

Digital Twin of Injection Molding:

Bauteilqualitätskontrolle beim Einsatz von recycelten Kunststoffen durch selbstnachtrainierende Machine Learning Modelle

Marco Klute, Hans-Peter Heim

VDI-Jahrestagung Spritzgießen 2024

Wiesbaden

Was ist ein Digitaler Zwilling?



Ein digitaler Zwilling ist eine digitale Repräsentation eines physischen Produkts, Systems oder Prozesses

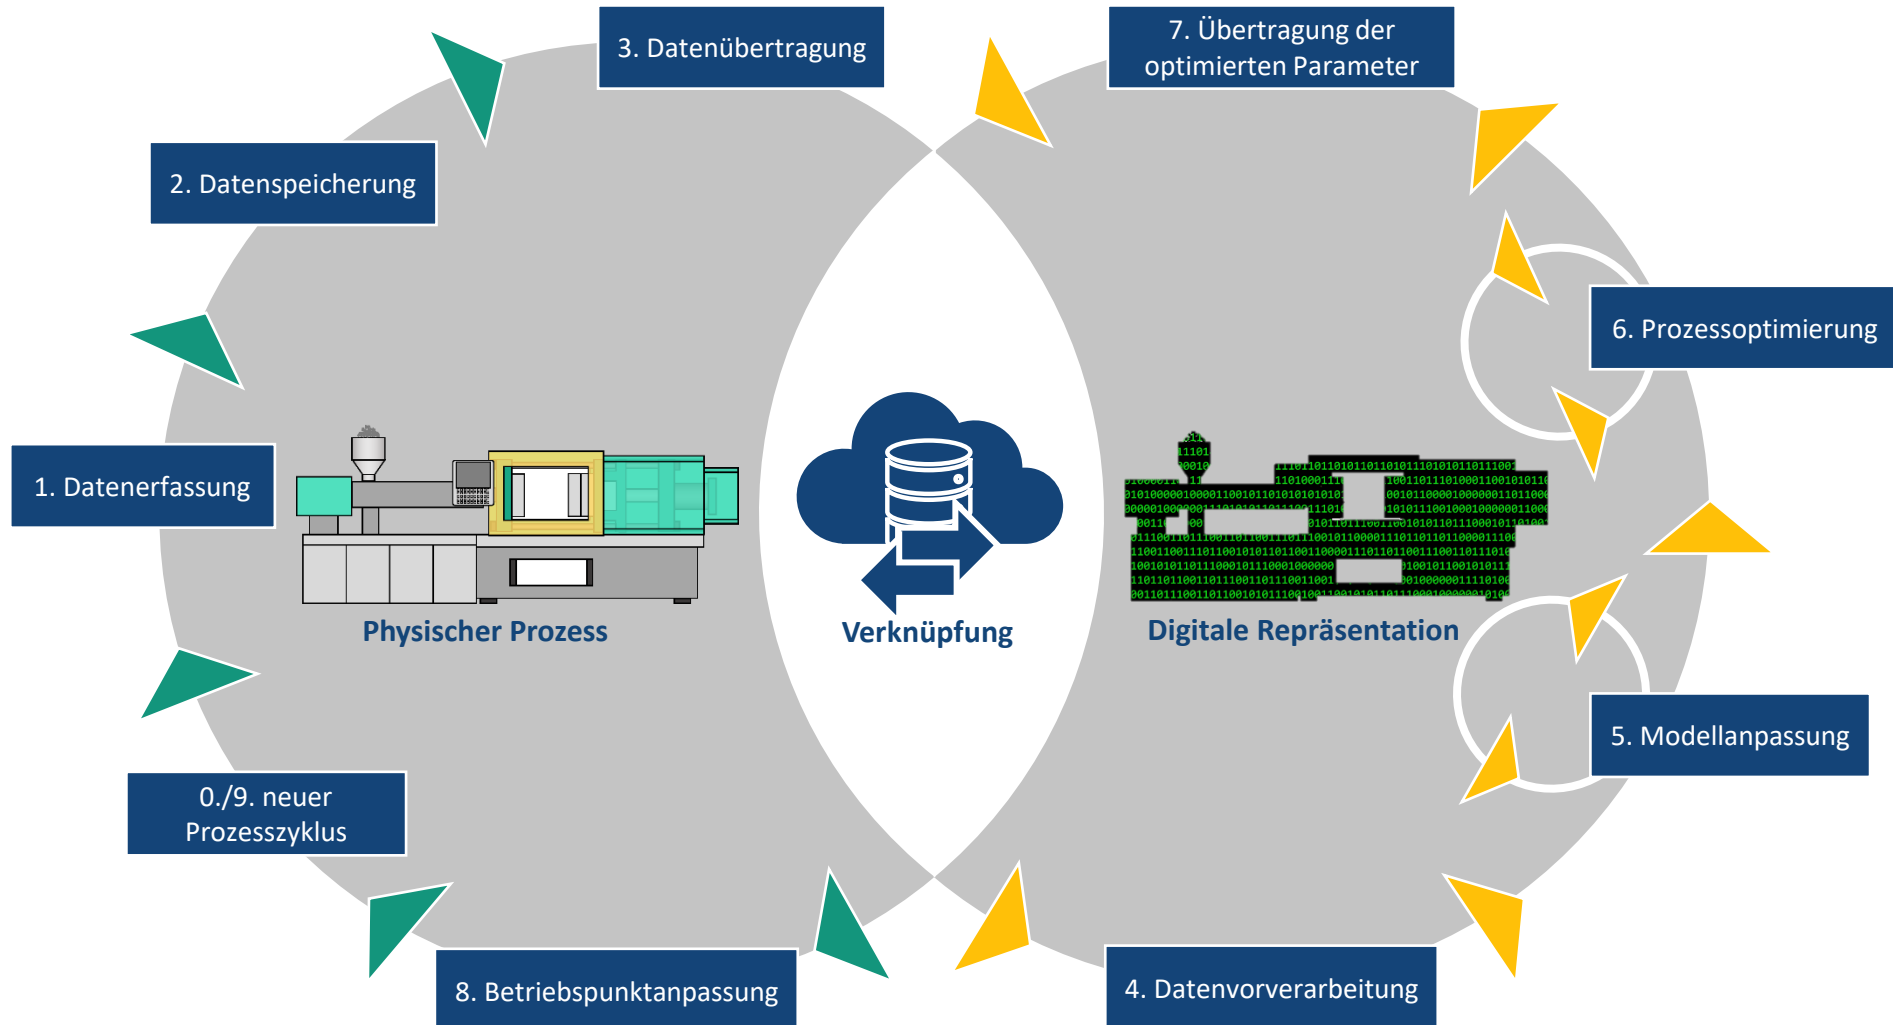


[1]

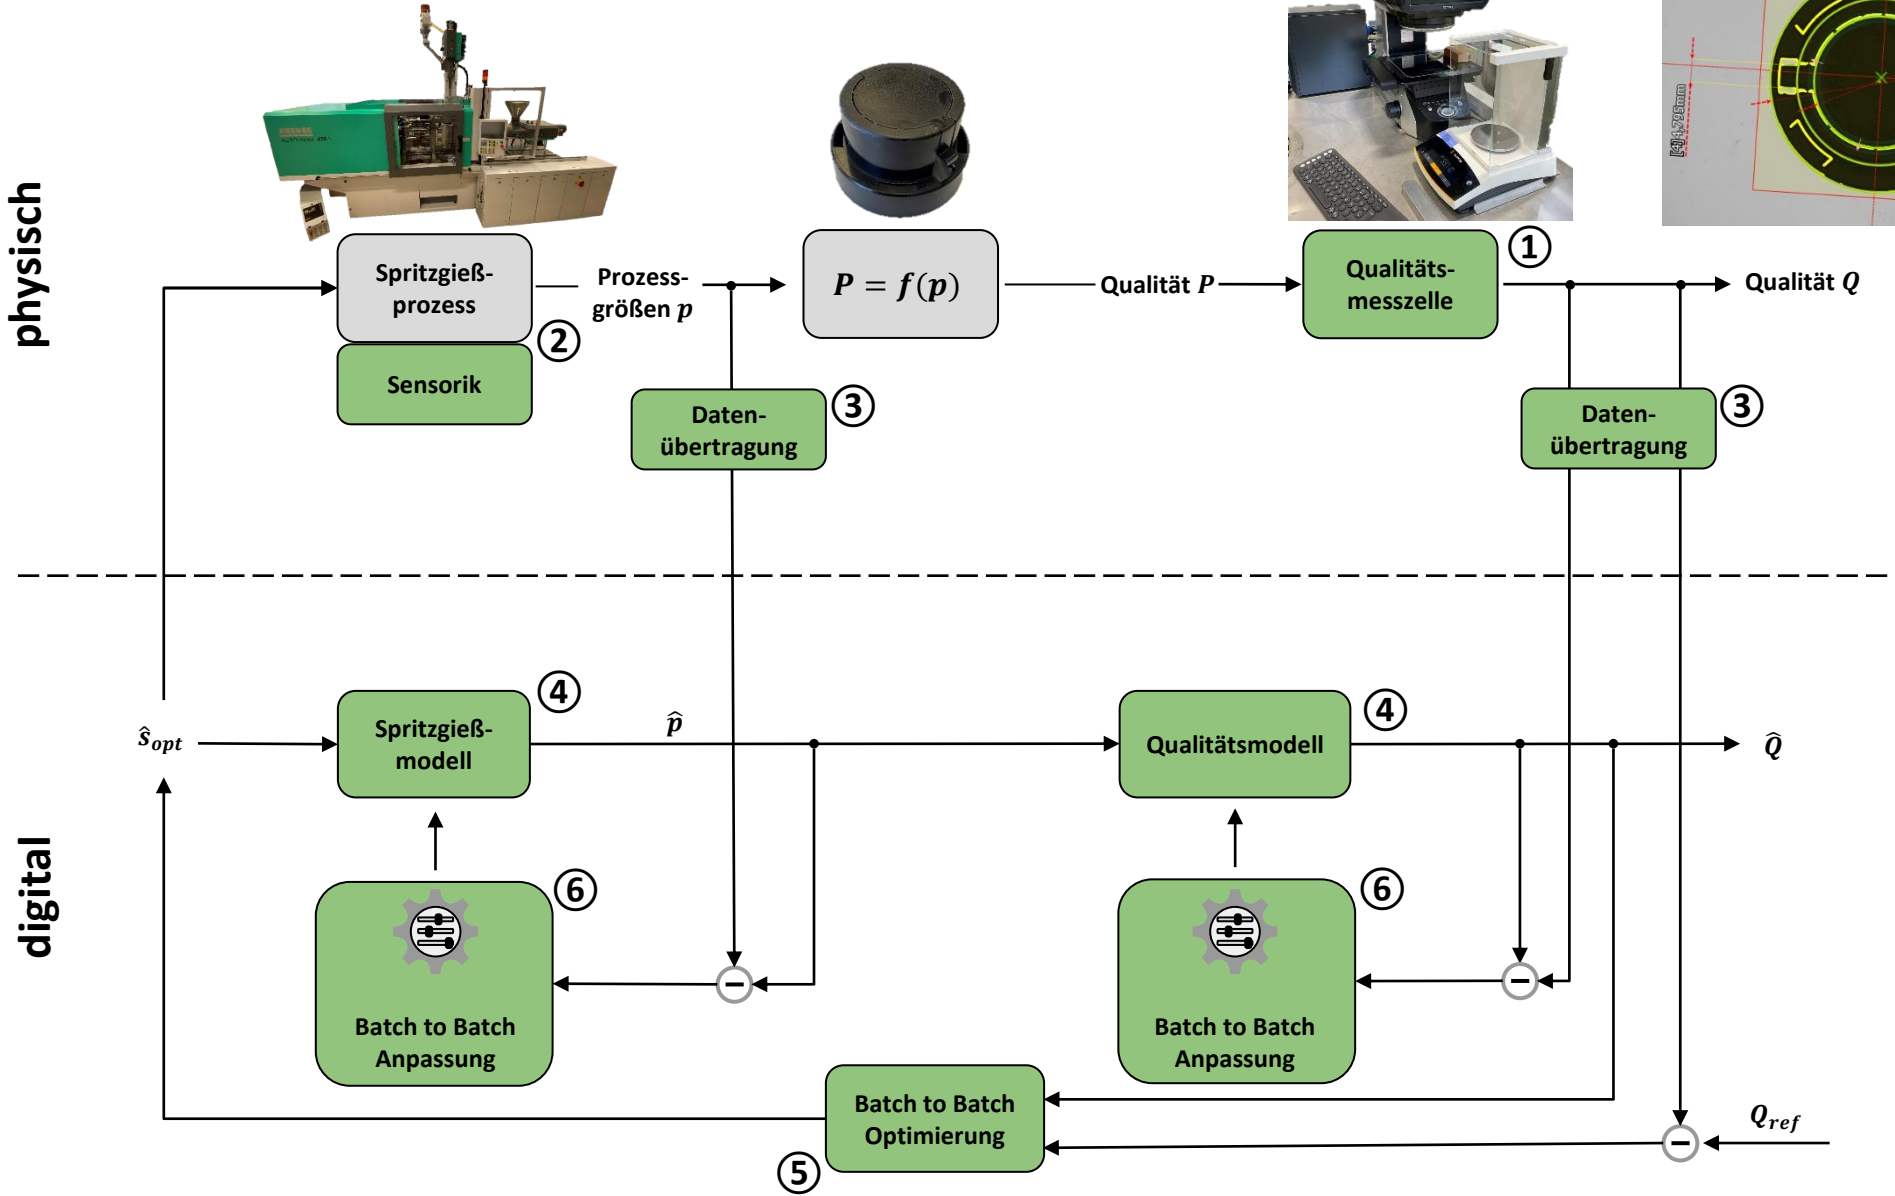
Was ist ein Digitaler Zwilling?



Ein digitaler Zwilling ist eine digitale Repräsentation eines physischen Produkts, Systems oder Prozesses



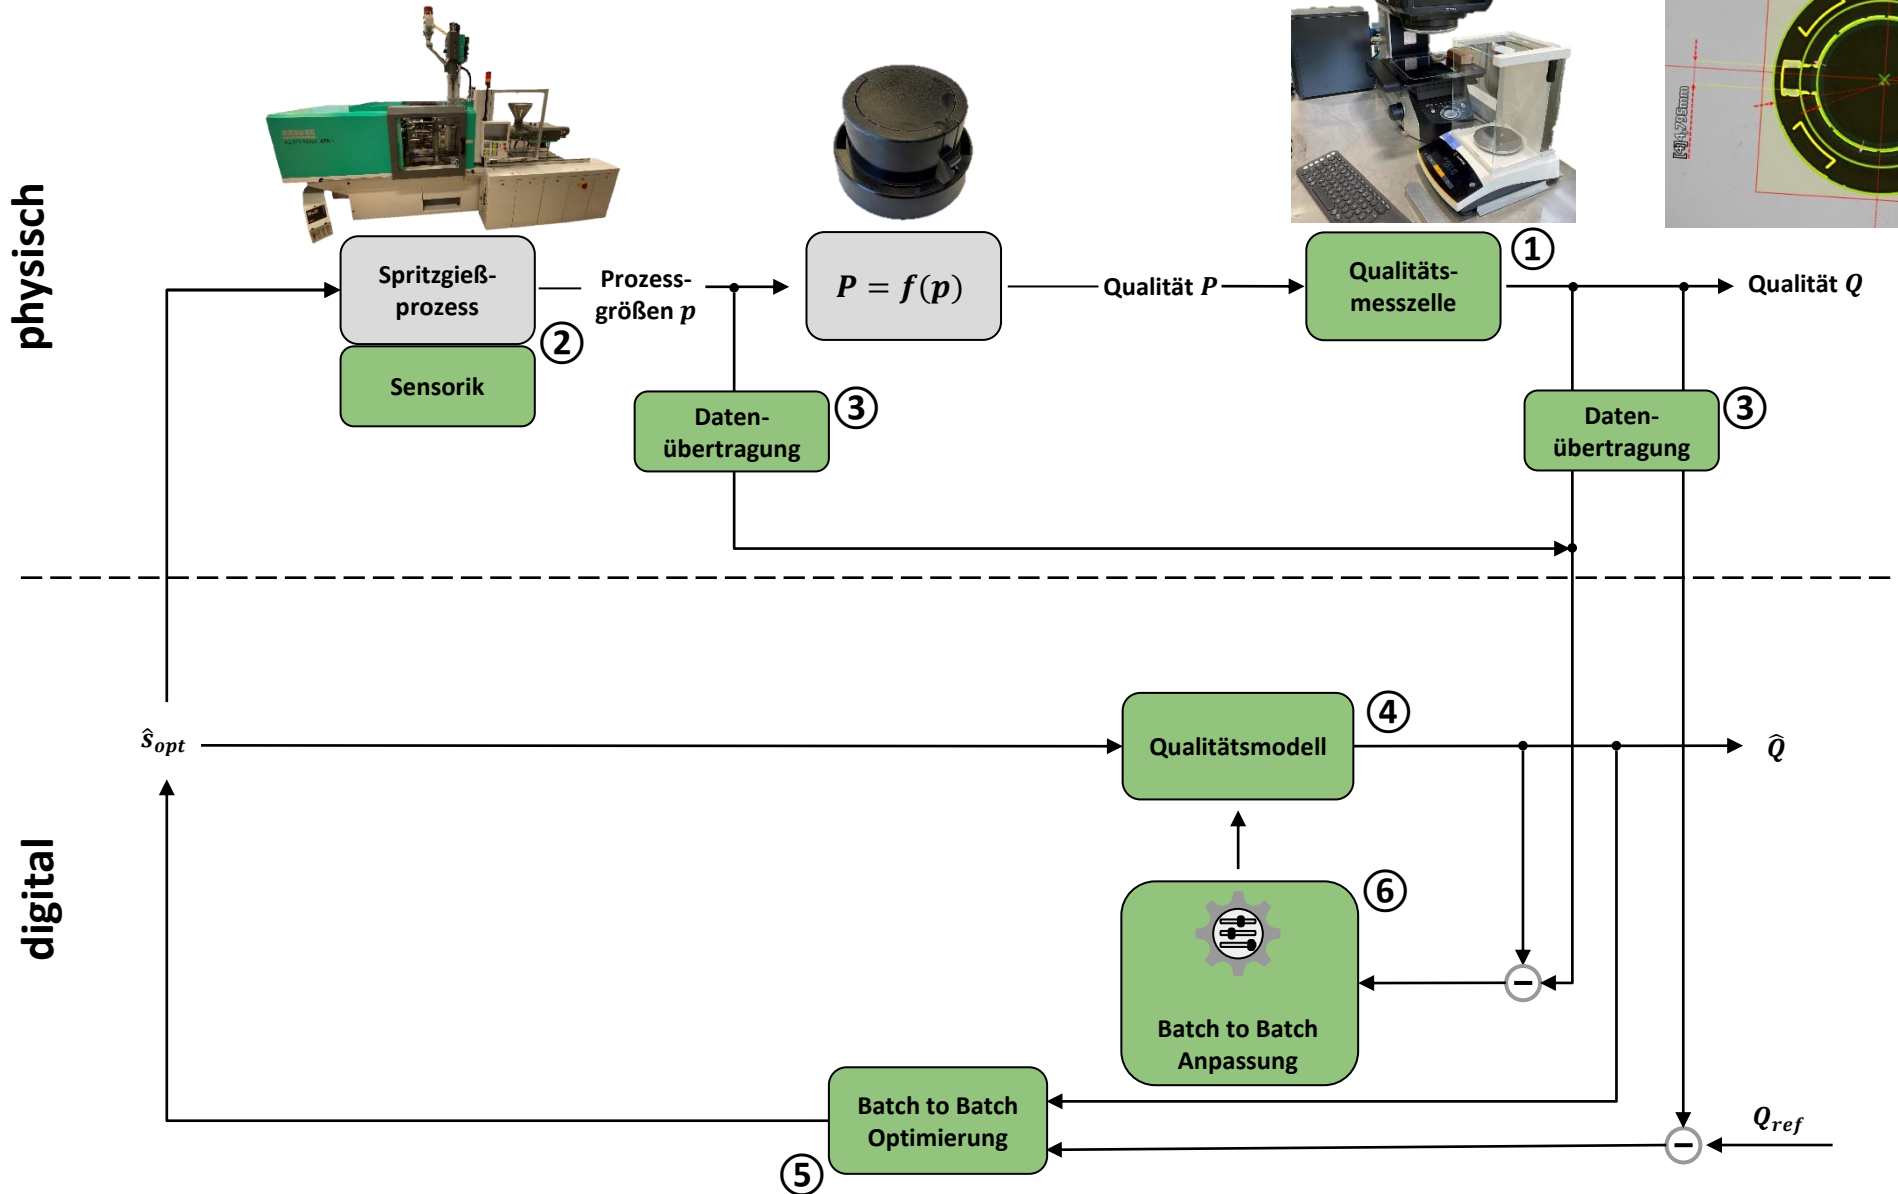
Digital Twin of Injection Molding



Entwicklungsschritte:

- ①: Qualitätsgrößen definieren
- ②: Maschine mit zusätzlicher Sensorik ausrüsten
- ③: Echtzeit-Datenübertragung einrichten
- ④: datengetriebene Modellierung des Spritzgießprozesses
- ⑤: modellgestützte Prozessoptimierung
- ⑥: Online-Modelladaption

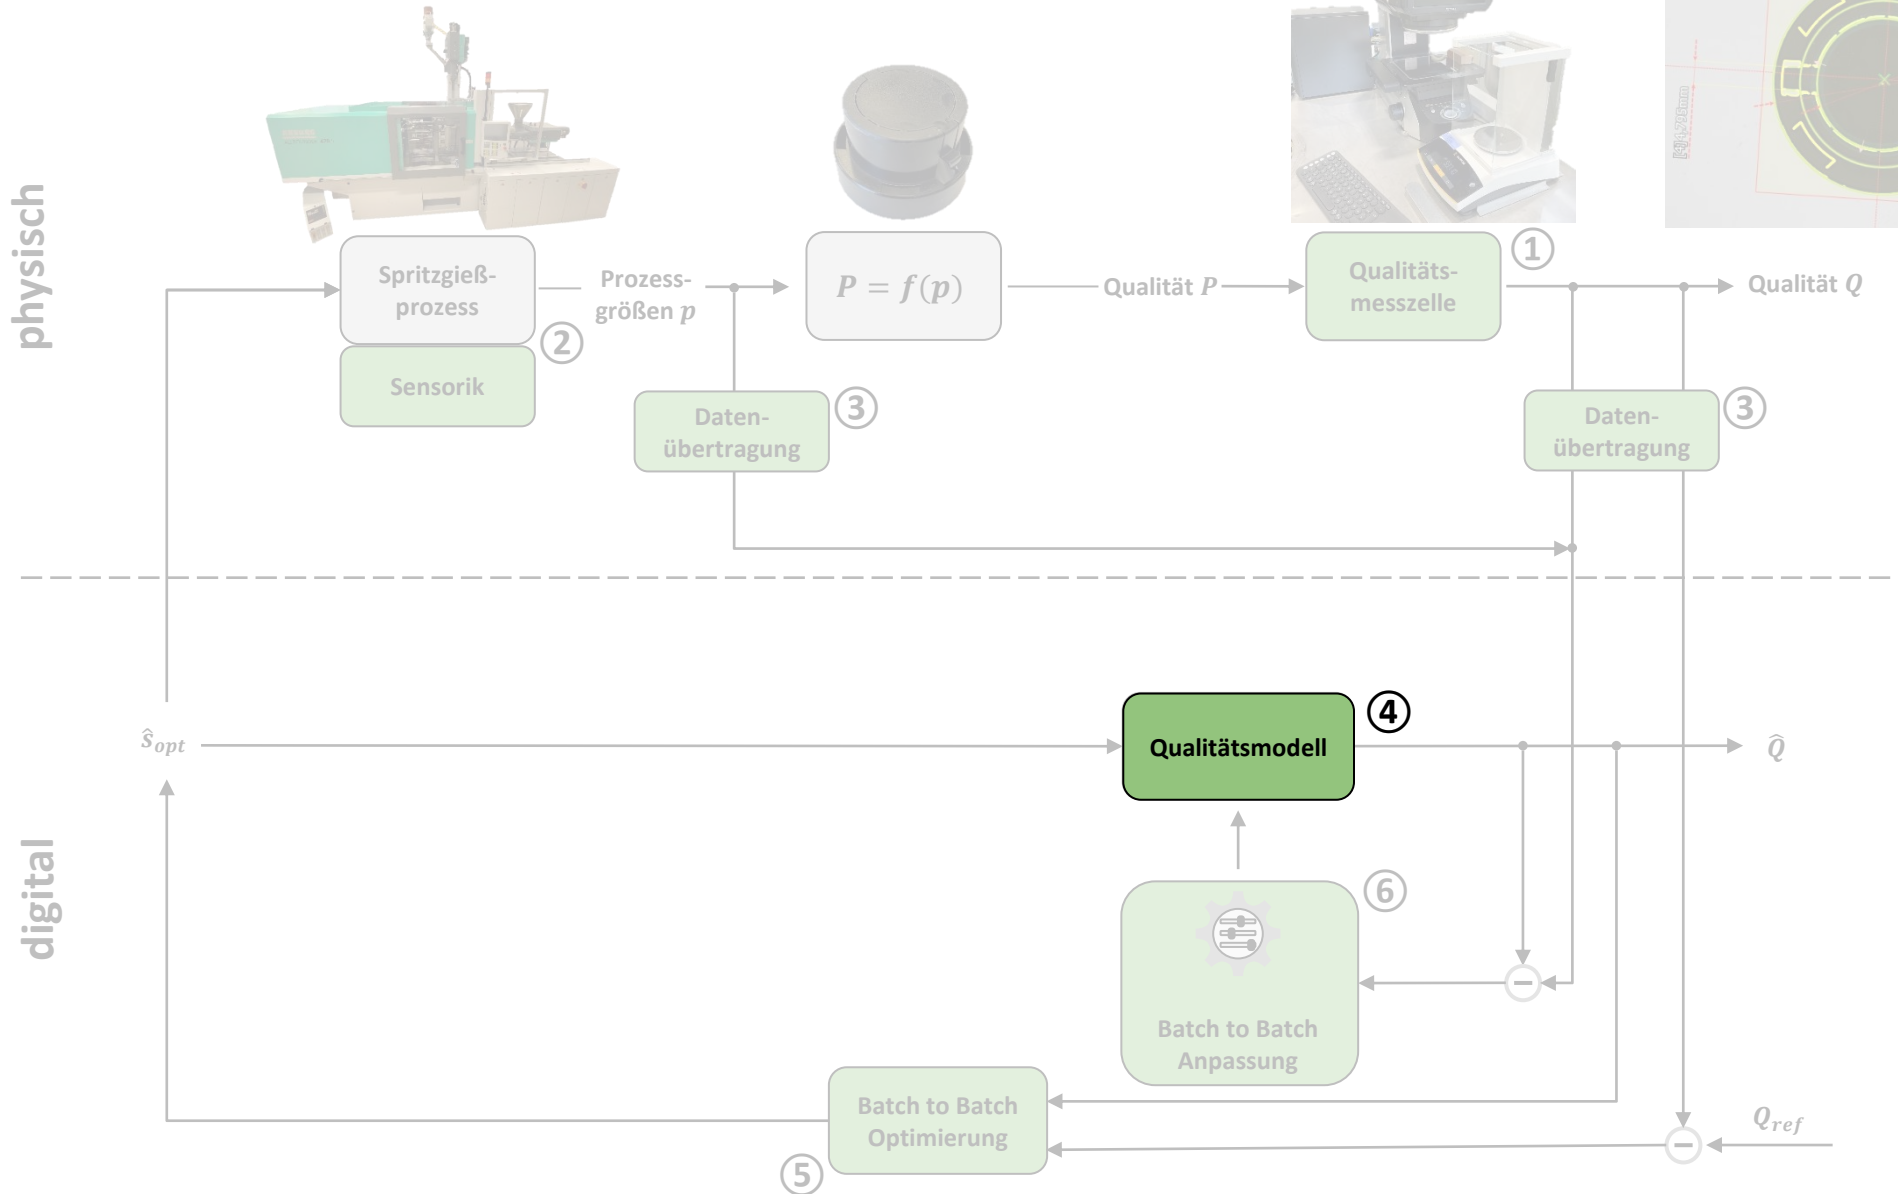
Digital Twin of Injection Molding



Entwicklungsschritte:

- ①: Qualitätsgrößen definieren
- ②: Maschine mit zusätzlicher Sensorik ausrüsten
- ③: Echtzeit-Datenübertragung einrichten
- ④: datengetriebene Modellierung des Spritzgießprozesses
- ⑤: modellgestützte Prozessoptimierung
- ⑥: Online-Modelladaption

Digital Twin of Injection Molding



Entwicklungsschritte:


- ①: Qualitätsgrößen definieren
- ②: Maschine mit zusätzlicher Sensorik ausrüsten
- ③: Echtzeit-Datenübertragung einrichten
- ④: datengetriebene Modellierung des Spritzgießprozesses
- ⑤: modellgestützte Prozessoptimierung
- ⑥: Online-Modelladaption

Datengetriebene Modellbildung



Flächenzentriertes zentral zusammengesetzter Versuchsplan (CCF)

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

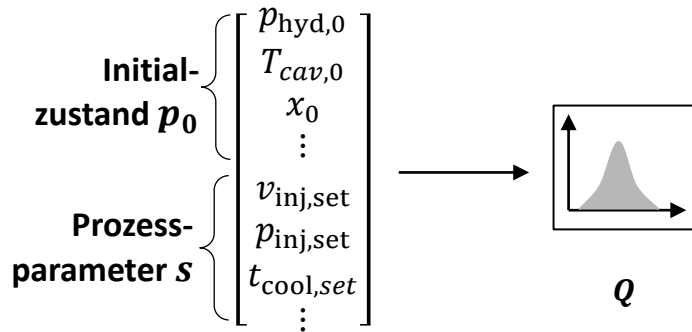



$$\begin{aligned}
 &2 \text{ Faktorstufen}^8 \text{ Einstellgrößen} = 256 \text{ Faktorenpunkte} \\
 &\quad + \\
 &2 \text{ Faktorstufen} * 8 \text{ Einstellgrößen} = 16 \text{ Sternpunkte} \\
 &\quad + \\
 &2 \text{ Wiederholungen des Zentralpunkts} \\
 &= \\
 &274 \text{ Einstellkombinationen (à 10 Zyklen)}
 \end{aligned}$$

Datengetriebene Modellbildung




Modellierungsansätze




$$Q = a_0 + a_1 \cdot v_{inj} + b_1 \cdot p_1 + \dots + d_1 \cdot p_2 + a_2 \cdot v_{inj}^2 + b_2 \cdot p_1^2 + \dots + d_2 \cdot p_2^2$$

Polynomiale Modelle

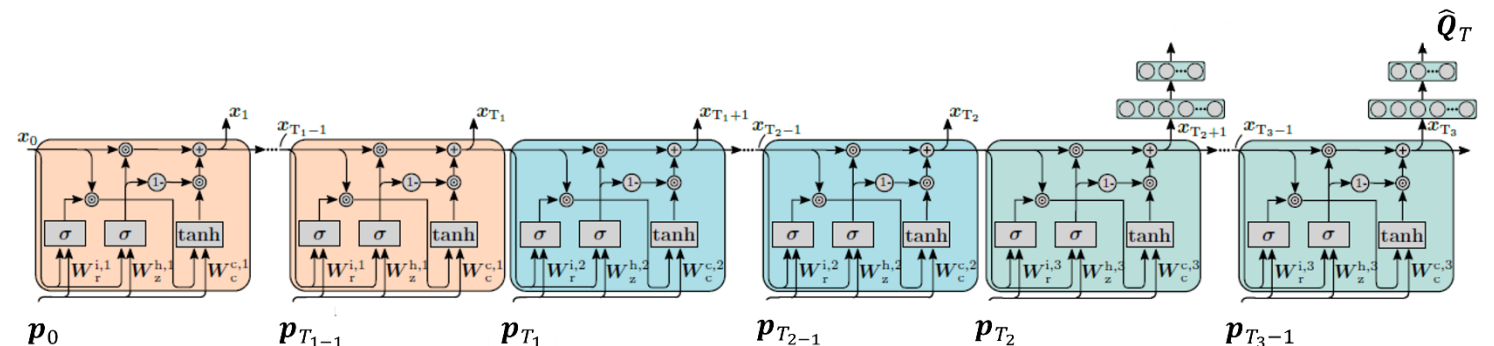
Modellstruktur (Auswahl)



Neuronale Netze mit beliebig vielen Neuronen in der verdeckten Schicht



Prozessgrößen p





Schaltende Modelle mit interner Dynamik (Rekurrente Neuronale Netze)

Datengetriebene Modellbildung



Gegenüberstellung statischer und dynamischer Modelle



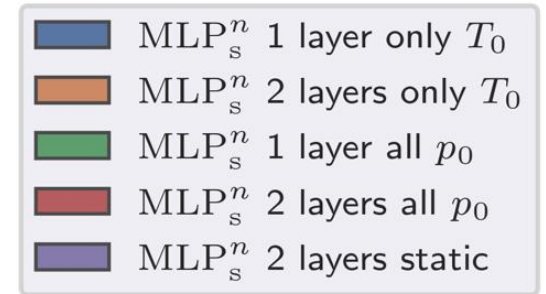
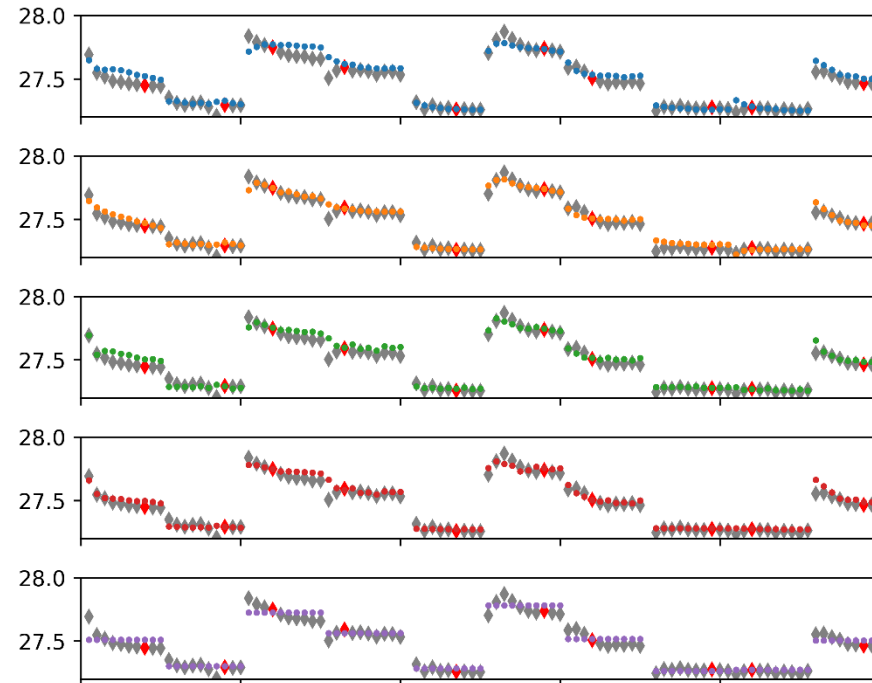
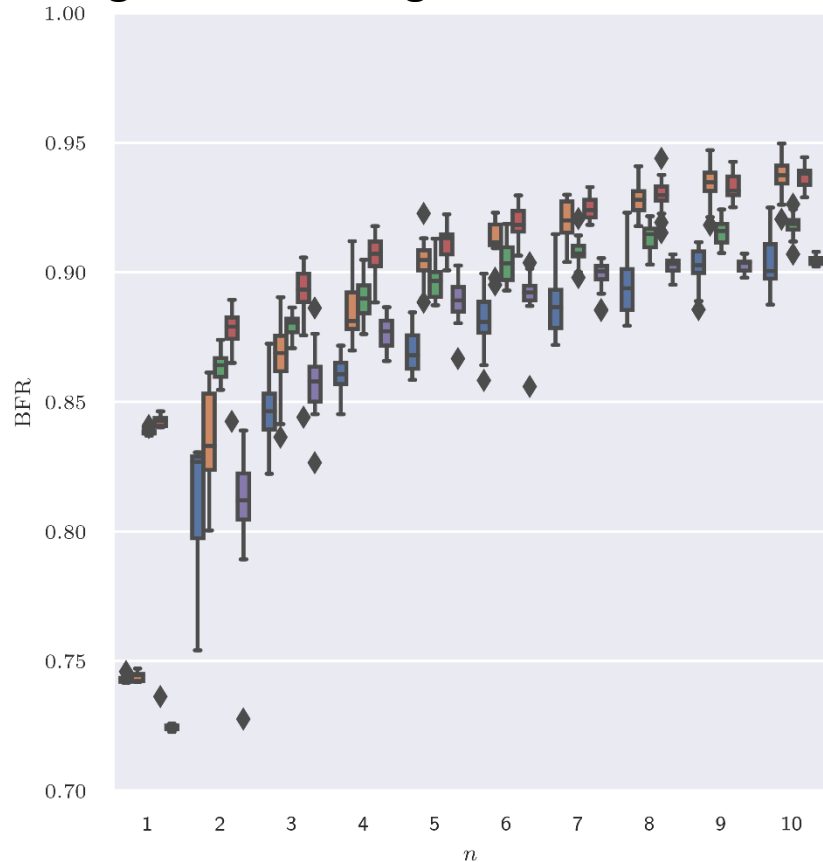
Fazit:

- Dynamische Modelle (ID) zeigen sehr gute Ergebnisse aber auch eine hohe Varianz und benötigen viel Rechenzeiten
- Statische Modelle (MLP, PR) liefern ähnlich gute Ergebnisse mit deutlich niedrigerem Rechenaufwand.
- Weiterer Vorteil: die Modelleingangsgrößen der statischen Modelle sind die Maschineneinstellgrößen und können deshalb direkt für die Prozessoptimierung verwendet werden.

Datengetriebene Modellbildung



Gegenüberstellung unterschiedlicher Neuronaler Netze (MLPs)



Fazit:

- MLPs mit zwei Schichten scheinen für den Digitalen Zwilling am besten geeignet zu sein.
- Die initiale Temperatur in der Kavität enthält für die Modellierung relevante Informationen (insb. nach Prozessanpassungen).

Wie reagiert der Digitale Zwilling auf Rezyklat?



Szenario:

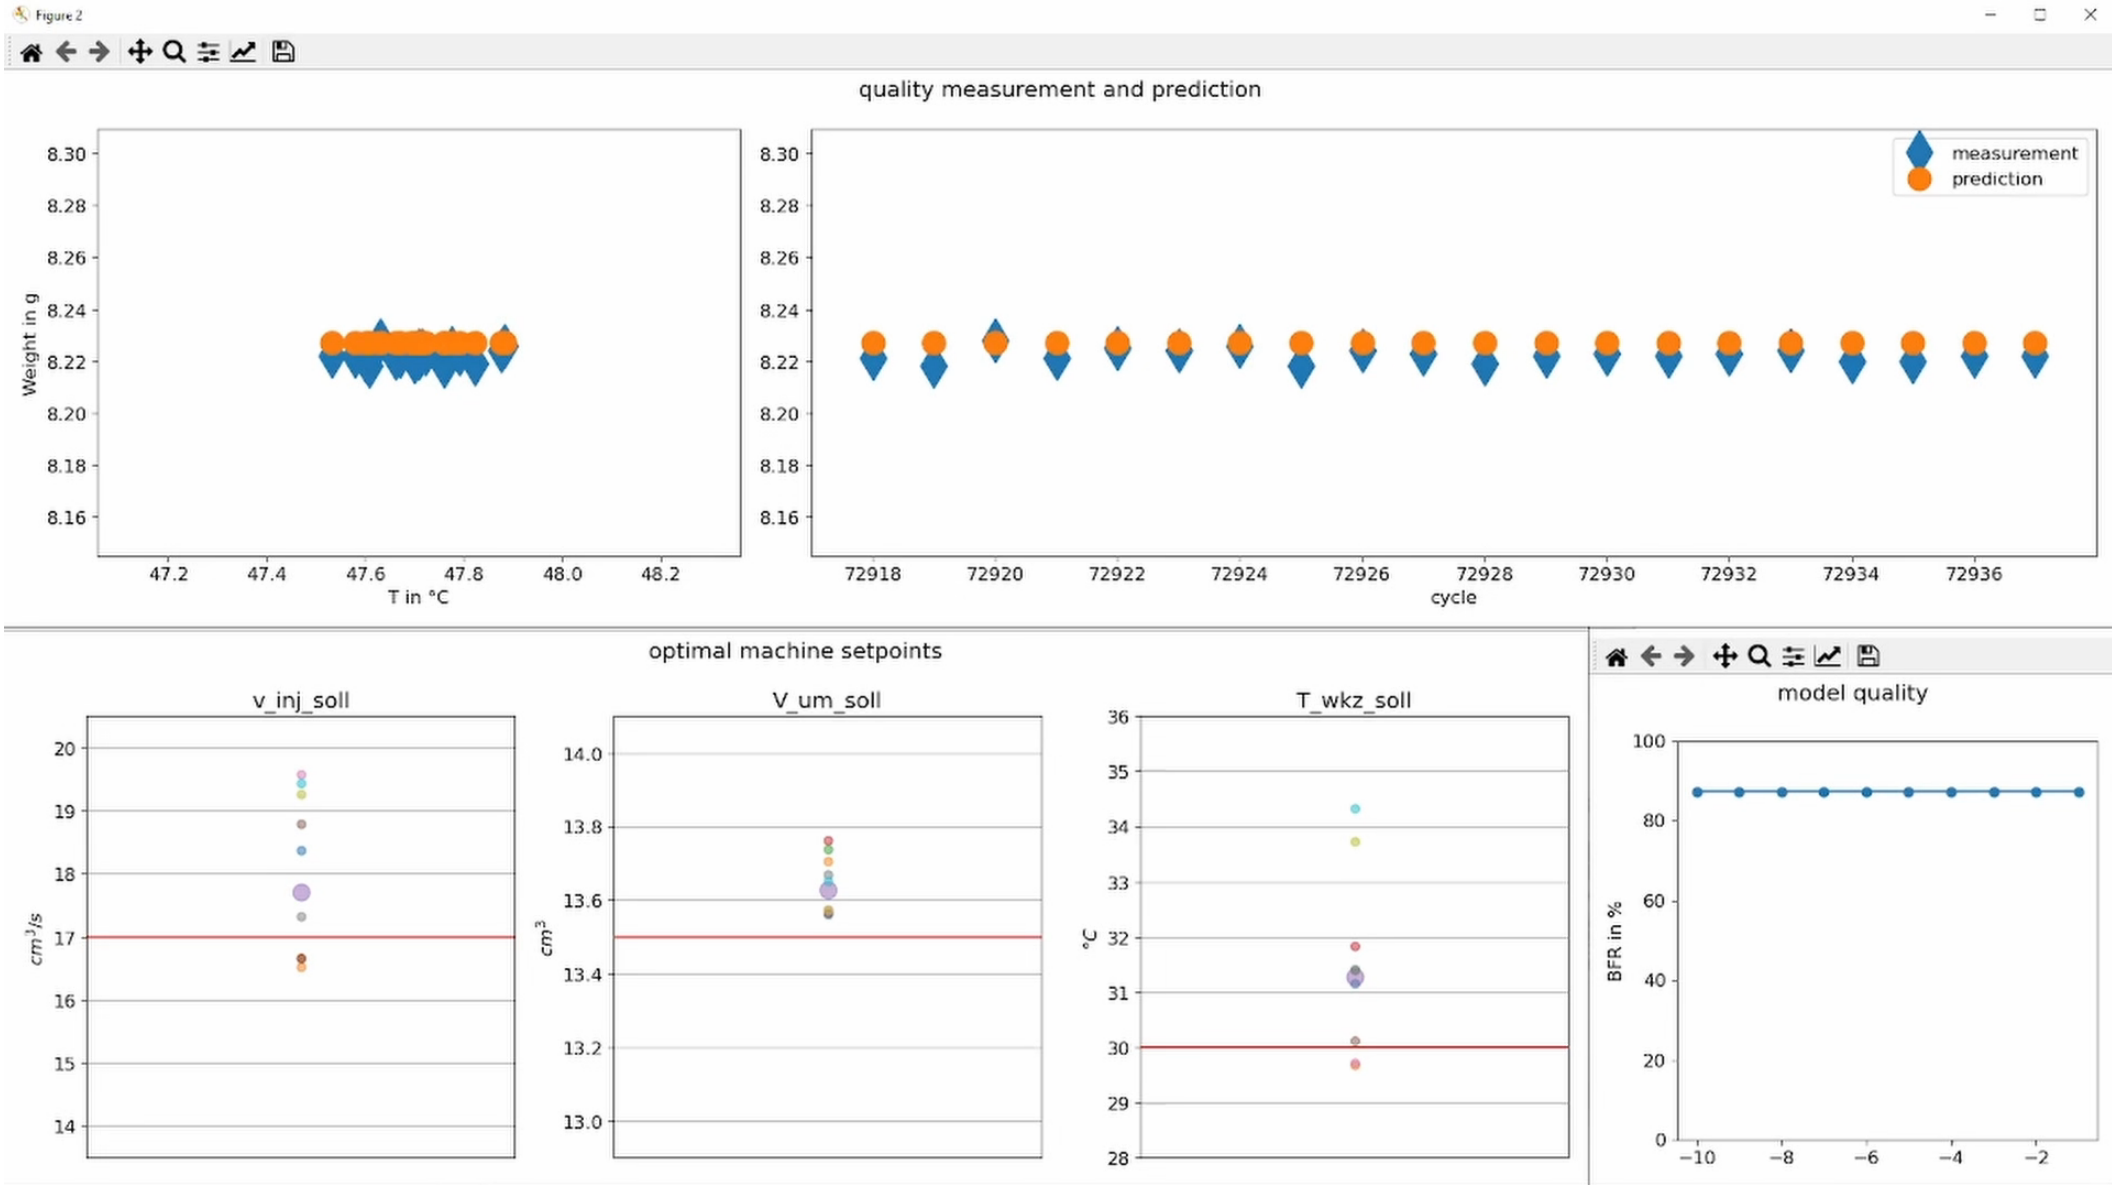
- Ein MLP wurde mit den Trainingsdaten aus dem CCF trainiert.
- Die hergestellten Bauteile wurden gemahlen, um Rezyklat herzustellen.
- Der Prozess wurde mit reinem Granulat angefahren, um einen stabilen Betriebspunkt zu erreichen.
- Dem Prozess wurden 20 % Granulat zugeführt (unbekannter Zustand).

Einstellgrößen	-1	0	1
Werkzeugtemperatur in °C	29	32	35
Einspritzgeschwindigkeit in cm ³ /s	14	17	20
Umschaltpunkt in cm ³	13	13,5	14

Aufgabe des Digitalen Zwillings:

1. Nachtrainieren der Modelle mit den neuen Daten.
2. Vorschläge für optimierte Prozesseinstellungen errechnen, um gewünschte Zielgröße (Gewicht) zu erreichen.
3. 1. und 2. wiederholen, bis die geforderte Zielgröße erreicht ist.

Wie reagiert der Digitale Zwilling auf Rezyklat?



Lessons Learned



- Dynamische Modelle sind besser als statische Modelle, aber der Rechenaufwand ist sehr viel höher.
- Statische Modelle liefern gute Ergebnisse und sind daher für die Entwicklung eines digitalen Zwillings geeignet.
- Die Anfangstemperatur in der Kavität verbessert die Leistung des Modells.
- Der digitale Zwilling sagt die Bauteilqualität mit einer BFR von mehr als 90 % voraus.
- Unbekannte Einflüsse, wie bspw. die Verwendung von Rezyklaten, reduzieren die Aussagekraft der Modelle und der vorhergesagten Qualität.
- Durch das Nachtrainieren werden zielgerichtete Parameteranschläge gemacht und der gewünschte Qualitätswert kann erreicht werden.

Projektförderung



EUROPEAN UNION
Investing in our Future
European Regional
Development Fund



**Institut für Werkstofftechnik
Kunststofftechnik
Universität Kassel**



**Institut für Analyse und Regelung technischer Systeme
Mess- und Regelungstechnik
Universität Kassel**

Abbildungen:

- [1] <https://hmq-3d.ch/referenzen/740/spritzgiessmaschine-arburg.html>
(letzter Aufruf 12.04.2024)

Publikationen:

- [1] Rehmer, A., Klute, M., Kroll, A. & Heim, H.-P. A Digital Twin for Part Quality Prediction and Control in Plastic Injection Molding, In: Modeling, Identification, and Control for Cyber-Physical Systems Towards Industry 4.0, Emerging Methodologies and Applications in Mod-elling, Identification and Control, Elsevier, submitted.
- [2] Rehmer, A., Klute, M., Kroll, A. & Heim, H.-P. An internal dynamics approach to predicting batch-end product quality in plastic injection molding using Recurrent Neural Networks. In: Preprints of the 6th IEEE Conference on Control Technology and Applications (CCTA), Tri-este, Italy, 22.-25- August, IFAC, 2022.
- [3] Rehmer, A. & Kroll, A. A Deep Recurrent Neural Network model for affine quasi-LPV Sys-tem identification. In: Proceedings of the 20th European Control Conference (ECC), pp. 566-571, London, UK, 12.-15. July, 2022.
- [4] Rehmer, A. & Kroll, A. The effect of the forget gate on bifurcation boundaries and dynamics in Recurrent Neural Networks and its implications for gradient-based optimization. In: 2022 International Joint Conference on Neural Networks (IJCNN), pp. 01-08, Padova, Italy, 18.-23. July, IEEE, 2022.
- [5] Rehmer, A. & Kroll, A. On affine quasi-LPV System Identification with unknown state-scheduling using (deep) Recurrent Neural Networks. In: IFAC-PapersOnLine Proceedings of the 26th International Conference on System Theory, Control and Computing (ICSTCC), pp. 446-451, Sinaia, Romania, 19.-21- October, 2022.



www.ifw-kassel.de



www.uni-kassel.de/go/DIM

Marco Klute, M. Sc.
Wissenschaftlicher Mitarbeiter



+49(561)804-3629



marco.klute@uni-kassel.de