

Spritzgießsimulation im Kontext der hybriden (Prozess-)Modellierung



Prof. Gerald R. Berger-Weber



Pro²Future

CHASE

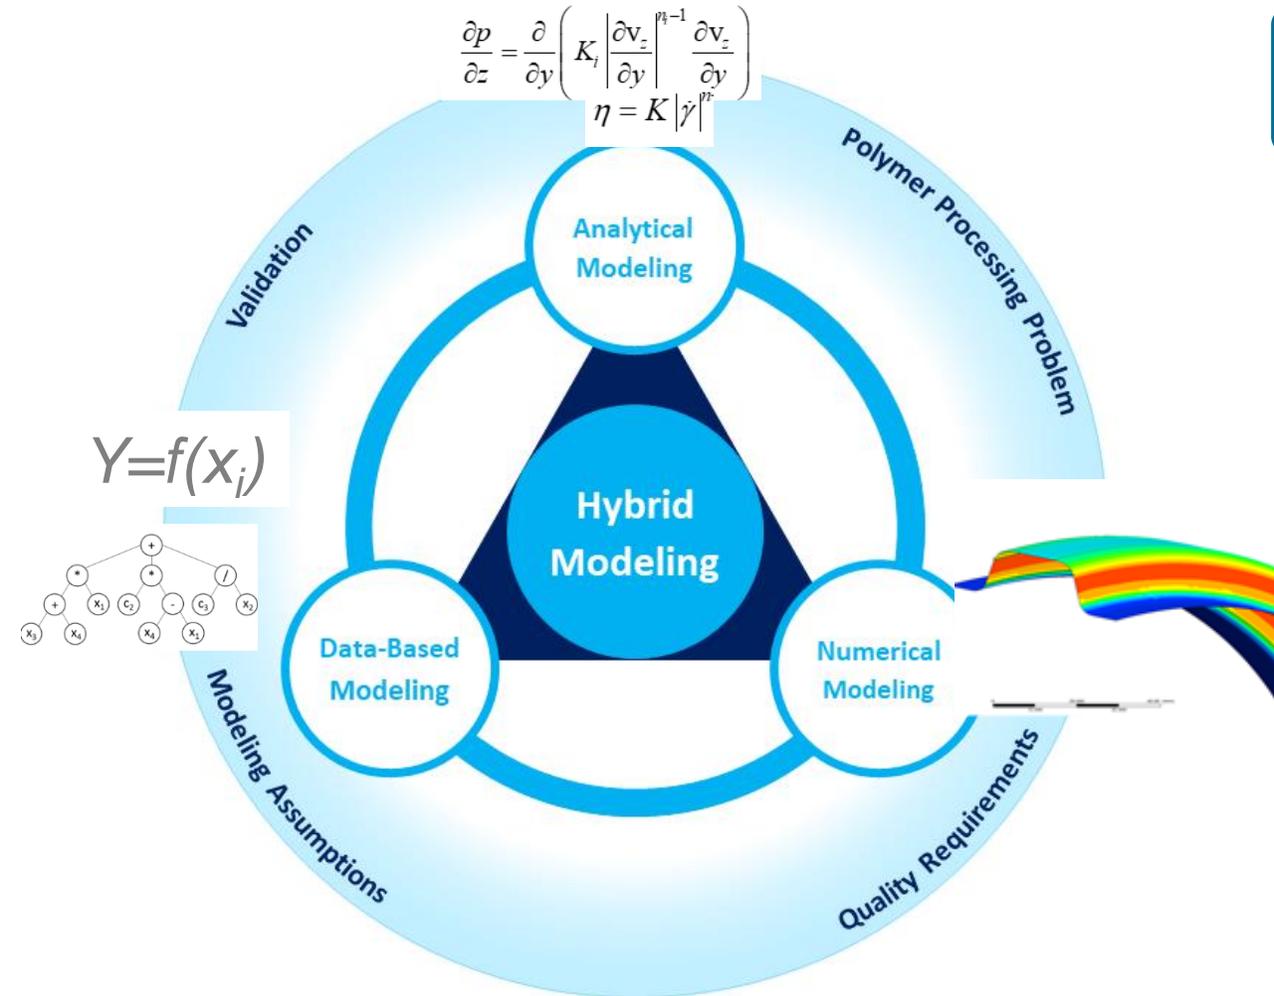
Inhalt

- Was ist die hybride Modellierung?
- Hybride Modellierung – Fallbeispiele Extrusion
- Herausforderungen Simulation: Extrusion und Spritzgießen
- Anwendungsbeispiel Kaffeemaschinenblende
- Take-home-Messages

Hybride Prozess-Modellierung (in der Extrusion)

$$\frac{\partial p}{\partial z} = \frac{\partial}{\partial y} \left(K_1 \left| \frac{\partial v_z}{\partial y} \right|^{n-1} \frac{\partial v_z}{\partial y} \right)$$

$$\eta = K |\dot{\gamma}|^{n-1}$$



Physics-informed (analytisches) Prozessmodell zwischen Eingangs- und Zielgrößen

Mit Berücksichtigung von:

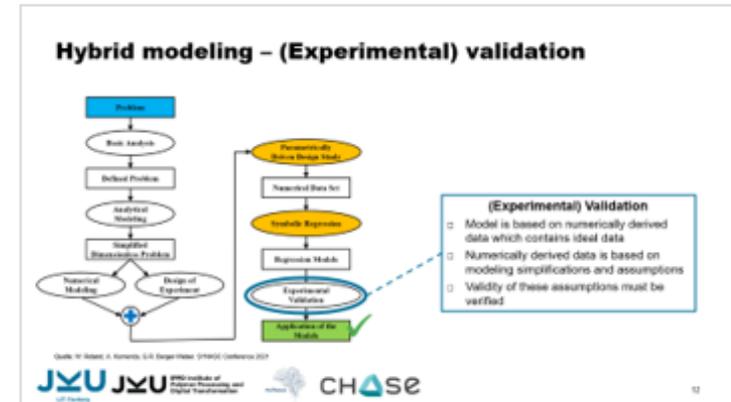
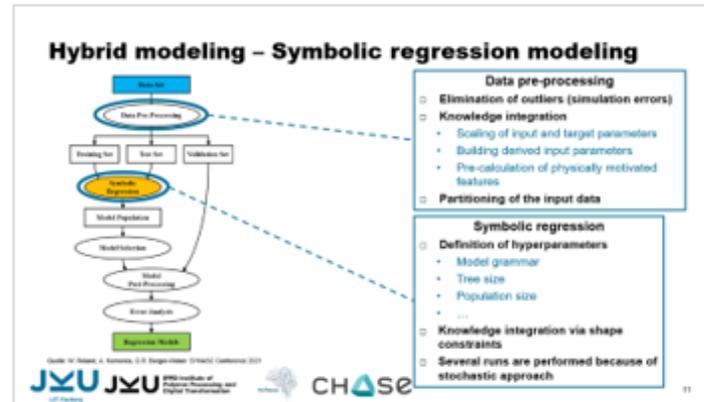
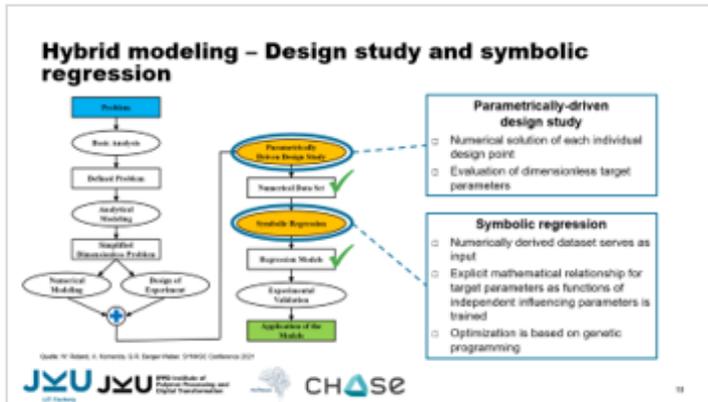
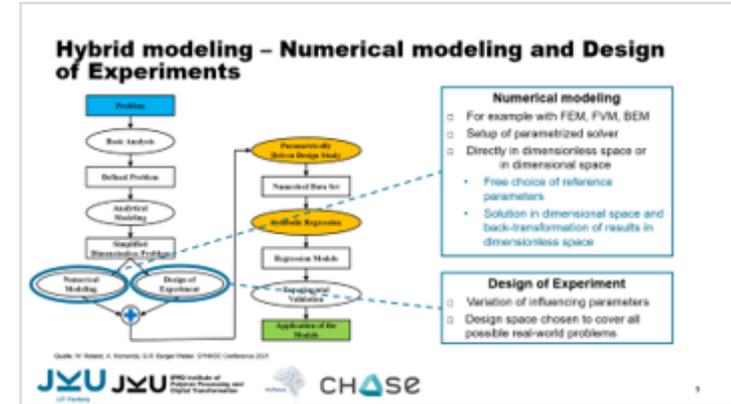
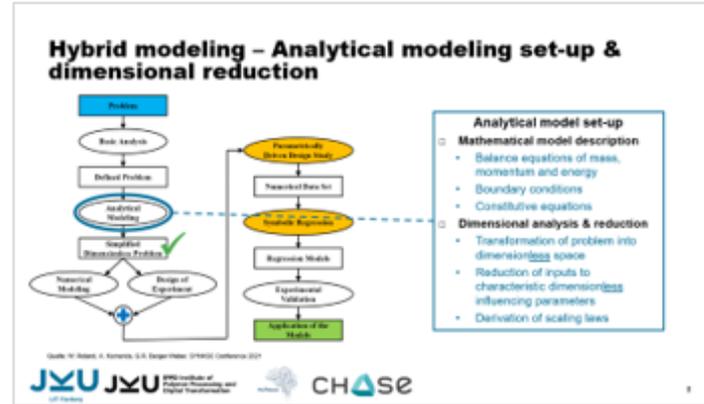
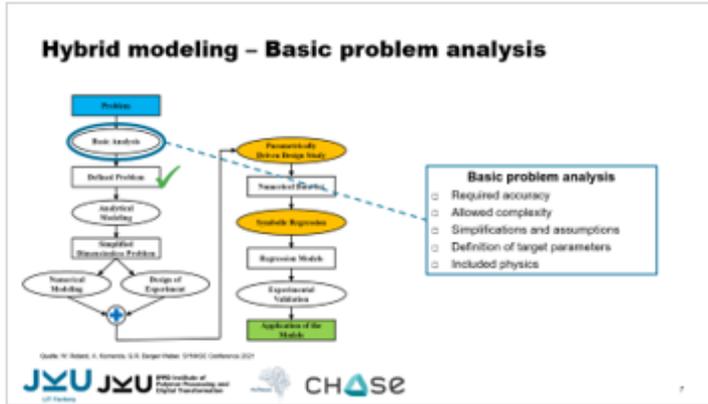
- nicht-linearem Materialverhalten
- komplexen (3D)-Geometrien
- gekoppelten Problemen (z.B. Strömungsfeld und Temperaturfeld)

Sehr genau und verlässlich

Generalisierbar, transferierbar, skalierbar

Quelle: Chr. Marschik, W. Roland, G. Steinbichler. ANTEC Conference 2020

Hybride Modellierung – Ablauf im Detail

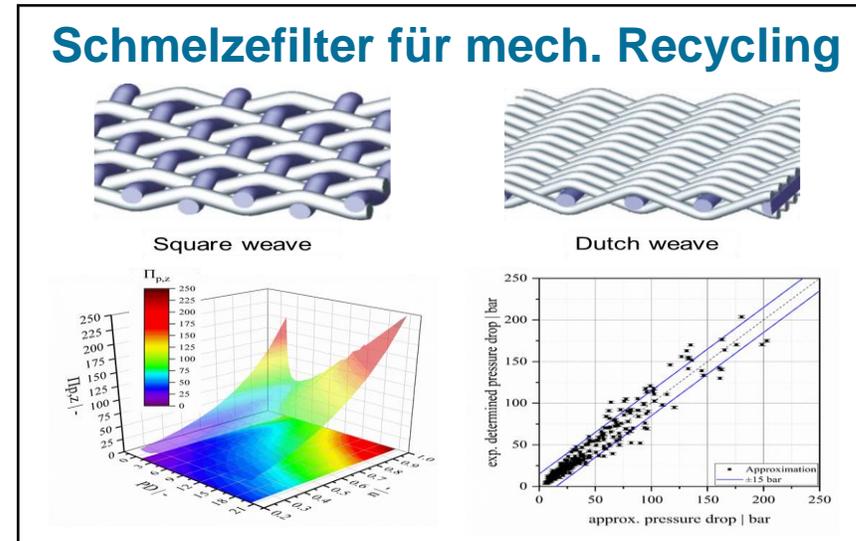
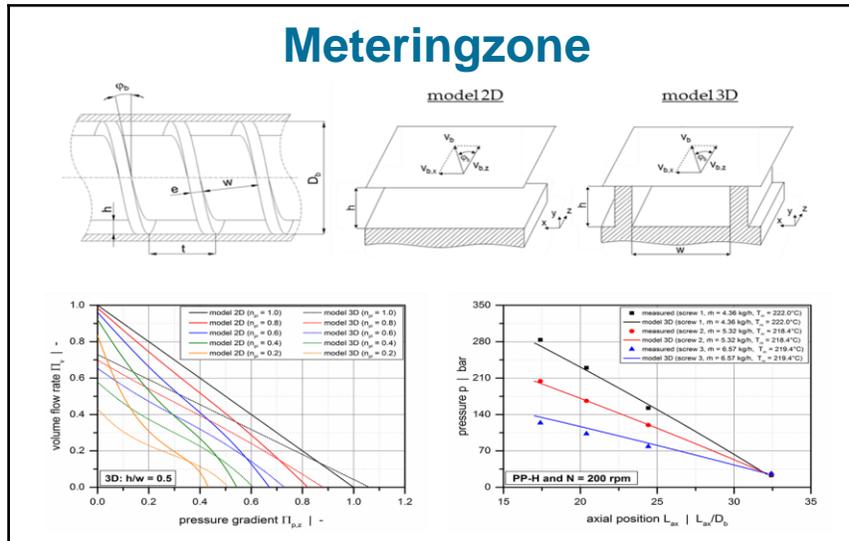


Erfolgsgeheimnis: Expertenwissen + Erfolgreiche Dimensionsreduktion + Große Datensätze!

Quelle: W. Roland, A. Komenda, G.R. Berger-Weber. SYNASC Conference 2021

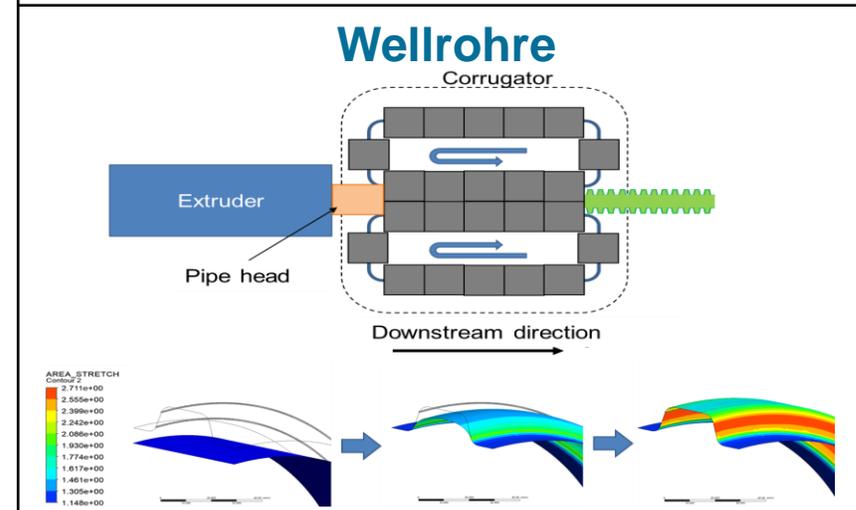
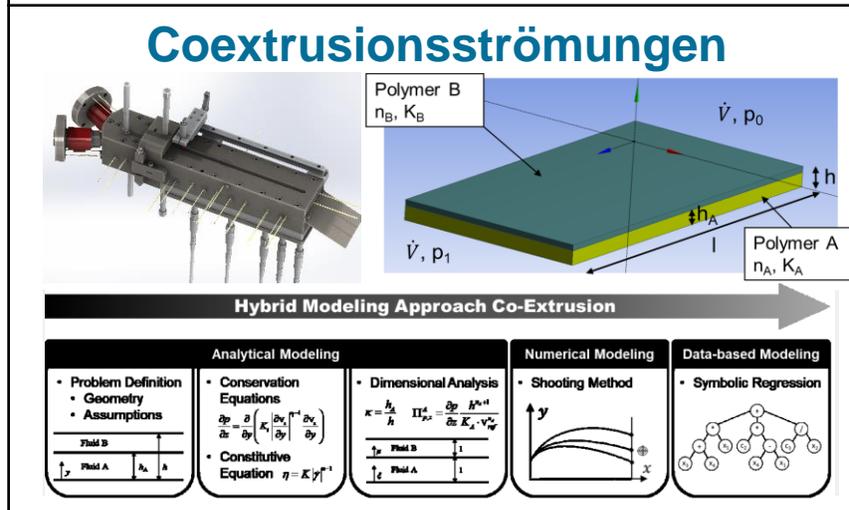
Hybride Modellierung: Ausgewählte Fallbeispiele

Dissertationen
Christian Marschik
Wolfgang Roland



Dissertation
Sophie Pachner

Dissertation
Alexander Hammer



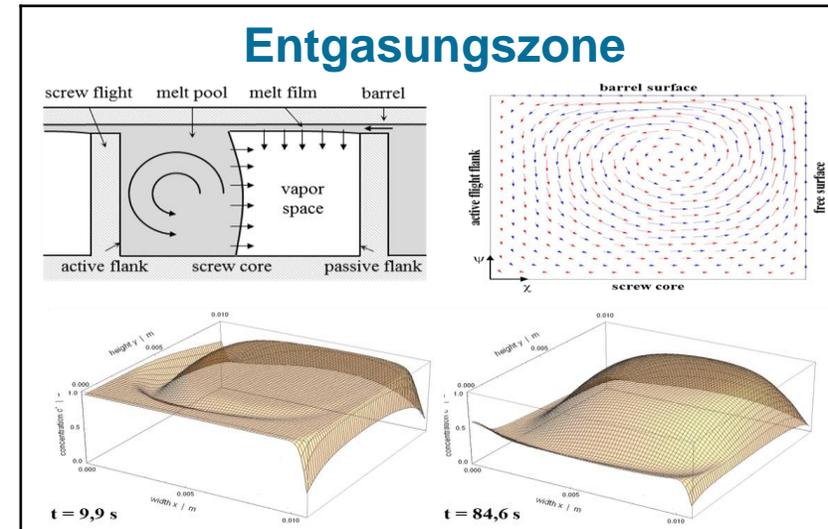
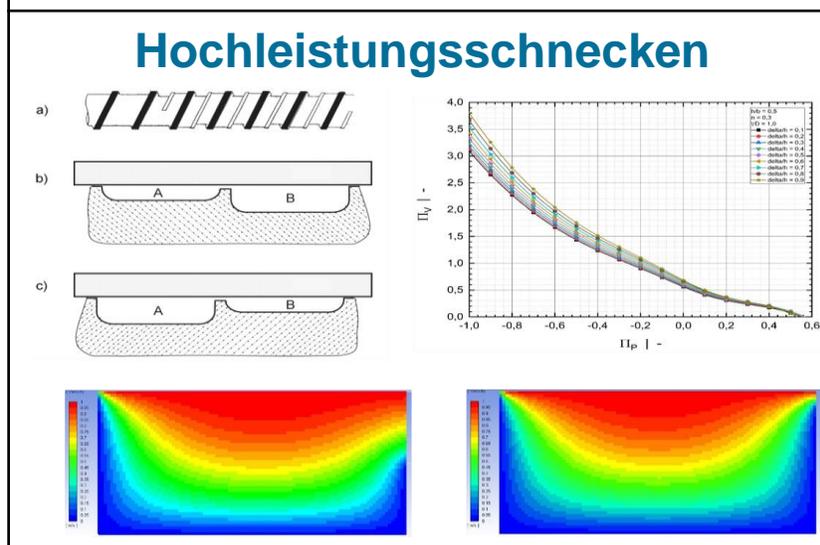
Projektarbeit
Hanny Albrecht

Hybride Modellierung – weitere Fallbeispiele

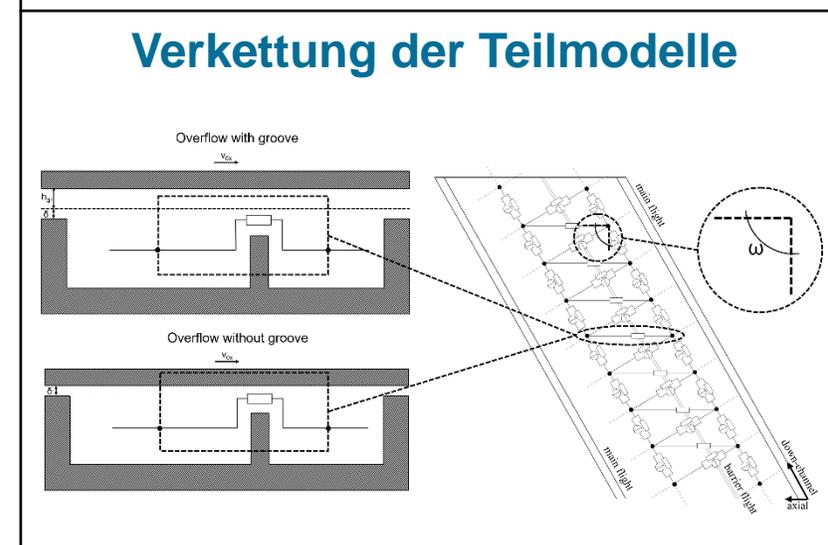
Dissertation
Ursula Stritzinger



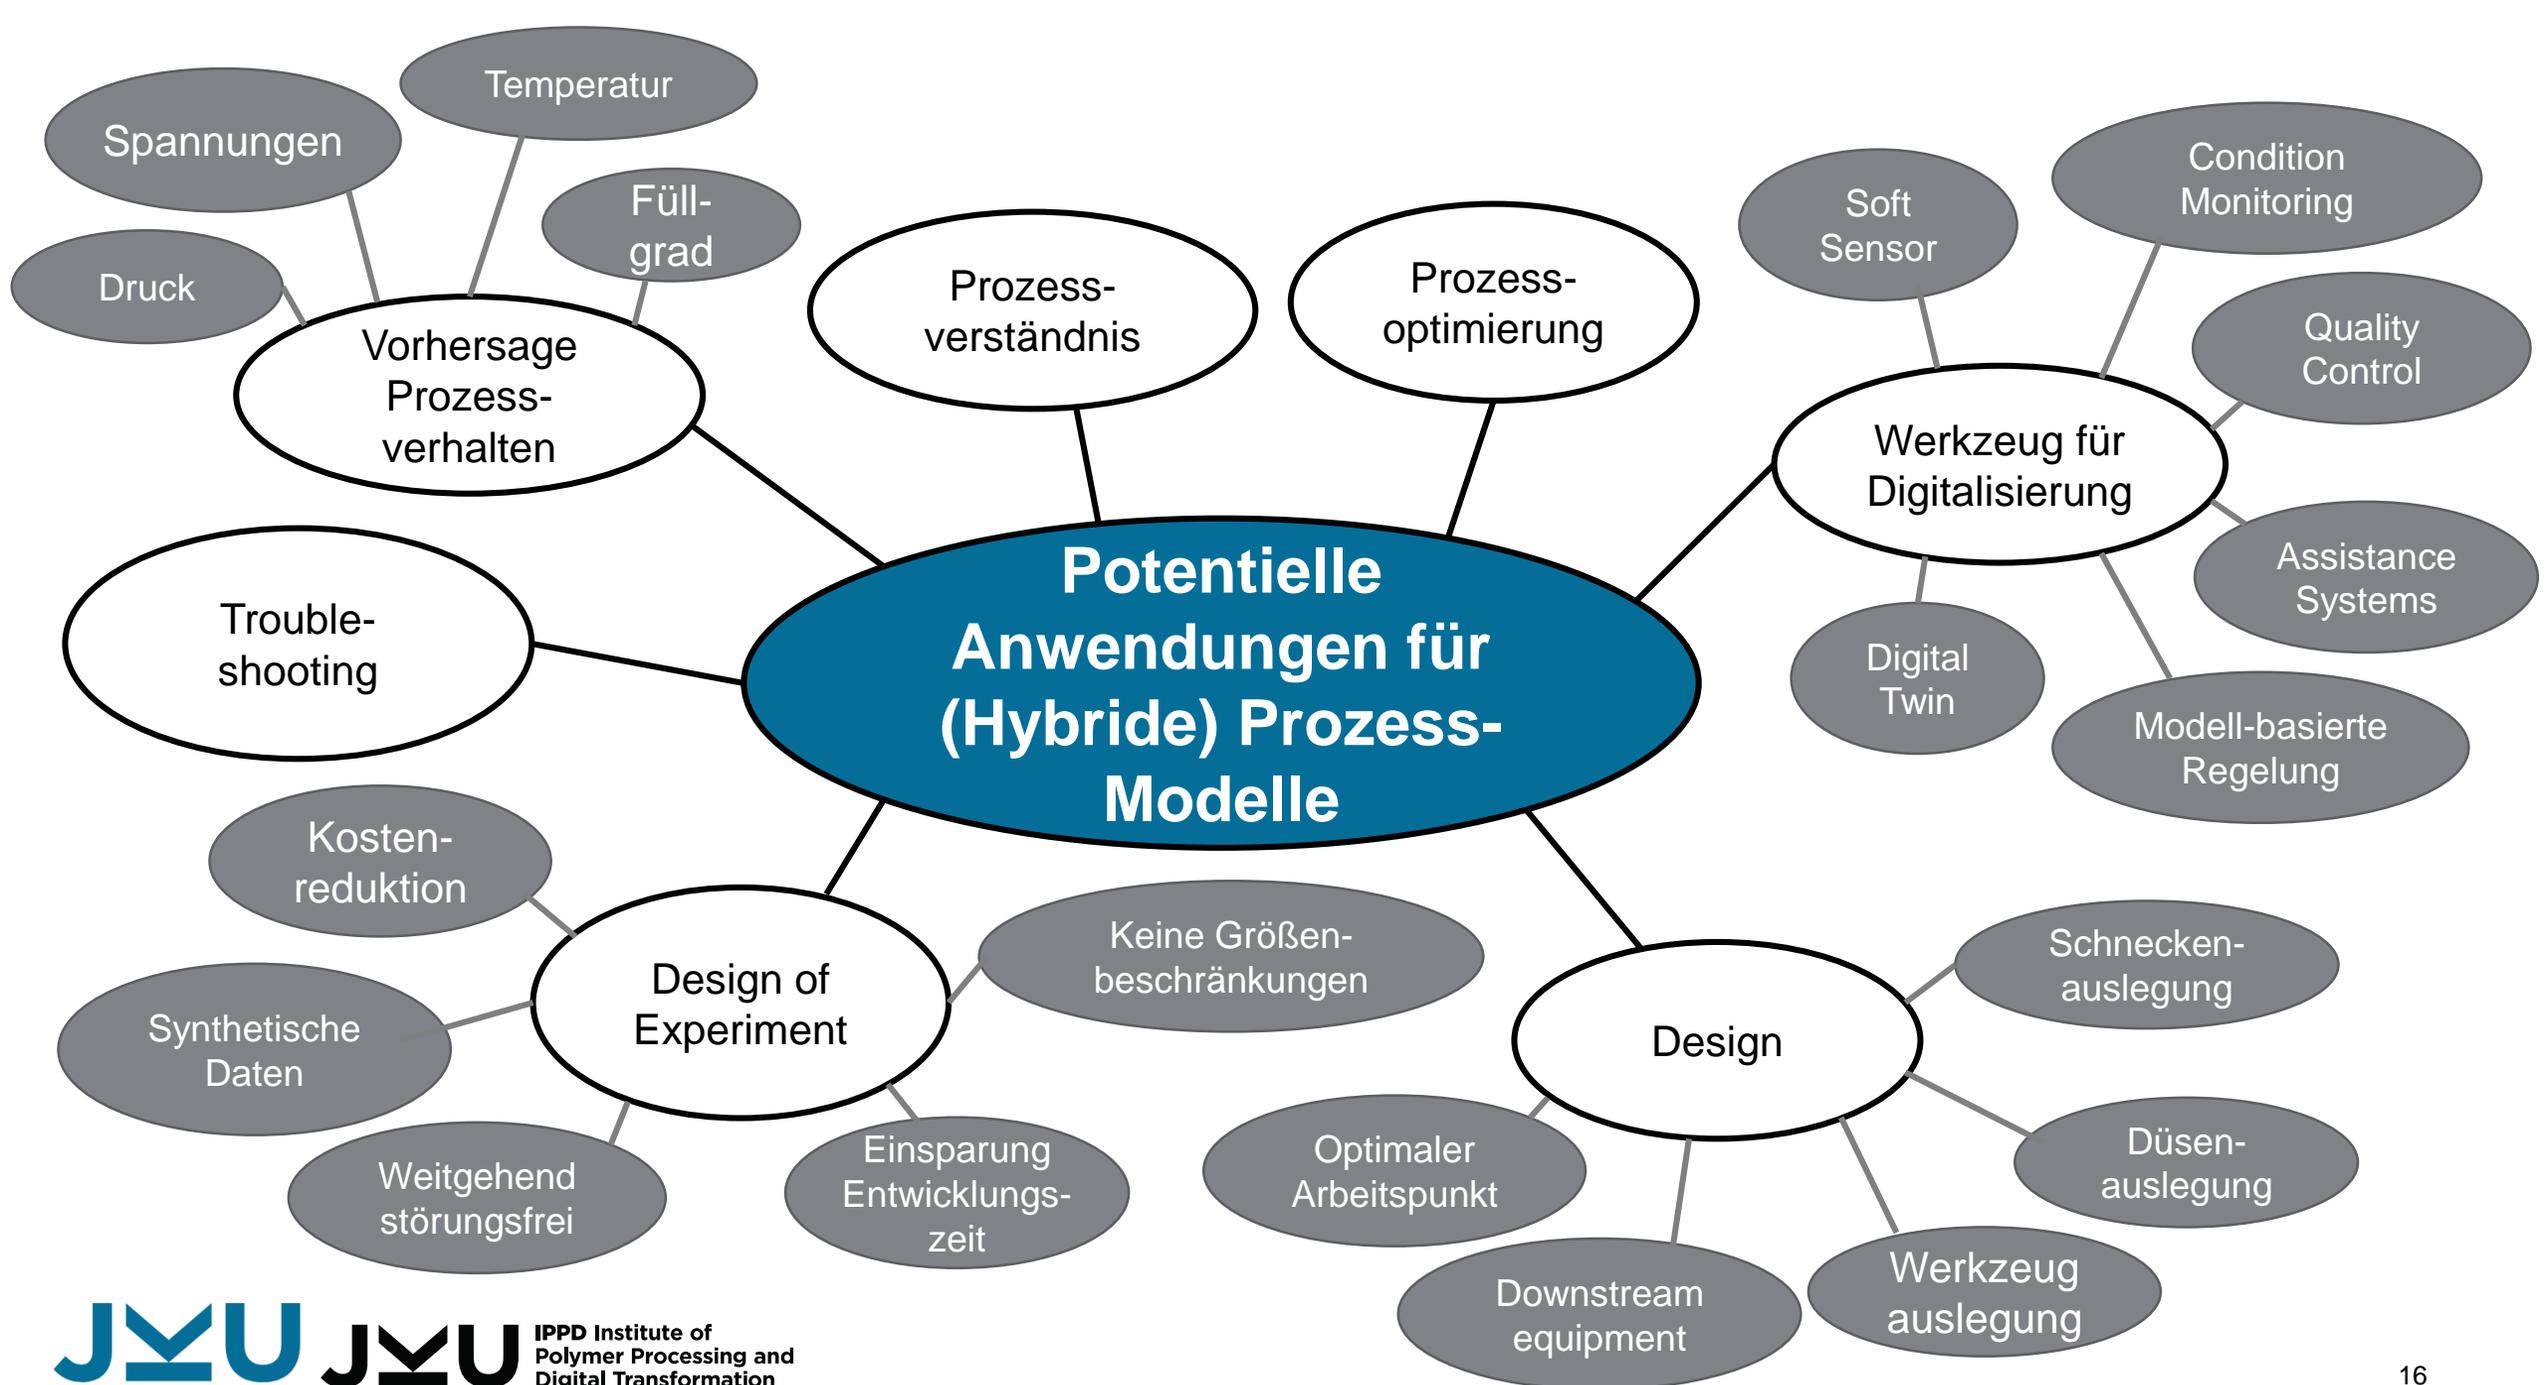
Laufende Dissertation
Daniel Herzog



Dissertation
Nia Chung

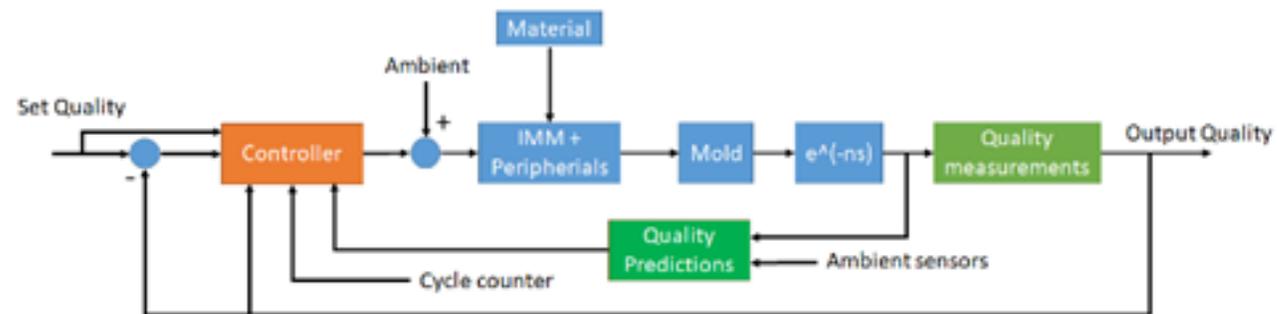


Laufende Dissertation
Maximilian Zacher



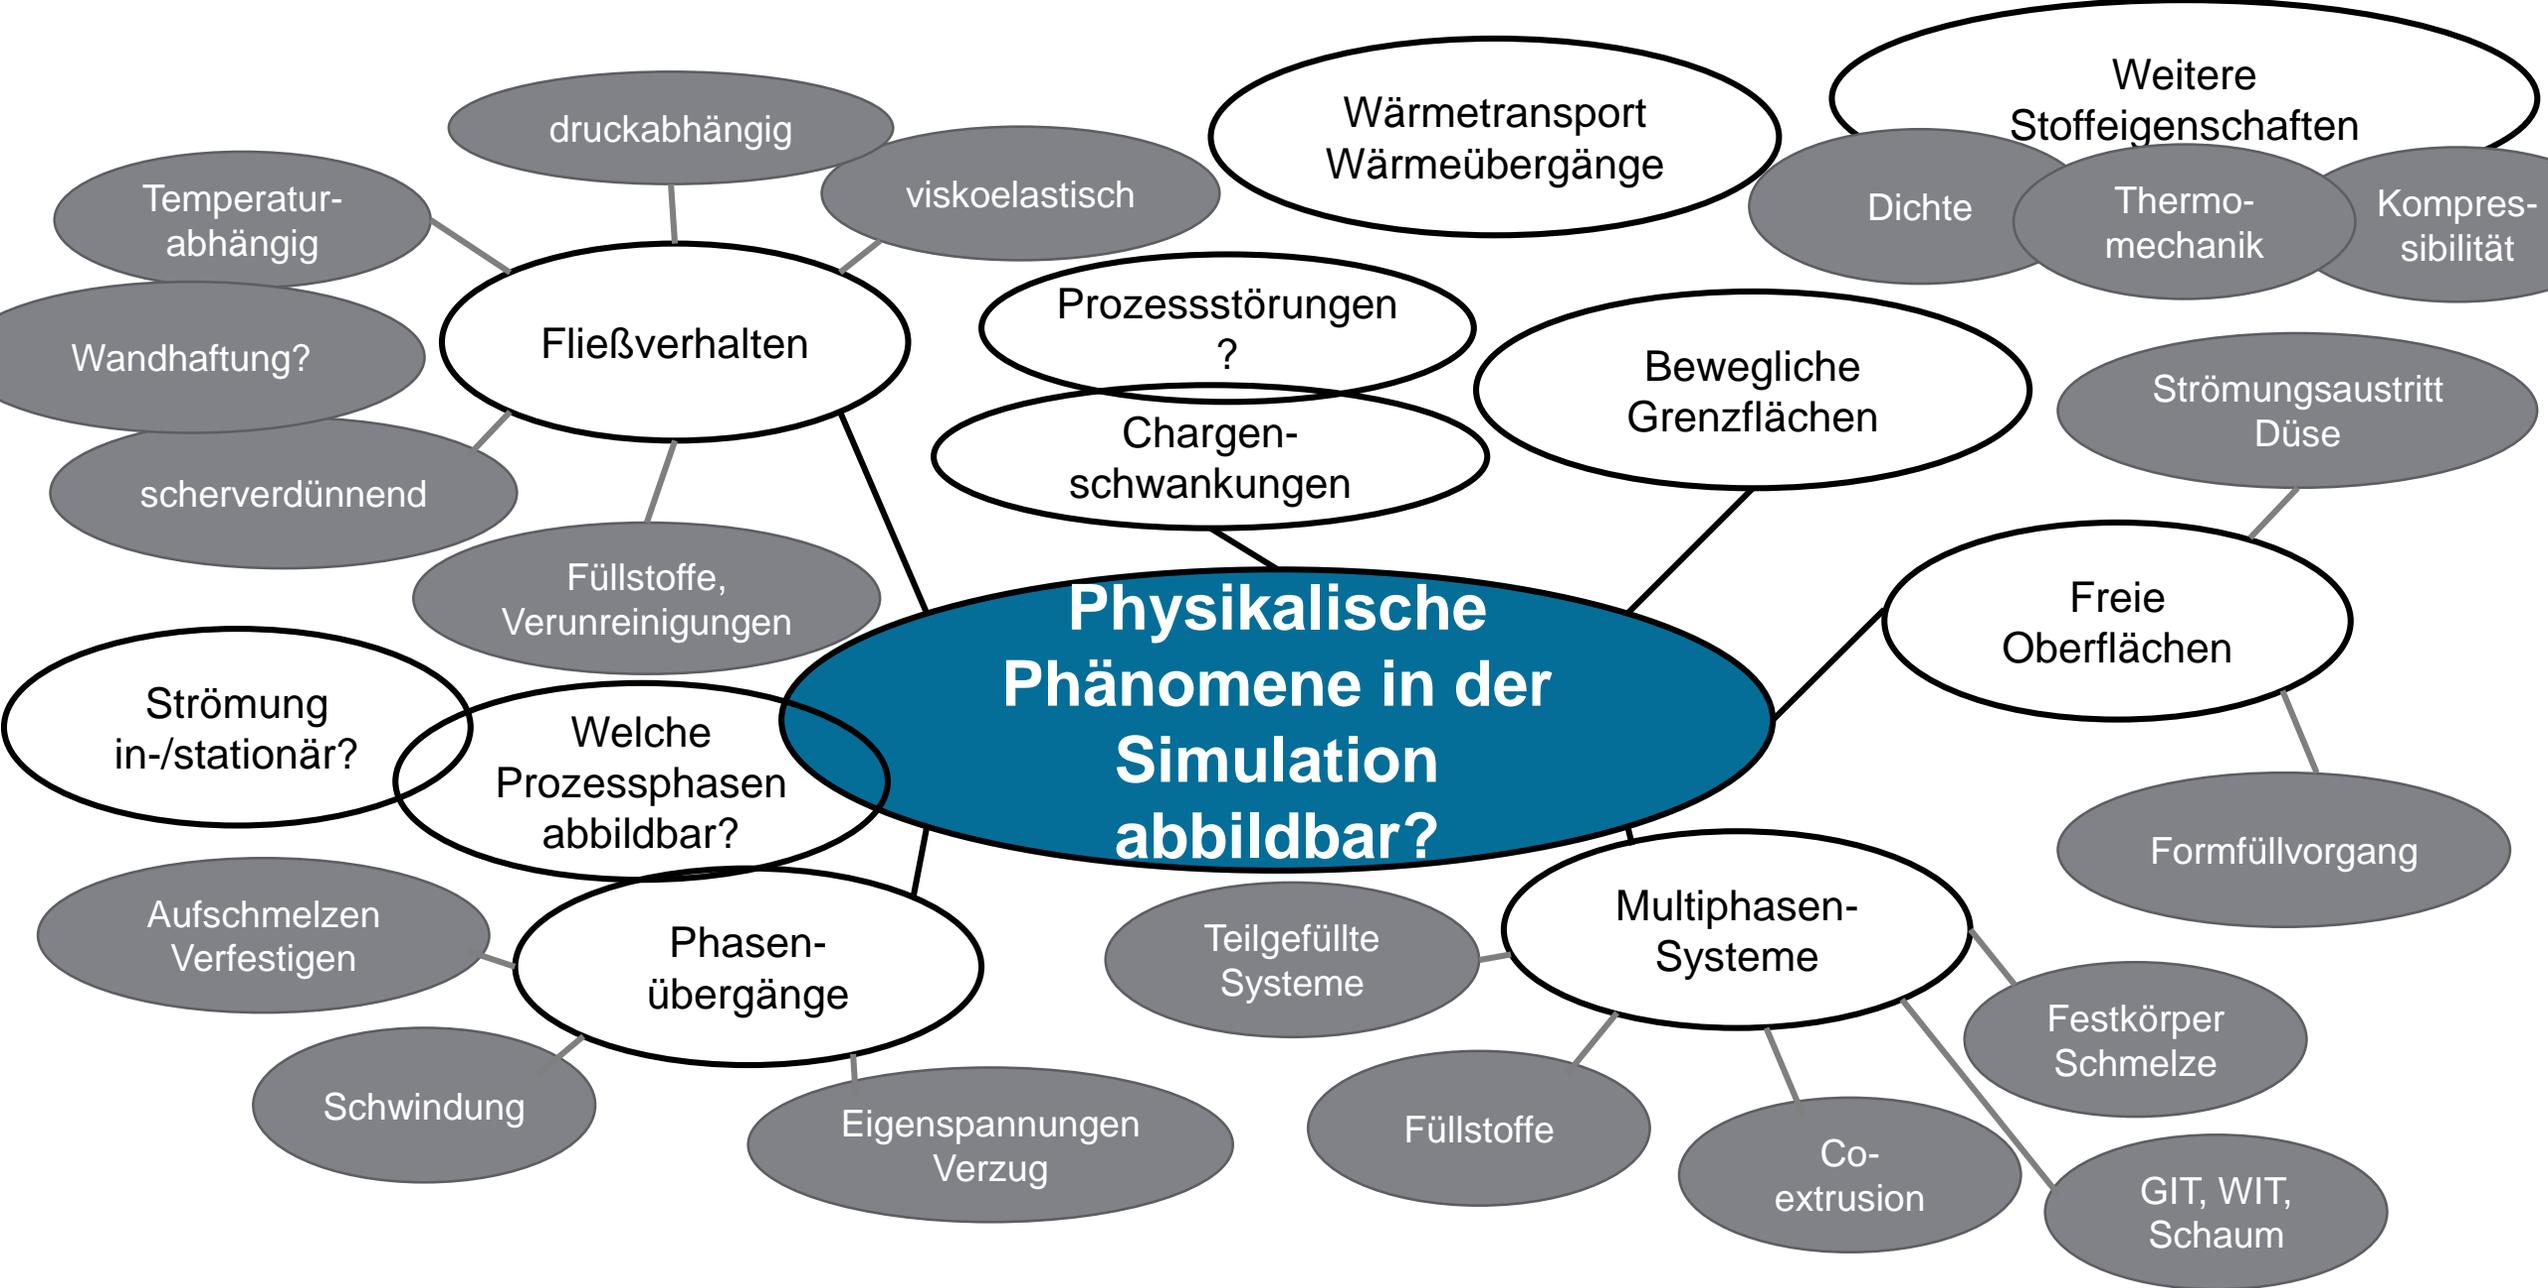
Vision: Hybride (synthetisch datenbasierte) Modelle als Kernstück einer Inline Qualitätsregelung? Für Spritzgießen?

- Verlässliche und genaue Prozessmodelle (Prozesseinstellungen – Prozesszustands (Sensoren) – Produktqualitäts-Beziehungen)
- Inline Monitoring der Prozesskonstanz bzw. –abweichungen
- Regelkreis der Modellbeziehungen kennt, Abweichungen richtig interpretiert und zeitnah und automatisiert eingreifen kann.



Quelle: S.S. Aminabadi, P. Tabatabai, A. Steiner, D.P. Gruber, W. Friesenbichler, Chr. Habersohn, G.R. Berger-Weber. Polymers 2022, 14, 3551. <https://doi.org/10.3390/polym14173551>

- DoE-basierte Spritzgießsimulation für erstes Modelltraining geeignet?



Besondere Herausforderungen bei der Spritzgießsimulation

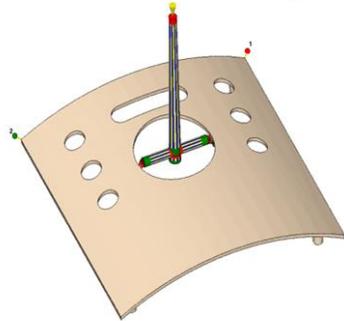
- Diskontinuierlicher Prozess mit mehreren Phasen.
- Instationäre Phänomene: Kopplung Strömung, instationärer Wärmetransport und Strukturmechanik (Abkühlung und Verzug).
- Große Abhängigkeit von der Qualität der Materialdaten und deren Modelle.
- Immense Variantenvielfalt der Bauteildimensionen, der Bauteilgestalt, der Werkstoffe und der Sondertechnologien.
- Oftmals hohe und unterschiedliche Anforderungen an die Bauteilqualität (Dimensionsstabilität, Gewicht, Oberflächenqualität, mechanische Eigenschaften ...).
- ...
- Vielfach noch zu großer Unterschied zwischen Simulationsergebnissen und Realität.

Use Case: Trainingsdatengenerierung mit Spritzgießsimulation

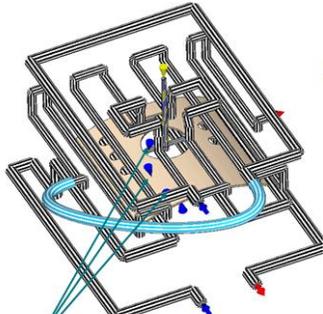
G. Berger-Weber, S. Saeidi Aminabadi. The injection mold as a cyber physical system. Using simulation to train its artificial intelligence. 29th Leoben conference on Polymer Engineering and Science, Leoben, 2021.

Simulation model of part and mold

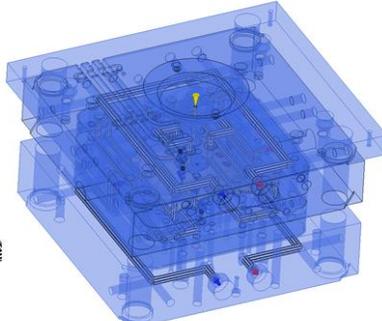
- Part & runner design
- Cooling design
- Mold model



(120mm x 120mm x 25mm)
1-2 Distance „Width-50“



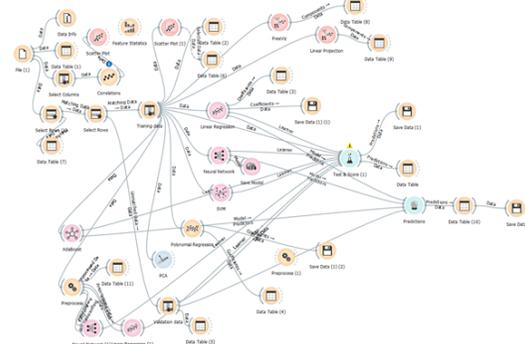
Virtual sensors
 • Melt temperature
 • Viscosity
 • Pressure
 • Shear rate



Full 3D-thermal simulation

Data preprocessing and preparation for model training

- Cadmould saved input and output data in .txt-files.
- Own Excel VBA-code read the files and extracted necessary data.
- Basic statistical analysis in Minitab v18 (error level = 0.05)
- More sophisticated machine learning in Python-based Orange 3 (University of Ljubljana)
 - Support vector machine
 - Neural networks
 - AdaBoost
 - Polynomial regression
 - PCA
- Model build and validation structure in Orange python



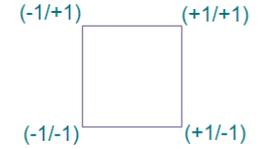
Process parameters and experimental plan

- Process parameters in CCD plan

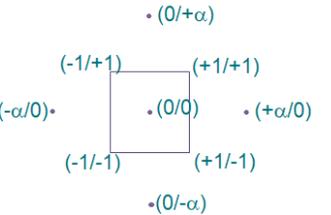
Parameters	Units	(- α) (-1) (0) (+1) (+ α)				
		Lower extreme level	Low level	Center point	High level	Upper extreme level
Melt temperature T_M	°C	230	243	250	257	270
Injection rate v_i	cm ³ /s	10	23	30	37	50
Packing time t_p	s	8	12.5	15	17.5	22
Packing pressure p_h	bar	125	400	550	700	975
Total cooling time t_c	s	23	27.5	30	32.5	37
Coolant temperature 1 T_{v1}	°C	25	38	45	52	65
Coolant temperature 2 T_{v2}	°C	25	38	45	52	65

- Experimental plans

- Narrow window, 2^x



- Broad window, CCCD



- Material
 - ABS Novodur HH112
 - 79 CCD simulation runs
 - 25 random parameter simulations

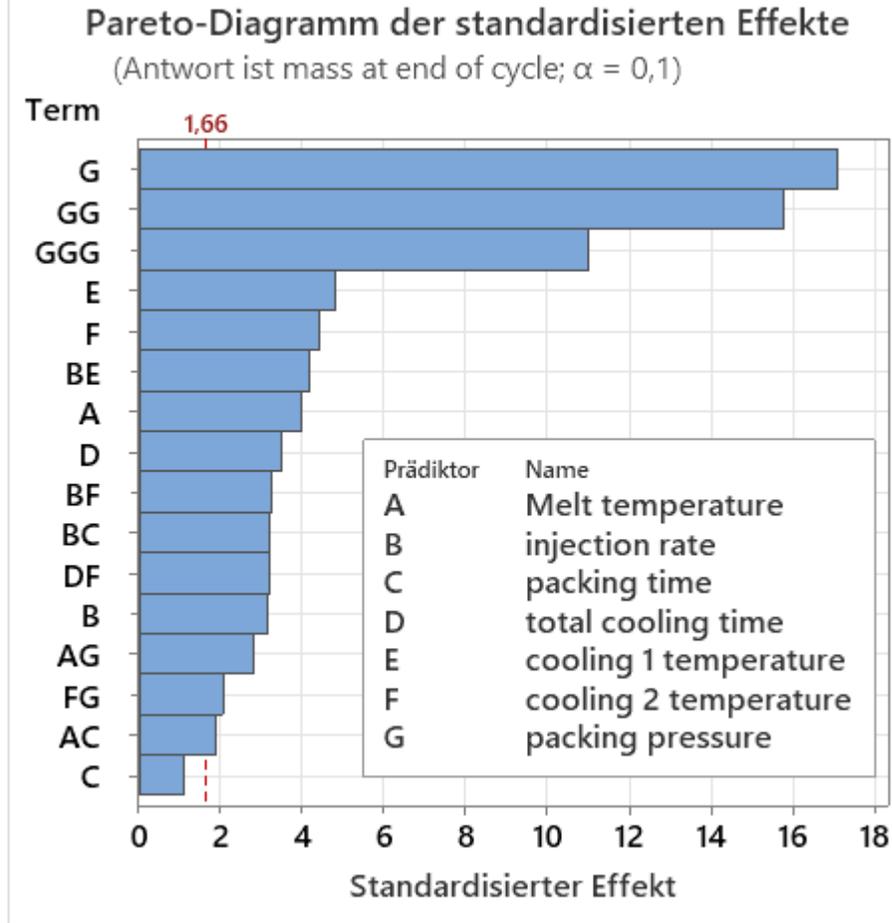
- Quality features
 - 4 distances
 - Mass
 - Maximum clamping force
 - Maximum deformation
 - Maximum warpage
 - Mean of shrinkage

Model quality for validation cycles (machine learning algorithms)

- Model validation determines the ability of a trained model to foresee unknown data
- Modelling algorithms
 - Artificial neural network multi-layer perceptron (MLP) algorithm with backpropagation
 - Metrics MAE = 0,017mm (0,015%)
 - Support vector machine (SVM)
 - Adaptive Boosting
 - Linear lasso regression

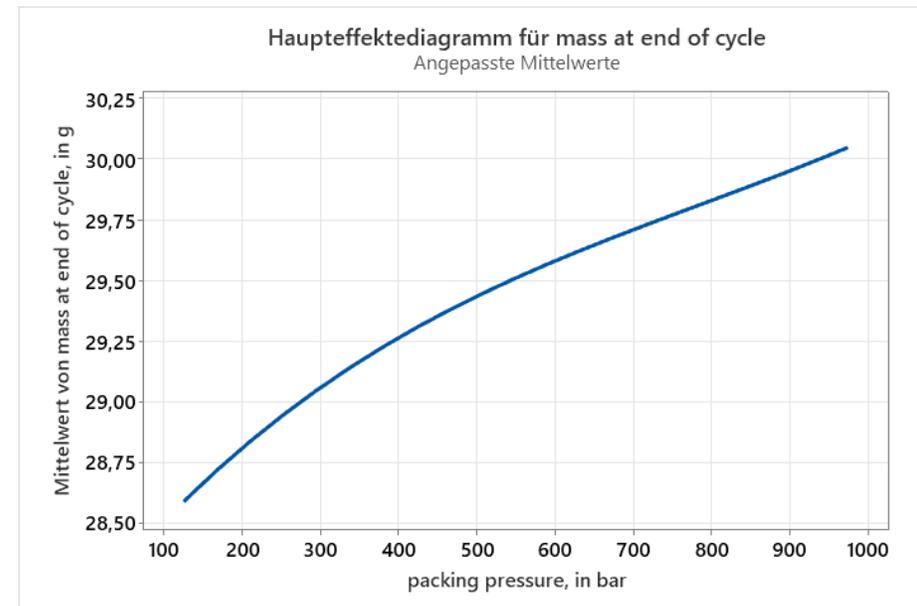
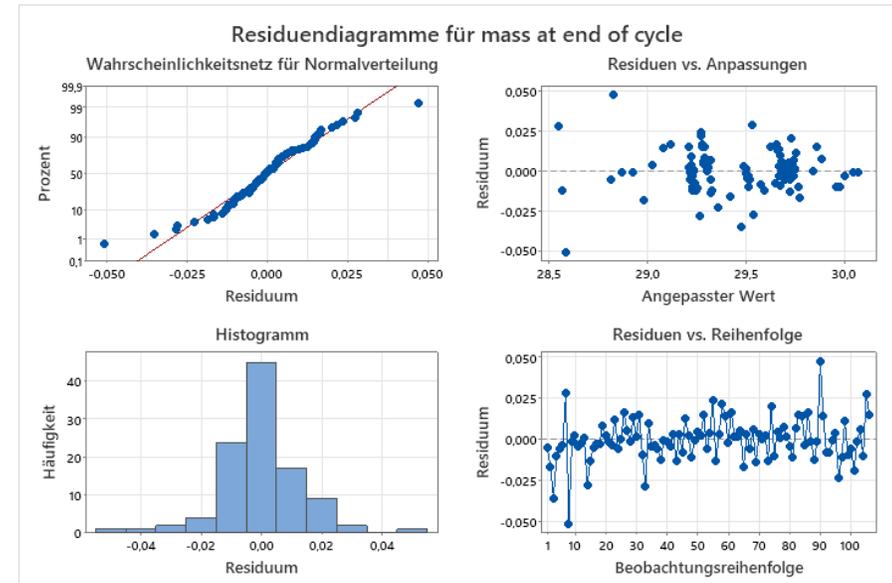
Process settings						Simulation		Neural network		SVM		AdaBoost		Linear Lasso regression	
T_M	v_i	t_p	p_h	T_{v1}	T_{v2}	Width-50 (mm)	Pre (mm)	r.e. (%)	Pre (mm)	r.e. (%)	Pre (mm)	r.e. (%)	Pre (mm)	r.e. (%)	
241	43	8	145	25	31	60	118.435	118.400	0.030	118.449	0.012	118.545	0.093	118.331	0.088
231	46	18	148	30	62	53	118.518	118.480	0.032	118.676	0.134	118.914	0.334	118.651	0.113
256	16	20	172	26	56	40	118.583	118.553	0.025	118.668	0.072	118.483	0.084	118.648	0.055
242	14	19	182	25	30	32	118.467	118.434	0.028	118.468	0.001	118.545	0.066	118.396	0.060
264	32	10	255	25	35	30	118.531	118.548	0.014	118.555	0.021	118.619	0.075	118.513	0.015
243	30	9	269	31	45	43	118.582	118.595	0.011	118.622	0.034	118.722	0.118	118.592	0.009
230	40	22	272	31	33	33	118.512	118.510	0.001	118.519	0.006	118.625	0.095	118.479	0.028
262	29	20	280	26	48	64	118.587	118.613	0.022	118.626	0.033	118.713	0.107	118.591	0.004
235	33	22	301	27	54	60	118.600	118.610	0.009	118.659	0.050	118.687	0.074	118.636	0.031
233	23	17	379	29	65	59	118.716	118.732	0.013	118.760	0.038	118.914	0.167	118.791	0.054
262	20	12	380	24	65	33	118.809	118.805	0.004	118.812	0.002	118.914	0.088	118.855	0.038
257	19	18	404	33	45	60	118.682	118.681	0.001	118.682	0.000	118.730	0.041	118.660	0.018
251	31	9	409	34	55	59	118.737	118.739	0.002	118.771	0.029	118.705	0.026	118.756	0.016
241	38	10	418	23	25	42	118.484	118.449	0.030	118.541	0.048	118.545	0.051	118.442	0.036
268	19	8	432	29	55	27	118.807	118.812	0.005	118.813	0.006	118.750	0.048	118.823	0.018
264	18	606	23	55	61	118.778	118.822	0.037	118.870	0.077	118.713	0.055	118.824	0.038	
244	44	10	617	23	50	30	118.790	118.794	0.004	118.853	0.053	118.700	0.078	118.811	0.019
244	50	13	776	23	29	61	118.515	118.513	0.002	118.719	0.173	118.711	0.165	118.585	0.059
244	16	19	728	27	50	45	118.874	118.865	0.007	118.914	0.034	118.886	0.011	118.863	0.009
263	46	16	794	24	44	48	118.846	118.855	0.008	118.910	0.054	118.880	0.029	118.848	0.002
259	36	17	809	24	52	32	118.831	118.832	0.000	118.897	0.055	118.740	0.078	118.847	0.013
257	46	10	820	25	25	45	118.606	118.580	0.022	118.806	0.169	118.711	0.089	118.675	0.059
254	26	21	860	25	33	60	118.685	118.700	0.012	118.834	0.126	118.712	0.022	118.746	0.051
256	12	18	866	34	55	118.755	118.734	0.018	118.853	0.083	118.717	0.032	118.785	0.025	
264	13	19	923	31	48	54	119.046	119.046	0.048	118.997	0.091	119.075	0.025	118.974	0.109
255	18	9	945	36	50	40	119.164	119.162	0.002	119.048	0.097	119.075	0.075	119.040	0.104
Mean absolute error						0.017	0.015	0.058	0.058	0.097	0.082	0.049	0.041		
Maximum error						0.058	0.048	0.205	0.173	0.396	0.334	0.133	0.113		

Use Case: Nichtlineares Regressionsmodell bis 3. Ordnung

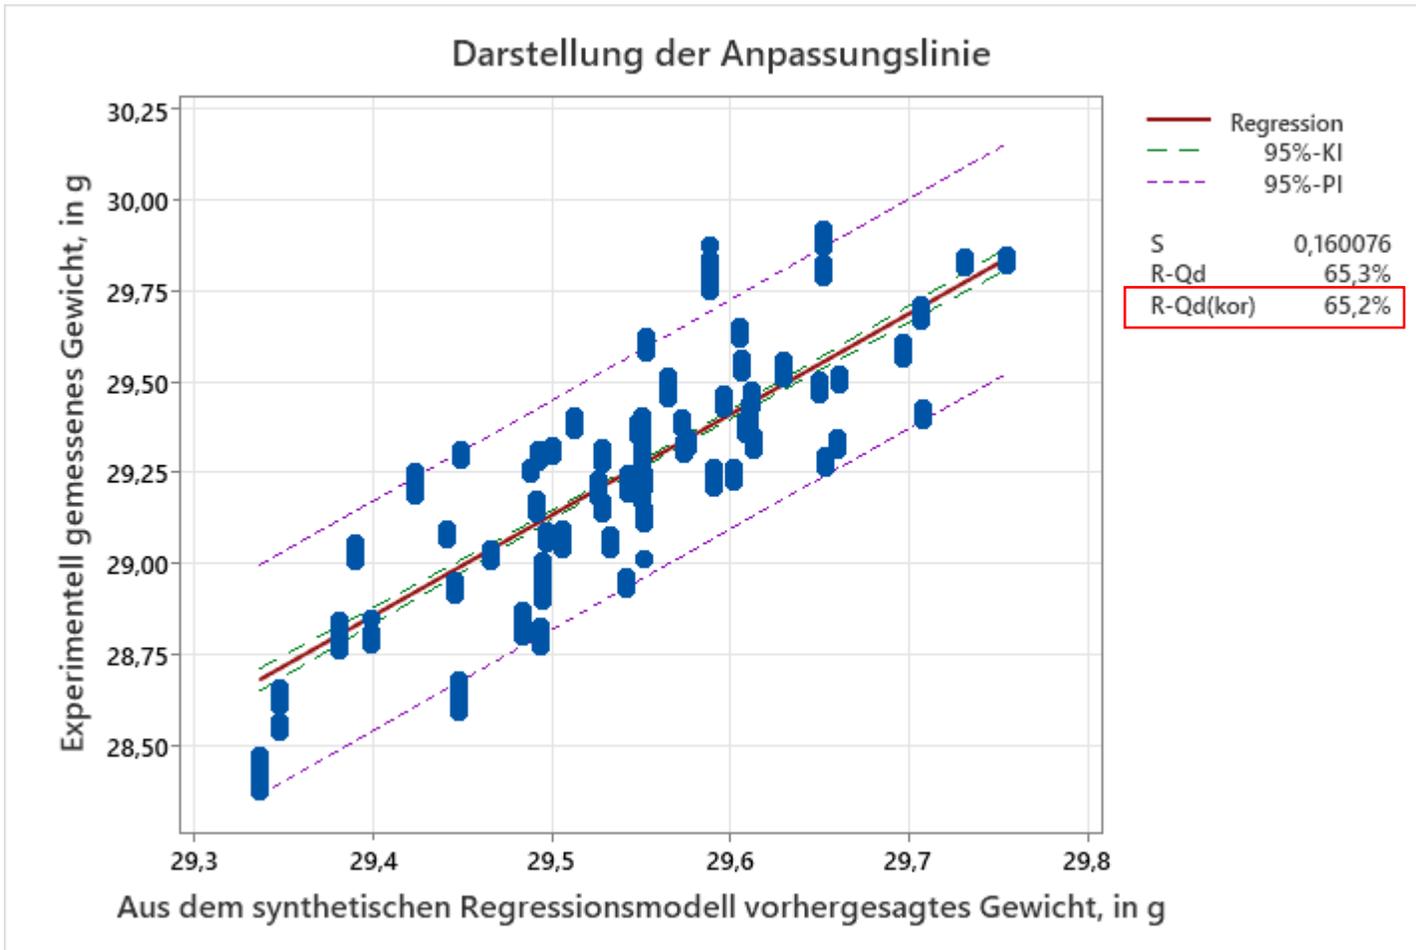


Training set = 80

S	R-Qd	R-Qd(kor)	R-Qd(prog)	Faltungen	Faltungen
0,0142293	99,82%	99,79%	99,65%	0,0188280	99,63%



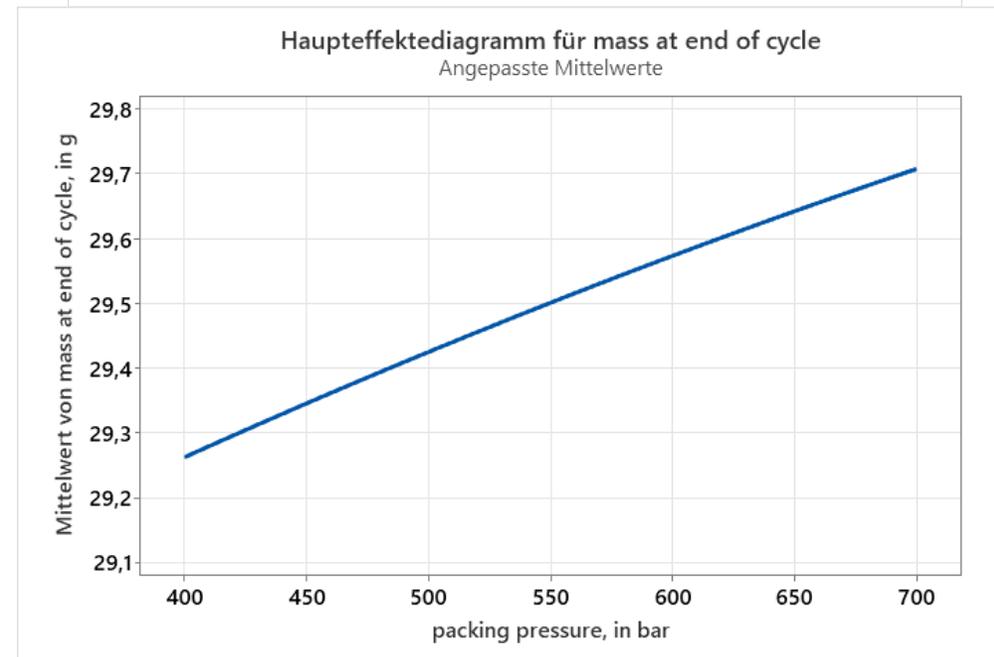
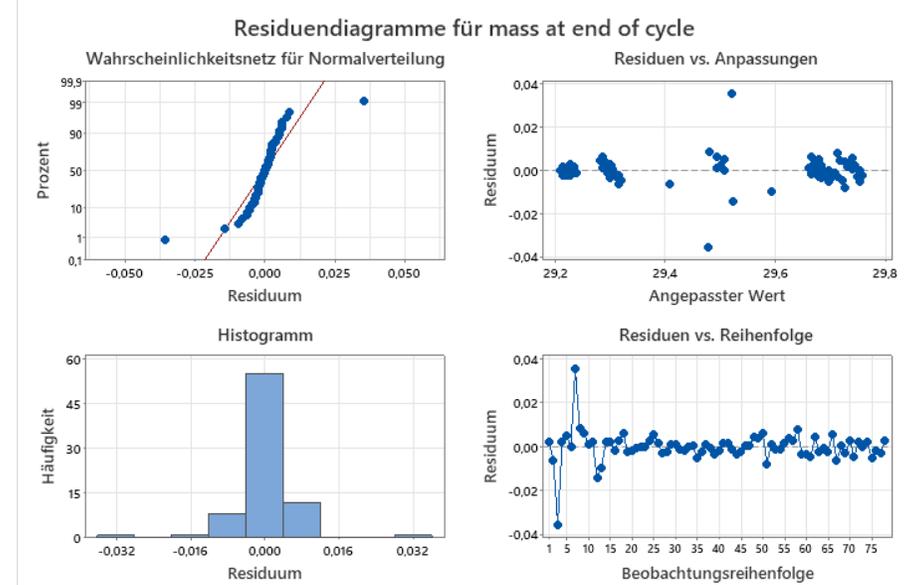
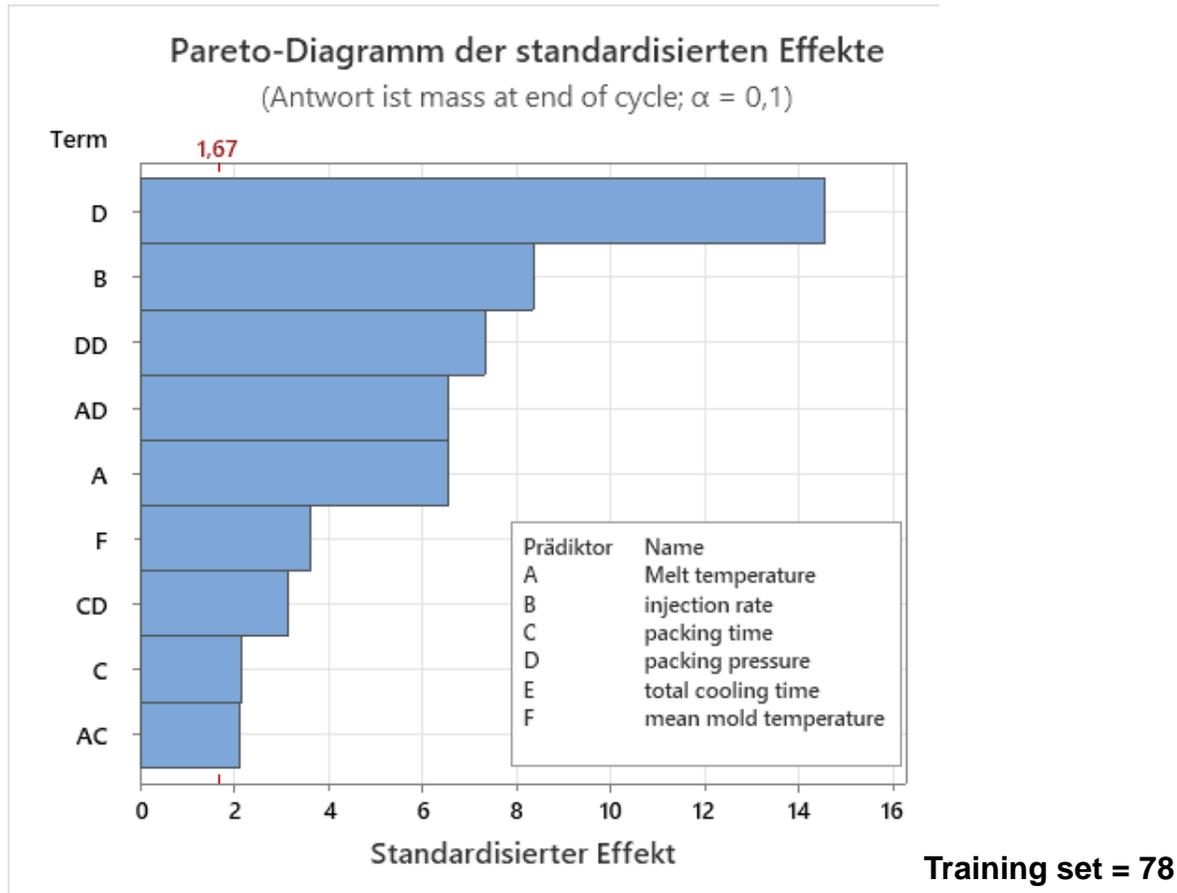
Use Case: Wie gut sagt das synthetische (simulations-trainierte) Modell die Realität voraus? Komplexes Modell 3.Ordnung



Potentielle Ursachen für Abweichung:

- Schwache Stoffdaten (pvT, Additive)
- Zu starke Vereinfachungen in der Simulation
- Zu kleiner Trainingsdatensatz, fehlende Einflussgrößen, unerkannte Prozessstörungen
- „verbogenes“ oder überbestimmtes Regressionsmodell
- Unterschiedliche Prozessfenster, d.h. unzulässige Extrapolation ($T_{W,0,sim} = 45^{\circ}\text{C}$ $T_{W,0,real} = 94^{\circ}\text{C}$...)
- ~~Falsche automatisiert eingestellte Prozesseinstellungen~~
- ... noch eine weite Reise!

Use Case: Vereinfachtes Regressionsmodell bis 2. Ordnung

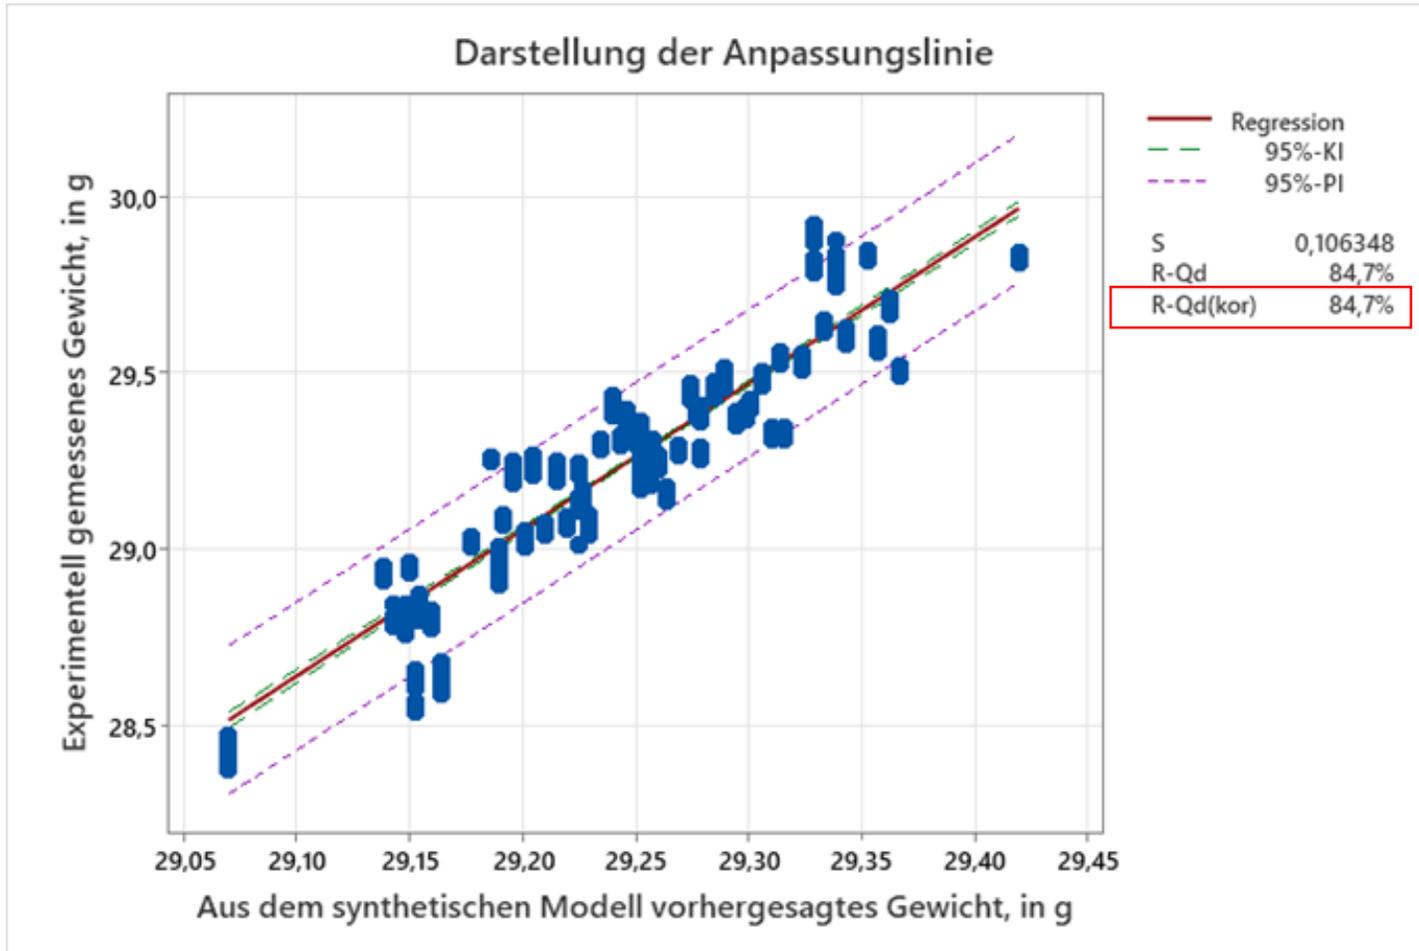


S für 10 R-Qd für 10

S	R-Qd	R-Qd(kor)	R-Qd(prog)	Faltungen	Faltungen
0,0073555	99,89%	99,87%	99,84%	0,0085590	99,82%

Use Case: Wie gut sagt das synthetische (simulations-trainierte) Modell die Realität voraus?

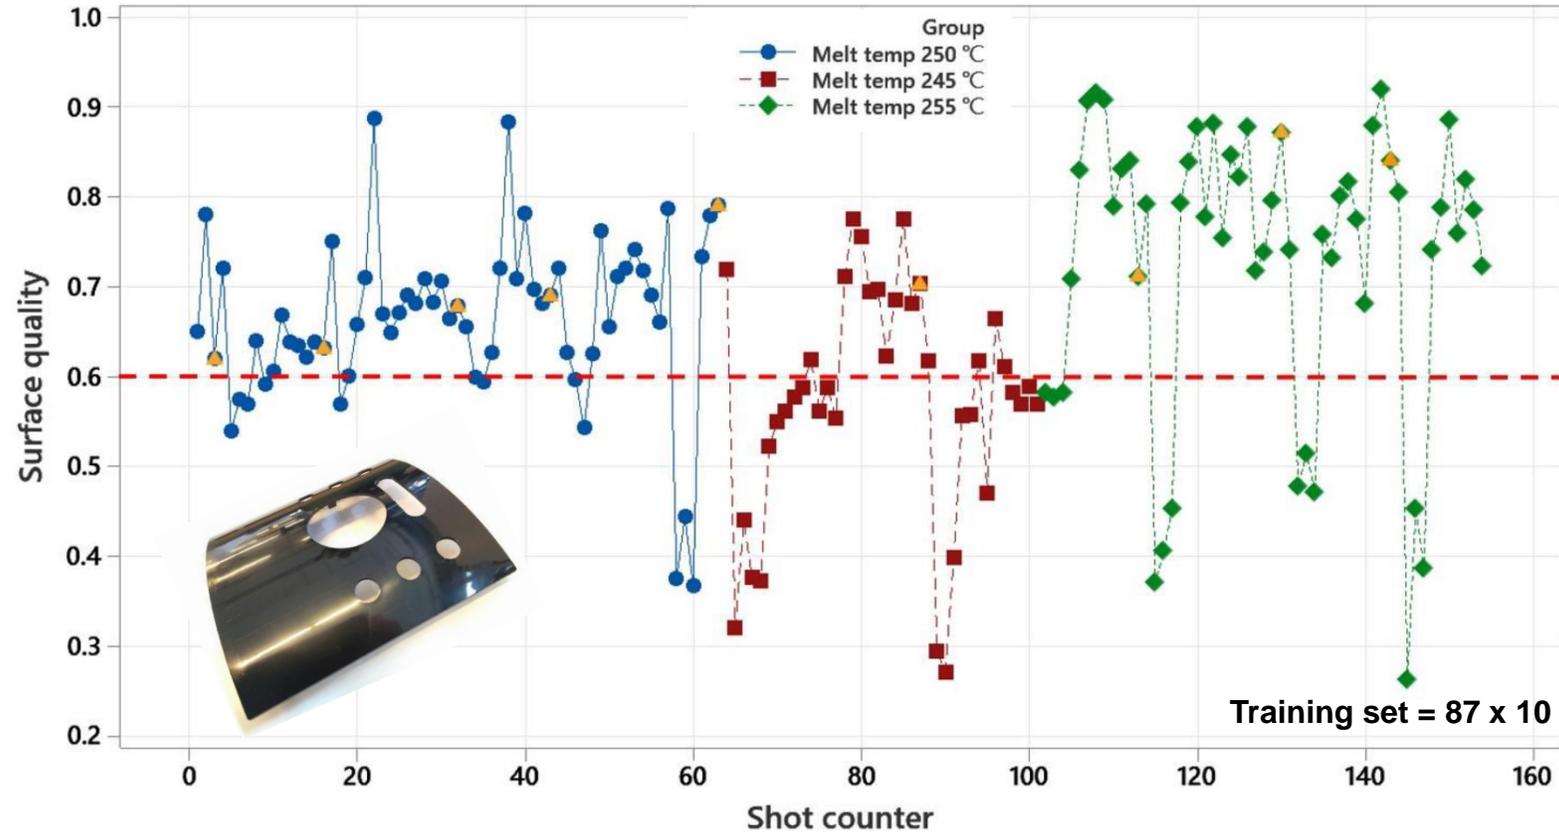
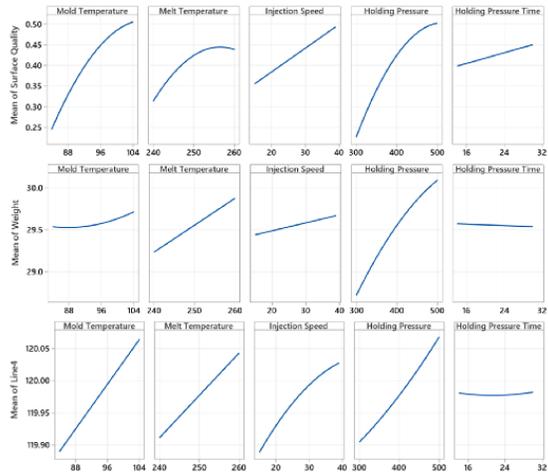
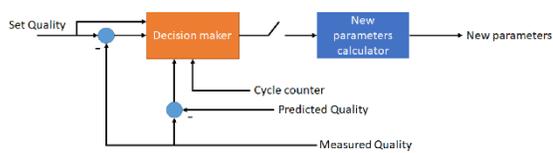
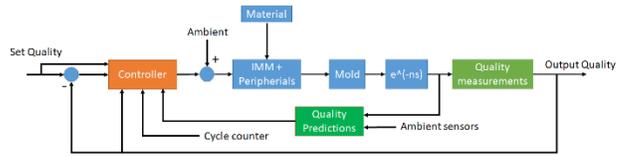
Einfaches Modell



Ein einfaches Regressionsmodell mit erfahrungsbasierten Modelltermen erreicht eine passable Modellgüte, aber:

- Natürliche Prozessstreuung ist nicht abgebildet.
- pVT-Verhalten scheint nicht richtig abgebildet zu sein.
- Maschineneinstellungen alleine reichen nicht aus für eine gute Modellvorhersage.

Use Case: Experiment-Datenbasierte Inline Regelung der Oberflächenqualität



Quelle: S.S. Aminabadi, P. Tabatabai, A. Steiner, D.P. Gruber, W. Friesenbichler, Chr. Habersohn, G.R. Berger-Weber. Polymers 2022, 14, 3551. <https://doi.org/10.3390/polym14173551>

Projekt
INQCIM
2019 - 2021

FFG
Forschung wirkt.

**KUNSTSTOFF
TECHNIK
LEOBEN**
SPRITZGIESSEN VON
KUNSTSTOFFEN

PCCL
Polymer Competence Center Leoben

IFT
Ein Institut der TU
Graz

Wilmann **Botzenfeld**

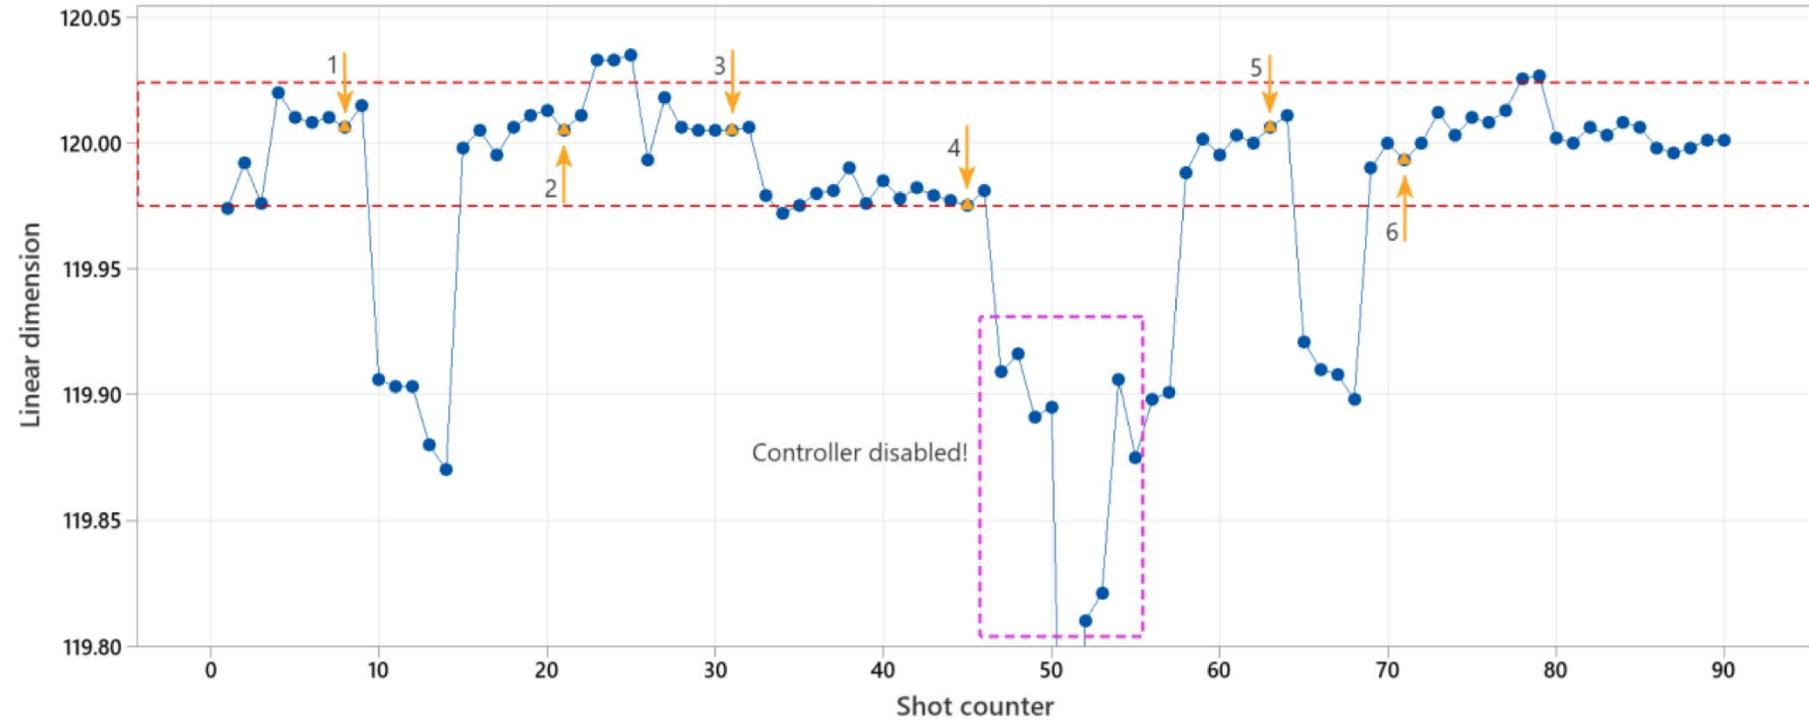
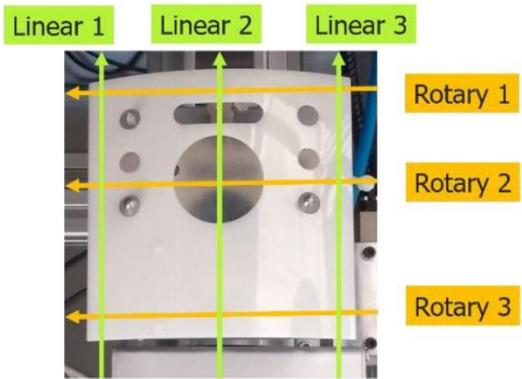
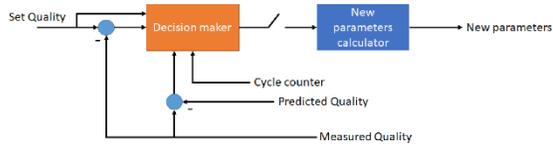
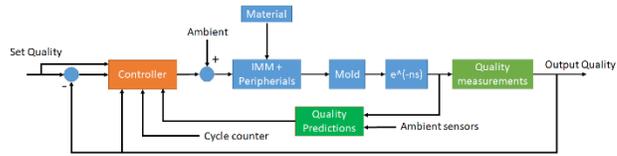
míraplast

DRAXLMAIER

blum

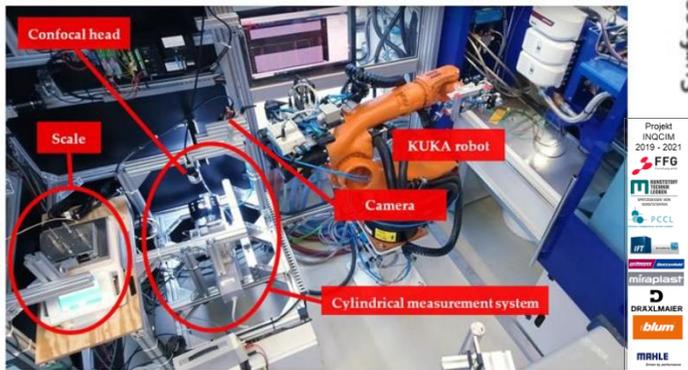
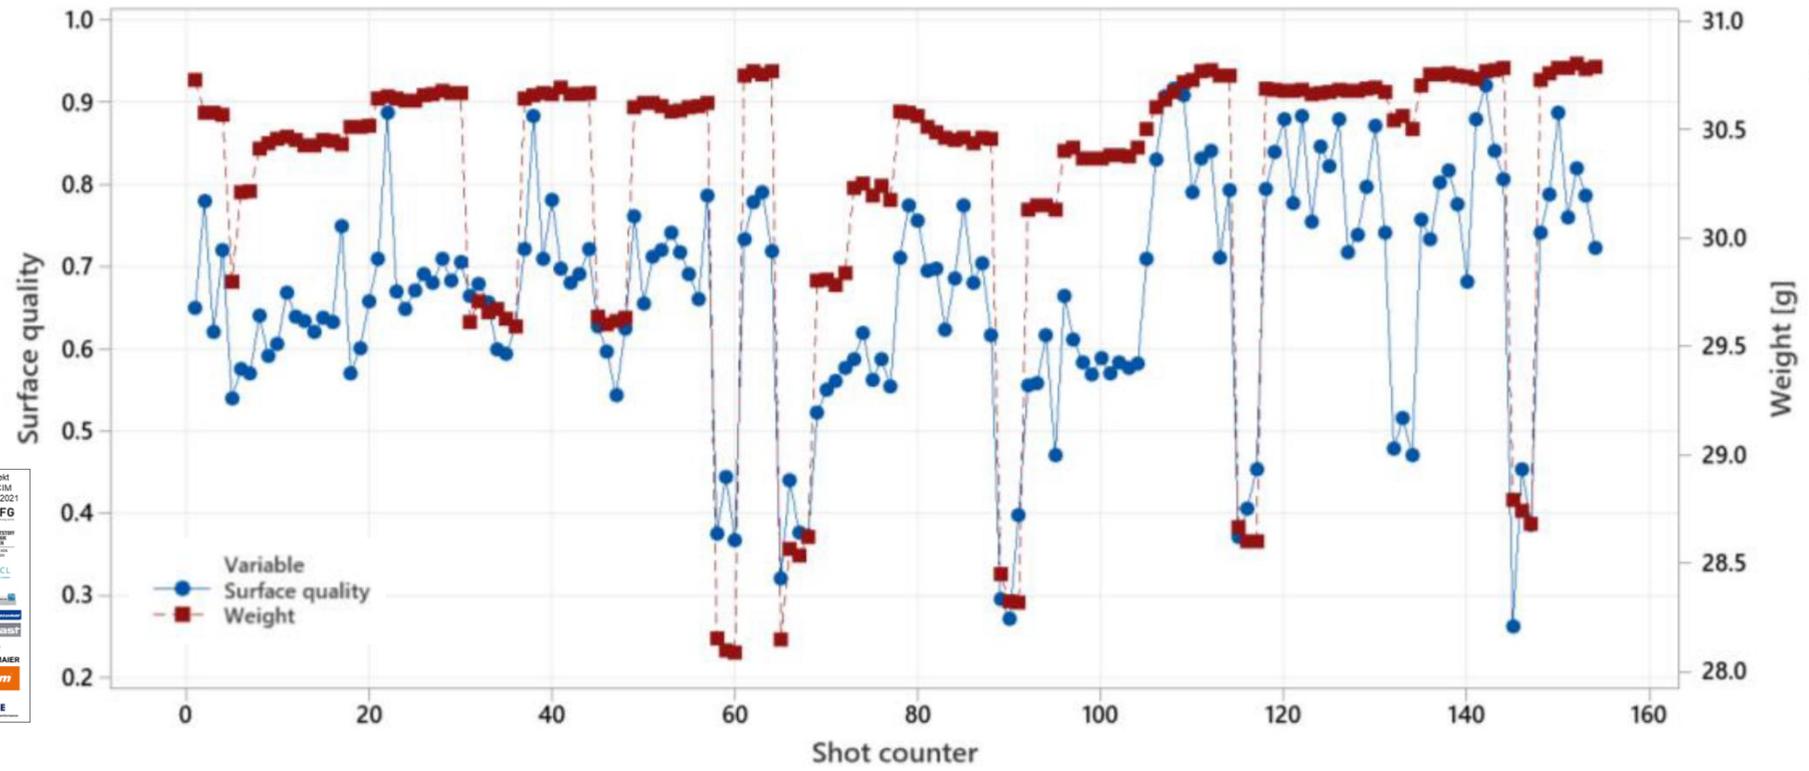
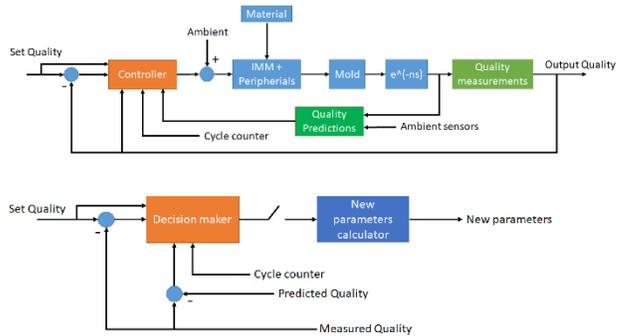
MAHLE
Driven by performance

Use Case: Experiment-Datenbasierte Inline Regelung der Bauteildimension



Quelle: S.S. Aminabadi, P. Tabatabai, A. Steiner, D.P. Gruber, W. Friesenbichler, Chr. Habersohn, G.R. Berger-Weber. Polymers 2022, 14, 3551. <https://doi.org/10.3390/polym14173551>

Use Case: Experimentell bestimmte unzureichende Korrelation zwischen Gewicht und Oberflächenqualität



Quelle: S.S. Aminabadi, P. Tabatabai, A. Steiner, D.P. Gruber, W. Friesenbichler, Chr. Habersohn, G.R. Berger-Weber. Polymers 2022, 14, 3551. <https://doi.org/10.3390/polym14173551>

Take-home-Messages

- Spritzgießsimulation hat großes Potential um Trainingsaufwand zu reduzieren, aber es wird weiterhin Modelltraining mit experimentellen Daten brauchen.
- Es ist noch ein weiter Weg bis zu generalisierten Prozessmodellen im Spritzgießen.
- Digitale Transformation in der Kunststofftechnik wird nur funktionieren, wenn die Domänenexperten intensiv zusammenarbeiten!

**Vielen Dank für ihre
geschätzte Aufmerksamkeit!**



Contact:

Univ.-Prof. Dr. mont. Gerald Berger-Weber
gerald.berger-weber@jku.at
+43 732 2468 6572



Pro²Future

