zeit. Im dargestellten Anwendungsbeispiel lassen sich für verschiedene Vorgaben der zu erzielenden Formteilgewichte zahlreiche Kombinationen der Maschineneinstellungen ableiten, die die Zielvorgaben auch in den praktischen

Validierungsversuchen erfüllen. Neben der Vorhersage einzelner Einstellparameterkombinationen bieten INN jedoch auch darüber hinaus großes Potential. So lassen sich beispielsweise gezielt die Einflüsse der einzelnen Einstellparameter für den Anwender oder Anlagenbediener visualisieren. Weiterhin kann über die gezielte Modifikation der synthetisch erzeugten Trainingsdaten und deren Verteilungen die Vorhersage

gezielt beeinflusst und an konkrete Prozessanforderungen optimiert werden.

KI4KI-Projekt

Das IKV verfügt über langjährige Erfahrung in der Anwendung von Methoden der Künstlichen Intelligenz und Digitalisierung in der Kunststofftechnik und untersucht, wie diese gezielt eingesetzt werden können, um der Kunststoffindustrie nachhaltige Wettbewerbsvorteile zu erschließen. Die aktuelle Whitepaper-Serie gibt Einblicke in laufende Forschungsprojekte und zeigt praxisnahe Ansätze für Unternehmen. Das **Projekt KI4KI – Künstliche Intelligenz** für die Kunststoffindustrie verstehen und nutzen greift dieses Potenzial systematisch auf. Im Fokus steht der Einsatz moderner KI-Methoden – wie etwa invertierbarer neuronaler Netze – zur datenbasierten Auswahl und Optimierung von Prozessparametern in kunststofftechnischen Anwendungen. Ziel des Projekts „KI4KI - Künstliche Intelligenz für die Kunststoffindustrie verstehen und nutzen“ ist es, Unternehmen aus der Kunststoffindustrie systematisch in die Lage zu versetzen, Potenziale der Digitalisierung und Künstlichen Intelligenz (KI) zu

erkennen, systematisch zu bewerten und gezielt für ihre Produktentwicklungs- und Produktionsprozesse nutzbar zu machen. Ein besonderer Fokus liegt dabei auf der KI-gestützten Optimierung des Produktentwicklungsprozesses, zum Beispiel durch virtuelle Auslegung, simulationsbasierte Methoden und datengetriebene Erweiterungen. Letztere ermöglichen es, klassische Simulationsansätze durch lernfähige Modelle anzureichern, Unsicherheiten zu reduzieren und Vorhersagen unter realen Betriebsbedingungen zu verbessern. Ebenso im Fokus steht die Effizienzsteigerung und Qualitätsverbesserung in der Produktion, unter anderem durch prädiktive Wartung, automatisierte Qualitätsüberwachung oder datenbasiertes Prozessmonitoring. Ergänzend werden Querschnittsthemen wie Datenmanagement, regulatorische Anforderungen, Datensouveränität und ethische Aspekte adressiert. Damit unterstützt das Projekt nicht nur die kurzfristige Anwendung von KI-Methoden, sondern auch die strategische Positionierung der beteiligten Unternehmen im digitalen Transformationsprozess.



Ihr Experte für Künstliche Intelligenz und Digitalisierung



Lukas Seifert

*Wissenschaftlicher
Mitarbeiter*

Rezepturenentwicklung/
Soft-Sensorik

+49 241 80-28354

ki4ki@ikv.rwth-aachen.de



INSTITUT FÜR
KUNSTSTOFF
VERARBEITUNG

Institut für Kunststoffverarbeitung (IKV)
in Industrie und Handwerk an der RWTH Aachen
Seffenter Weg 201 | 52074 Aachen

#WHITTEPAPER