


Digital Twin of Injection Molding



Leitfaden

Datengetriebene Modellbildung von Spritzgießprozessen

Alexander Rehmer
Universität Kassel

Fachgebiet Mess- und Regelungstechnik

Prozessbeschreibung

Für eine erfolgreiche Modellbildung ist es hilfreich den zu modellierenden Prozess und seine Einflussgrößen zunächst in einem Blockschaltbild zu beschreiben. Ausgehend von dieser grafischen Darstellung der Wirkungszusammenhänge können dann Modellierungsansätze mit unterschiedlichem Detailgrad bzw. unterschiedlichen vereinfachenden Annahmen abgeleitet werden. Der in der vorliegenden Spritzgießmaschine Arburg Allrounder 470 S realisierte Prozess lässt sich wie in Abbildung 1 dargestellt beschreiben.




Abbildung 1: Blockschaltbild des geregelten 3-phasigen Spritzgießprozesses

Der Maschinenführer gibt durch Eingabe am Bedienfeld der Maschine und am Kühlaggregat Werte für die Prozessparameter s vor, welche die Sollwerttrajektorien $\{r_k\}_{k=1}^N$ für die maschineninternen Regler parametrieren. Dabei ist k die diskrete Zeit mit $t = kT_A$, T_A : Abtastzeit. Die Abbildung $f(s)$ der Prozessparameter auf die Sollwerttrajektorien ist deterministisch und bekannt. Der Spritzgießprozess selbst lässt sich in drei Phasen unterteilen: Eine geschwindigkeitsgeregelterte Einspritzphase, eine druckgeregelterte Nachdruckphase und eine Abkühlphase, in der das Bauteil bis zur Entformung abkühlt. Die während des Zyklus erfassten Prozessgrößen $\{p_k\}_{k=1}^N$ wirken in der hier verwendeten Modellvorstellung auf das im Werkzeug entstehende Bauteil und beeinflussen so dessen Eigenschaften Q . Hierbei kann es sich bspw. um dessen Masse, Geometrie, mechanische Eigenschaften und Oberflächeneigenschaften handeln. Während sich der Fertigungsprozess in drei klar voneinander abgrenzbare Phasen unterteilen lässt, ist das für den Prozess der Bauteilentstehung und der Ausbildung der Qualitätseigenschaften nicht der Fall. Im Werkzeug finden komplexe Prozesse, wie bspw. zeitlich und räumlich verteilte Fließprozesse und Phasenumwandlungen statt, die sich nicht zwangsläufig mit derselben Anzahl an Teilmodellen wie der Fertigungsprozess beschreiben lassen und unter Umständen nicht einmal mit den hier verwendeten Modellen mit räumlich konzentrierten Parametern beschreibbar sind.

Unter der Annahme, dass sich der Prozess durch Modelle mit räumlich konzentrierten Parametern beschreiben lässt, können aus der Prozessbeschreibung in Abbildung 1 verschiedene Modellierungsansätze abgeleitet werden, die im folgenden Abschnitt vorgestellt werden.

Modellierungsansätze

Zunächst sollte feststehen, für welchen Zweck das Modell eingesetzt werden soll. Daraus ergibt sich, welche Eingangsgrößen u dem Modell für die Prädiktion der Zielgröße (die Bauteileigenschaften Q) zur Verfügung stehen. Typische Anwendungsszenarien sind bspw.:

- Ein Modell soll als “Soft-Sensor” verwendet werden, um die Bauteileigenschaften Q im Anlagenbetrieb zu präzisieren, ohne dass diese gemessen werden müssen. In einem solchen Fall muss das Prädiktionsergebnis erst nach Abschluss des Zyklus vorliegen und somit können als Modelleingangsgrößen u alle Prozessparameter s , Prozessgrößen $\{p_k\}_{k=1}^N$ und beliebige daraus extrahierte Features verwendet werden.
- Soll ein Modell nicht nur zur Prädiktion verwendet werden, sondern um den Prozess zu steuern, muss das Modell die vom Nutzer manipulierbaren Größen als Modelleingangsgröße erhalten, also bspw. die Prozessparameter s . Darüber hinaus können weitere Größen zur Verbesserung des Prädiktionsergebnisses als Modelleingangsgrößen verwendet werden. Es muss jedoch sichergestellt werden, dass diese Größen zu dem Zeitpunkt zu dem Prädiktionsergebnis vorliegen muss, auch zugänglich sind. Soll ein Modell bspw. dazu verwendet werden um vor Beginn eines Zyklus die einzustellenden Prozessparameter s^{opt} zu berechnen, dann darf das Modell nur Eingangsgrößen verwenden, die vor Zyklusbeginn vorliegen oder geschätzt werden können.

Im Projekt wurden vorrangig die drei in Abbildung 2 dargestellten Modellierungsansätze untersucht. Der einfachste Ansatz a), die statische Abbildung der eingestellten Prozessparameter s auf die Bauteilqualität Q , impliziert einen identischen Anfangszustand der Spritzgießmaschine zu Zyklusbeginn sowie das Ausbleiben von Störgrößen bspw. durch sich ändernde Umgebungsbedingungen, Materialeigenschaften, Maschinenverschleiß. Inwieweit diese Annahmen erfüllt sind, entscheidet über die erreichbare Modellgüte mit diesem Ansatz.




Abbildung 2: Modellierungsansätze

Dieser Ansatz kann durch den initialen Maschinenzustand p_0 , sofern messbar, erweitert werden, siehe Abbildung 2b). Dieser umfasst bspw. die Werkzeugtemperatur zum Zyklusbeginn, die Position der Schnecke zum Zyklusbeginn und den Druck im Hydraulikaggregat zu Zyklusbeginn. Insbesondere die initiale Werkzeugtemperatur $T_{\text{wKz},0}$ hat sich als wichtiger Prädiktor herausgestellt. Hierzu sollte erwähnt werden, dass das vorlaufgeregelte Werkzeugtemperiergerät ein schnelles Auskühlen des Werkzeuges begünstigt.

Der umfassendste Ansatz zur Modellierung der Bauteilgüte ist die dynamische Abbildung der Prozessgrößentrajektorien $\{p_k\}_{k=1}^N$ auf die Bauteilqualität Q . Sogar die Auswirkungen von Störgrößen, siehe Abbildung 2c), die während eines Zyklus wirken, können hierbei mit abgebildet werden - vorausgesetzt die Wirkung der Störgröße ist in den Prozessgrößentrajektorien messbar. Für die Berechnung optimaler Prozessparameter s^{opt} ist dieses Modell im Gegensatz zu den anderen beiden Ansätzen jedoch nicht direkt nutzbar, da diese nicht ins Modell eingehen. Es ist ein weiteres Modell erforderlich, welches die Prozessparameter zunächst auf die Prozessgrößentrajektorien $\{p_k\}_{k=1}^N$ abbildet.

Die beiden vorgestellten statischen Modellierungsansätze wurden mittels Neuronaler Netze mit einer und zwei verdeckten Schichten sowie Polynomen mit Interaktionstermen umgesetzt. Für den dynamischen Ansatz musste ein schaltendes dynamisches Modell entwickelt werden, welches in Abbildung 3 dargestellt ist. Für eine detailliertere Modellbeschreibung wird an dieser Stelle auf den Konferenzbeitrag

Rehmer, A. & Klute, M. et al. *An internal dynamics approach to predicting batch-end product quality in plastic injection molding using Recurrent Neural Networks*, IFAC-PapersOnLine 6th IEEE Conference on Control Technology and Applications (CCTA), Vol. 53, Elsevier, 2022

verwiesen.




Abbildung 3: Schaltendes Qualitätsmodell mit interner Dynamik

Erreichte Modellgüten

Die Modellgüten werden im Folgenden basierend auf den Daten, die im Rahmen eines zwei-stufigen zentral zusammengesetzten Versuchsplans (Central Composite Design – CCD) mit Zentralpunkt und mittigen Sternpunkten erhoben wurden, vorgestellt. Die acht variierten Fak-toren sind in Tabelle 1 dargestellt.

Tabelle 1: Faktoren und Faktorstufen

Prozessparameter <i>s</i>	-1	0	1
Düsentemperatur	250 °C	255 °C	260 °C
Werkzeugtemperatur	40 °C	45 °C	50 °C
Einspritzgeschwindigkeit	16 cm ³ /s	32 cm ³ /s	48 cm ³ /s
Umschaltpunkt	13 cm ³	13,5 cm ³	14 cm ³
Nachdruckhöhe	500 bar	550 bar	600 bar
Nachdruckzeit	3 s	4 s	5 s
Staudruck	25 bar	50 bar	75 bar
Restkühlzeit	15 s	17,5 s	20 s

Das exemplarisch produzierte Bauteil ist der in Abbildung 4 abgebildete Originalitätsver-schluss. Die prädizierte Qualitätsgröße ist in diesem Fall der Durchmesser der Verschluss-kappe.



Abbildung 4: Originalitätsverschluss

Die Ergebnisse der Modellbildung sind qualitativ in Tabelle 2 zusammengefasst.

Tabelle 2: Qualitative Zusammenfassung der Modellbildung des Spritzgießprozesses

Modellierungsansatz	Modellstruktur	Implementierungsaufwand	Optimierungsdauer	Modellgüte	Anmerkungen
$s \rightarrow Q$	Polynom	gering	ms	o	<ul style="list-style-type: none"> • Global optimales Modell in einem Schritt berechenbar • Keine Mehrfachinitialisierung erforderlich • Polynom 4. Grades i.d.R. ausreichend, oszillierende Interpolation bei höheren Graden
	Multilayer Perceptron	gering	s - min	+	<ul style="list-style-type: none"> • Modellgüte variiert kaum • Wenige Mehrfachinitialisierung erforderlich • Zwei verdeckte Schichten i.d.R. etwas besser als seine verdeckte Schicht.
$\begin{bmatrix} s \\ p_0 \end{bmatrix} \rightarrow Q$	Polynom			+	
	Multilayer Perceptron	siehe oben	siehe oben	++	• siehe oben
$\{p_k\}_{k=1}^N \rightarrow Q$	Schaltendes Modell mit interner Dynamik	sehr hoch	h	+++	<ul style="list-style-type: none"> • Modellgüte variiert stark • Mehrfachinitialisierung erforderlich

Lessons Learned

Anhand der vorliegenden Ergebnisse und der während der Versuchsdurchführung gesammelten Erfahrungen lassen sich folgende Schlussfolgerungen ableiten:

- Statische Modelle sind zur Prädiktion der Bauteilqualität sehr gut geeignet und haben ein besseres Kosten-Nutzen Verhältnis als dynamische Modelle.
- Im Hinblick auf eine Optimierung der einzustellenden Prozessparameter s sind statische Modelle ebenfalls vorzuziehen, da diese sich unmittelbar hierfür verwenden lassen.

Bei der Mehrfachdurchführung von Versuchsreihen traten regelmäßig nicht-reproduzierbare Effekte, auch während des gleichen Tages auf. Es existieren also noch weitere, nicht erfasste und nicht kontrollierbare Größen, welche die Bauteilqualität beeinflussen. Mögliche Maßnahmen in diesem Fall sind:

- Den Prozess von jeglichen Störgrößen abschotten, indem alle Randbedingungen (Materialeigenschaften, Umgebung, etc.) konstant gehalten werden.
- Identifizieren und Messen der Störgrößen, um diese in das Modell aufnehmen zu können. Da der Eingangsgrößenraum hierdurch sehr hochdimensional würde, sind

Methoden zu entwickeln, die auch bei spärlich besetzten Eingangsräumen akzeptable Ergebnisse liefern.

- Nachschätzen des Modells basierend auf den vorliegenden Daten, damit dieses das geänderte Eingangs-Ausgangsverhalten lernt.

Im Projekt wurde sich für die letztere Maßnahme entschieden. Hat eine Maschine aber einen stark ausgeprägten „Tagesgang“ ist dies vermutlich keine langfristig befriedigende Lösung, da das Modell dann ständig nachgelernt werden muss und auf Basis des Modells errechnete Prozessparameter nicht vertrauenswürdig sind.

Weiterführende Literatur

Projektbezogene Literatur:

Rehmer, A. & Klute, M. et al. *An internal dynamics approach to predicting batch-end product quality in plastic injection molding using Recurrent Neural Networks*, IFAC-PapersOnLine 6th IEEE Conference on Control Technology and Applications (CCTA), Vol. 53, Elsevier, 2022

Rehmer, A. & Klute, M. & Kroll, A. & Heim, H.-P. *A Digital Twin for Part Quality Prediction and Control in Plastic Injection Molding*, Modeling, Identification, and Control for Cyber-Physical Systems Towards Industry 4.0, Elsevier, 2023, accepted.

Rehmer, A. & Kroll, A. *Eine Python-Toolbox zur datengetriebenen Modellierung von Spritzgießprozessen und Lösung von Optimalsteuerungsproblemen zur Steuerung der Bauteilqualität*, 32. Workshop Computational Intelligence, KIT Scientific Publishing, Berlin, Deutschland, <https://library.oapen.org/handle/20.500.12657/59840>, 2022.

Grundlagenliteratur:

Nelles, O., *Nonlinear system identification: from classical approaches to neural networks, fuzzy models, and gaussian processes*. 2. Auflage, Springer Nature, 2020.

Kroll, A., *Computational Intelligence: Probleme, Methoden und technische Anwendungen*, 2. Auflage, Berlin, Boston: De Gruyter Oldenbourg, 2016.
<https://doi.org/10.1515/9783110401776>

Bildquellen:

- [1] <https://hmq-3d.ch/galerie/40/3d-modell-spritzgiessmaschine-arburg.html>
zuletzt aufgerufen am: 21.02.2023