



Motivation und Zielsetzung

Optimale Maschineneinstellungen in der Kunststoffverarbeitung sind in der Regel das Ergebnis **zeit- und kostenintensiver Versuche**. Diese Forschungsarbeit stellt einen Arbeitsablauf vor, um ein **Assistenzsystem für den Plastifizierprozess** beim Spritzgießen zu erhalten, das auf **simulationsgesteuerten maschinellen Lernmodellen** basiert.

Das Assistenzsystem unterstützt den Anwender durch **Anwenden Neuronaler Netze** bei der **Ermittlung** der wichtigsten **Plastifizier- Prozessparameter** unter Einhaltung **vordefinierter Qualitätskriterien**.

Kriterien sind z.B. die **Schmelztemperatur**, die **Plastifizierzeit** und die **Aufschmelzposition** des Materials. Die **gesuchten Prozesseinstellungen** sind **Zylindertemperaturen, Schneckendrehzahl** und **Staudruck**.

Übersicht Vorgehensweise

Simulationsdatensatz mit „S3“-Software


10 Materialien * 3 Schnecken * 800 Prozesseinstellungen

→ **24000 Simulationen**



- Simulation**
 - Sammeln der Daten
 - Extrahieren der Parameter
- Modell Entwicklung**
 - Daten Aufbereitung
 - Inputs Auswahl
 - Wahl Modellklasse
 - Evaluierung
- Experimente**
 - Versuchsplan
 - Validierung
 - Vorbereitung Daten
- Modell Anpassung**
 - Fine-tuning mit Versuchsdaten

Modellanpassung (Fine-tuning) mit Experimentdaten




Ergebnisse Fine-tuned Modelle

Ergebnisse bezogen auf Versuchsdaten!

Pre-trained: Modell basierend auf Simulationsdaten

Experiment: Modell basierend auf Versuchsdaten

Fine-tuned: Kombiniertes Modell aus Simulation und Experiment



- **Physikalische Zusammenhänge** gelernt mit vielen **Simulationsdaten**
- **Maschinenverhalten** und **Simulationsabweichungen** mit **wenigen Versuchsdaten**

Optimierung durch Backpropagation

Der Backpropagation Algorithmus wird normalerweise dazu verwendet die Parameter (Gewichte w und bias b) eines Neuronales Netzes während der Trainingsphase anzupassen.

Diese Methode kann auch zur Optimierung der Inputs verwendet werden:

- Bestimmung Loss $L(\mathbf{x})$:
$$\mathcal{L}(\mathbf{x}) = \frac{1}{2}(f(\mathbf{x}) - y)^2$$
- Berechnung Gradient des Inputs der Loss Funktion:
$$\nabla_{\mathbf{x}} \mathcal{L}(\mathbf{x}) = (f(\mathbf{x}) - y) \nabla_{\mathbf{x}} f(\mathbf{x})$$
- Aktualisierung der Inputwerte:
$$\mathbf{x}^{(t+1)} = \mathbf{x}^{(t)} - \alpha \nabla_{\mathbf{x}} \mathcal{L}(\mathbf{x}^{(t)})$$

$f(\mathbf{x})$... Output Modell
 \mathbf{x} Inputs
 y Zielgröße

$\nabla_{\mathbf{x}}$... Gradient in Bezug auf Inputs
 t Iterationsschritt
 α Lernrate


Beispiel: Assistenzsystem

Initialisierung der Modell-Inputs

material	d_{screw}	m_{shot}	s_m	t_{cycle}	T_1	T_2	v_{rot}	p_{back}
ABS-P2HAT	30 mm	35 g	44 cm ³	15s	230 °C	250 °C	0.2 $\frac{m}{s}$	120 bar

Zielgrößen

Schmelztemperatur	T_m	210 °C
Plastifizierzeit	t_p	4.75 s
Aufschmelzposition	Φ	≤ 20 L/D



Optimierte Einstellung

d_{screw}	m_{shot}	s_m	t_{cycle}	T_1	T_2	p_{back}	v_{rot}	T_m	t_p	Φ
[mm]	[kg]	[cm ³]	[s]	[°C]	[°C]	[bar]	[m/s]	[°C]	[s]	[-]
30	0.035	44	15	210.6	230.6	87.93	0.28	209.99	4.76	18.53

Zusammenfassung

- Neuronale Netze werden mit Simulationen trainiert und mit Hilfe von Fine-tuning an Versuchsdaten angepasst.
- Modellvorhersagen bezogen auf experimentelle Messungen zeigen sehr gute Übereinstimmung für unbekannte (Test-)Daten.
- Der Backpropagation Algorithmus wird zur Optimierung der Inputs neuronaler Netze verwendet.
- Assistenzsystem ermittelt erfolgreich eine Grundeinstellung unter Einbeziehung definierter Zielgrößen.