

Long Short-Term Memory zur Prognose von real Zeitreihen aus einer Simulationsumgebung beim Kunststoffspritzgießen

Idee

- Reduzierung von Ausschuss und Generierung von Prozesswissen beim Spritzgießen von Kunststoffprodukten
- Die „Black Box“ Spritzgießwerkzeug zu einer aktiven Informationsquelle erweitern
- Einsatz von Sensoren und maschineller Lernverfahren zur Bewertung der Prozesssituation und Ausgabe von Hilfestellungsempfehlungen

Hürde

- Maschinelle Lernverfahren benötigen immer repräsentativ Daten für das Training
- Generierung von Daten bedeutet Herstellung von Bauteilen (inkl. nicht verkaufsfähiger Bauteile) was Zeit- und Ressourcenintensiv ist
- CAE-Software kann nicht direkt als Ersatzdatenlieferant genutzt werden, da die numerische Prozesssimulation nicht realitätsnah ist

Zielsetzung

- CAE-Software Ergebnisse sind durch zwei Surrogat-Modells zu nutzbaren Daten für das ML-Training zu modifizieren
- Generierung von realitätstreuen Zeitreihen der Messbaren physikalischen Größen Druck und Temperatur
- 100 % synthetische Datenbasis für das Training von Prozessbegleitungssystem

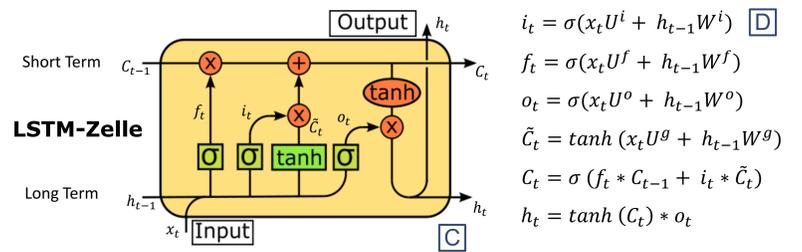
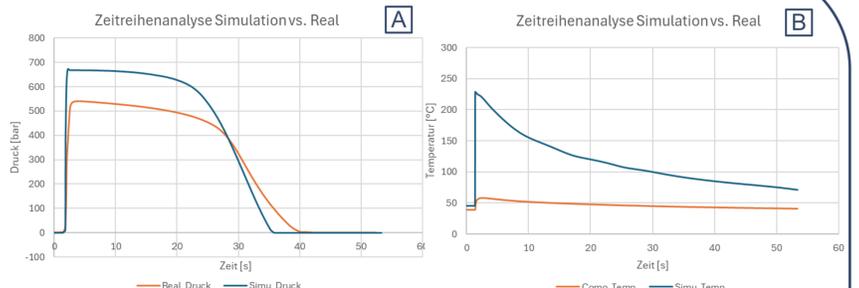
Vorgehen und Verfahren

Für die Untersuchung des Surrogat-Modells zur Zeitreihenmodifikation wurden Mehrzweckprobekörper nach DIN EN ISO 1873 aus Polypropylen mit einem Versuchswerkzeug inkl. Sensorik (Kistler Kombisensor Typ 6190) hergestellt. Mit der CAE-Software Moldex3D wurde dieser Herstellungsprozess unter Einhaltung der simulativ umsetzbaren Randbedingungen nachgebildet. Die numerisch generierten Zeitreihen weichen in ihrem Verlauf von den realen Messergebnissen ab ($MAE_{Druck} = 97,18 \text{ bar}$, $MAE_{Temp.} = 77,24 \text{ }^\circ\text{C}$), was eine direkte Verwendung als Trainingsgrundlage ausschließt. Für den Druckverlauf ist dies auf eine verallgemeinerte Annahme der Kristallinität von Kunststoffen zurückzuführen [Saad24] (A). Beim Temperaturverlauf ergibt sich die wesentliche Differenz aus dem mathematisch korrekten Temperaturanstieg bei Kontakt mit der Polymerschmelze und dem, was in der Realität durch Temperaturträgheit und Wärmeabfuhr über die Kavität wand messbar ist (B).

Das Ersatzmodell ist eine Long Short-Term Memory (LSTM) Zelle aus der Strukturfamilie der rekursiven Verfahren. Die Struktur des LSTM erlaubt die Verarbeitung von variablen Zeitreihen und wird auf seine Anwendbarkeit zur „Übersetzung“ der simulierten Graphen (Input) in reale Graphen (Output) untersucht (C). Durch die Kopplung mehrerer Summen- und Aktivierungsfunktionen (D) ist die LSTM-Zelle in der Lage, ein dem menschlichen Gehirn nachempfundenenes Kurz- und Langzeitgedächtnis zu trainieren.

Der im Preprocessing mehrdimensional zusammengefasste Input, bestehend aus den drei für die Prozessführung relevanten physikalischen Größen. Als Variationsparameter werden die Füllzeit, die Werkzeugtemperatur sowie die Schmelzetemperatur verwendet, die aufgrund ihres signifikanten Einflusses auf den Wärmehaushalt des Werkzeugs für die Prozessfähigkeit entscheidend sind.

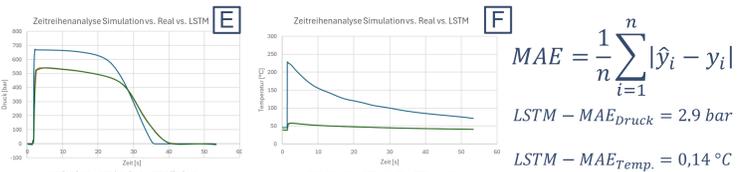
[Saad24] Saad et al., Efficient identification of a flow-induced crystallization model for injection molding simulation, The International Journal of Advanced Manufacturing Technology, Mar. 2024



Ergebnis

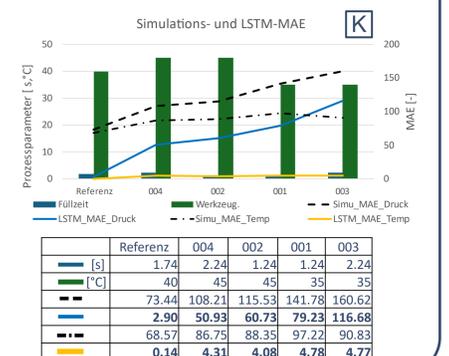
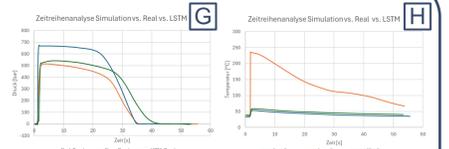
Das Training der Modellstruktur erfolgte nur mit einem Datensatz, d.h. es wurde ein realer Zyklus verwendet. Anschließend wurde das Modell mit vier simulierten Zeitreihen für Druck und Temperatur getestet und zur Kontrolle wurden wiederum nur vier reale Zyklen aufgenommen. Das Trainingsergebnis zeigt bereits, dass die LSTM-Zelle das angestrebte Ziel erfüllt und eine massive Reduktion der Abweichung realisiert (E, F).

Zur Bestimmung des Fehlermaßes wurde der Mean Absolute Error (MAE) verwendet, um den Prognosefehler bei Zeitreihenanalysen zu bestimmen. Hierbei wird die Summe der betragsmäßigen Abweichung zwischen der Messgröße y_i und dem zugehörigen Prognosewert \hat{y}_i durch die Anzahl n der Messpunkte in einem Graphen dividiert.



Die Testergebnisse der Zeitreihen mit Variation der Prozessparameter weichen aufgrund der geringen Datenerfassung für das Training stark von den realen Daten (G, H) ab, da das LSTM derzeit nur einen Datensatz kennt, der mit den Prozessparametern aus der Spalte Referenz erstellt wurde. Die Tatsache, dass das Ersatzmodell bereits in der Lage ist, die MAE-Werte je nach Prozessführung nahezu zu halbieren (siehe Tabelle), spricht für die angedachte Vorgehensweise und das verwendete Lernverfahren.

Einen signifikanten Einfluss hat hierbei die Werkzeugtemperatur, durch deren Reduzierung sich auch die Druckverhältnisse in der Kavität massiv ändern, was zu einer zunehmenden Abweichung in der Drucksimulation und auch in der LSTM-Vorhersage für den Druckverlauf (K) führt. Unter Berücksichtigung der für das Training verwendeten Datenmenge sind die Ergebnisse dennoch als positiv zu bewerten. Die Untersuchungen sollte zunächst nur zeigen, ob eine prinzipielle Anwendung des LSTM zielführend ist und nicht, ob das Verfahren mit nur einem Trainingsbeispiel allgemeingültig funktioniert.



Fazit und Ausblick

Die hier vorgestellten Ergebnisse zeigen die Anwendbarkeit von LSTM-Modellen für die Übersetzung von Simulationszeitreihen zur Generierung einer synthetischen Datenbasis für prozessbegleitende Lernverfahren beim Kunststoffspritzgießen. In zukünftigen Arbeiten soll die Datenbasis für das Training erweitert werden, um zu untersuchen, welche Kurvenverläufe relevant sind, mit dem Ziel das Modell zu verbessern. Dazu wird ein Versuchsplan simuliert und anschließend real durchgeführt. Um eine vollständige synthetische Datenbasis zu erhalten, müssen neben den Zeitreihen auch weitere Simulationsergebnisse, wie z.B. Scherraten und Viskositäten, auf eine modellgestützte Korrelation mit realen Zielgrößen, wie z.B. dem Bauteilverzug, untersucht werden. Hierzu wird neben dem LSTM ein FNN (Feed-Forward-Netzwerk), welches direkt mit den Informationsquellen Freigabe und Simulation (L) verbunden ist, in die Arbeiten integriert. Beide Verfahren übersetzen die Simulationsinformationen in reale und für die ganzheitliche Prozessüberwachung nutzbare Informationen. Die so generierte synthetische Datenbasis bildet die Trainingsgrundlage für das Prozessüberwachungsmodell FCN (Full Convolutional Network). Das DTR (Decision Tree Regression) wird wie das LSTM und das FNN direkt mit den relevanten Informationen aus den Versuchen trainiert, jedoch mit einer anderen Zielsetzung. Das DTR überwacht dann den Anfahrprozess und das CNN die Serienproduktion beim Spritzgießen.

