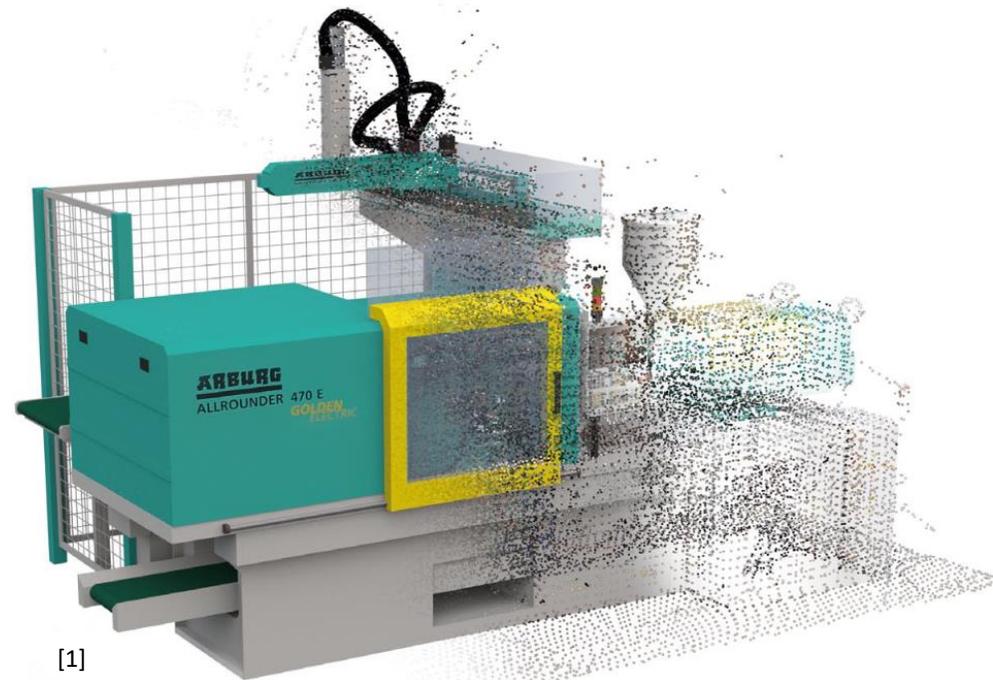


# Datengetriebene Modellbildung - Teil 2

## Seminar

### Digital Twin of Injection Molding (DIM)

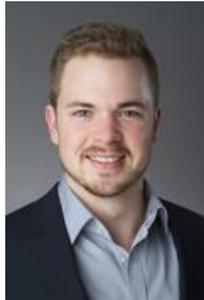
08.06.2022



[1]

## Forschungskonsortium

- Institut für Werkstofftechnik / FG Kunststofftechnik, Prof. Dr.-Ing. H.-P. Heim
- FG Mess- und Regelungstechnik, Prof. Dr.-Ing. A. Kroll



Alexander Rehmer



+



Marco Klute



+



Stefan Rosenbach



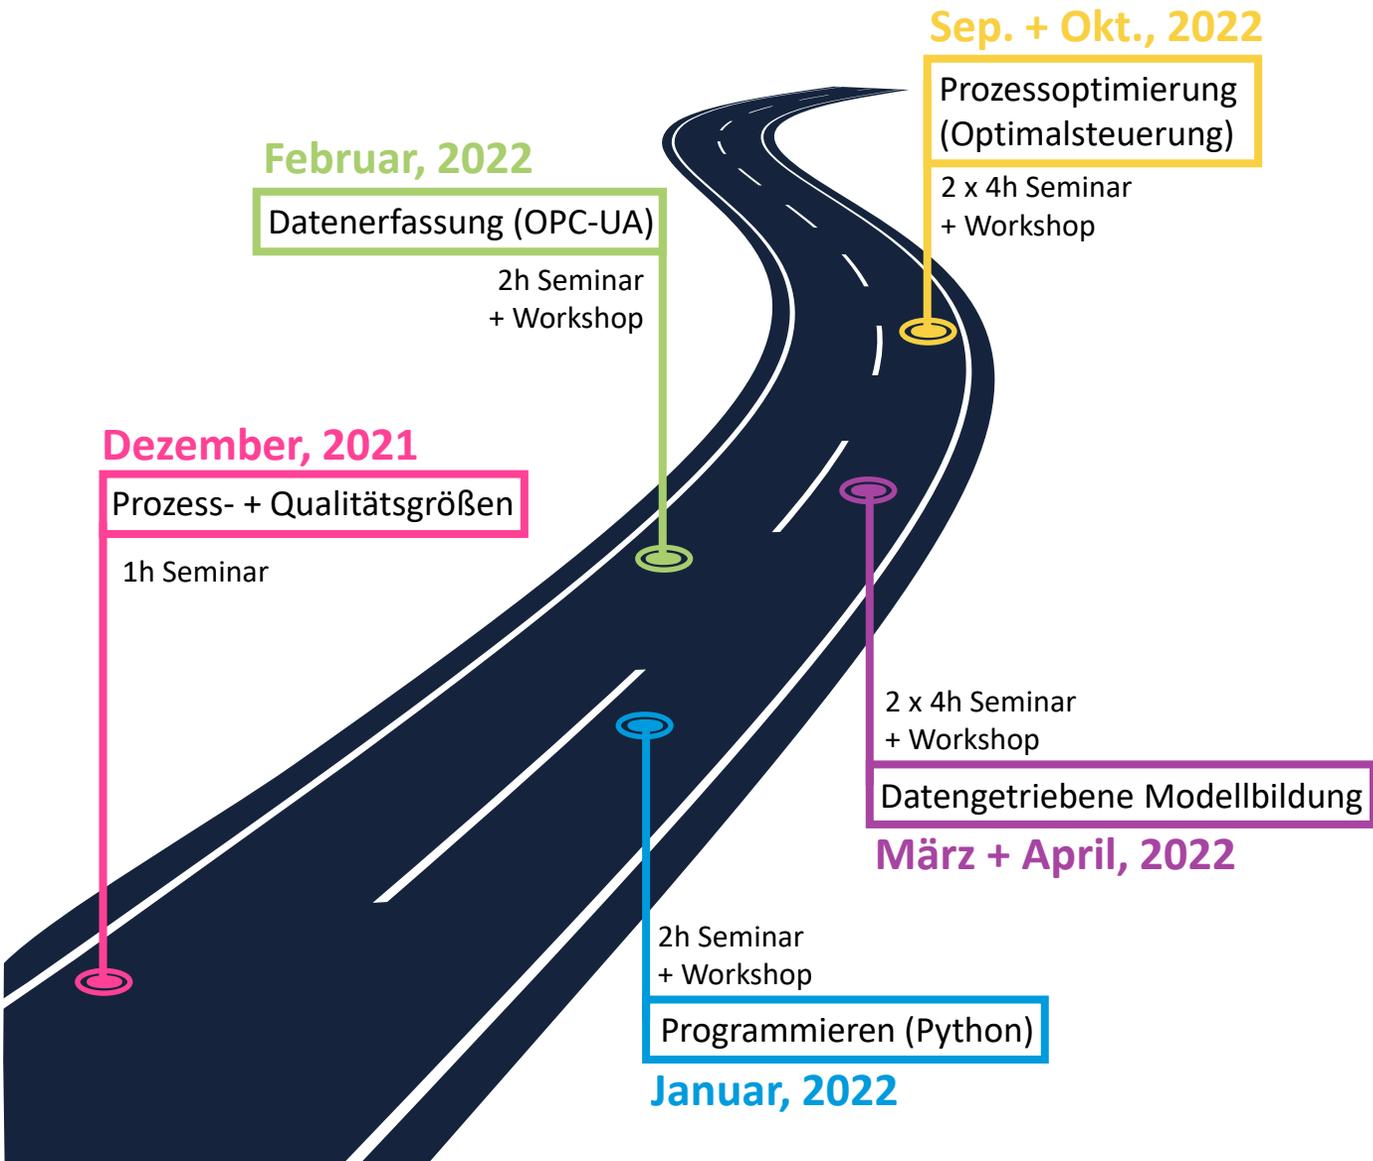
+

Studentische  
Hilfskräfte



## Kontakt:

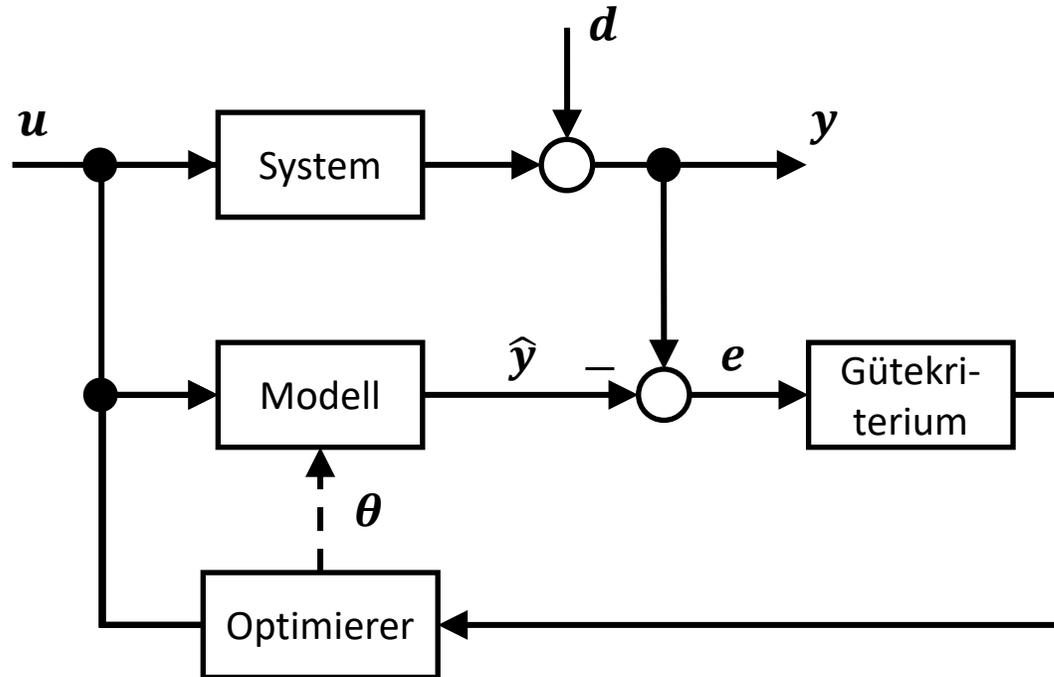
- [dim@uni-kassel.de](mailto:dim@uni-kassel.de)
- [www.uni-kassel.de/go/DIM](http://www.uni-kassel.de/go/DIM)



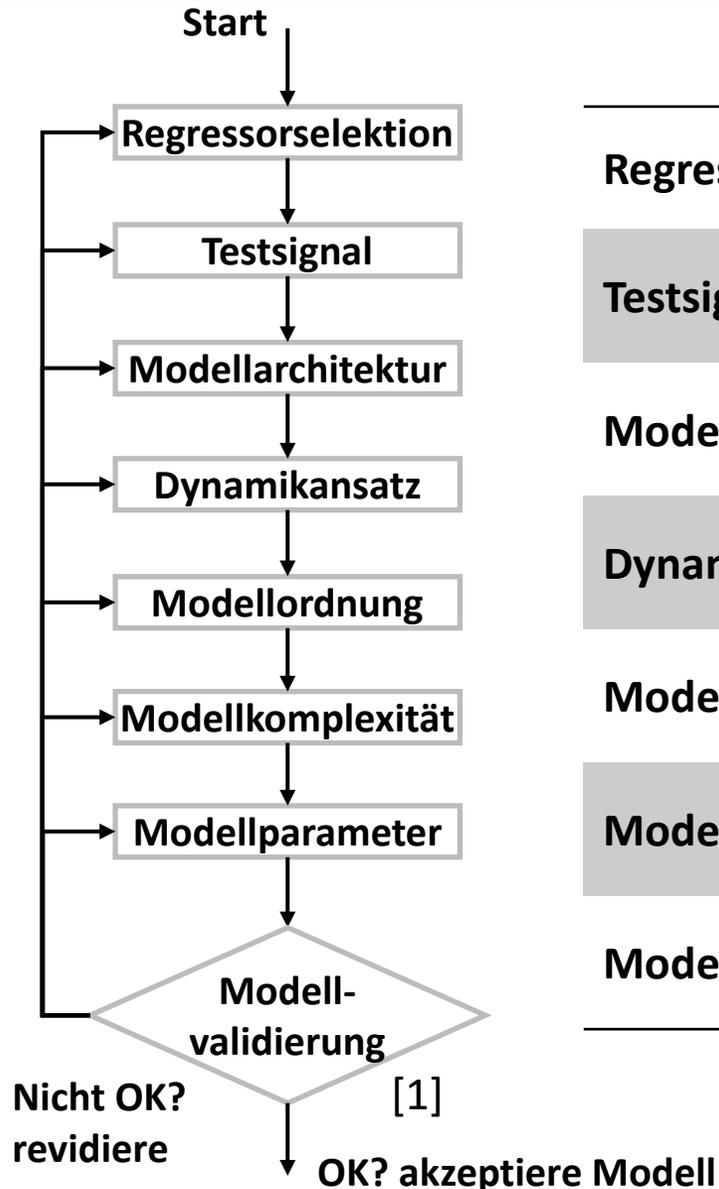
- Erfassung von Prozess- und Qualitätsgrößen
- **Programmieren mit Python**
  - Seminar: Vermittlung grundlegender und fortgeschrittener Aspekte der objektorientierten Programmierung mit Python
  - Workshop: Selbstständige Bearbeitung von Programmieraufgaben
  - Ziele:
    - Installieren und Ausführen von Python
    - Programmieren und Lesen von Python Code
- Datenerfassung mit OPC-UA
- Datengetriebene Modellbildung
- Prozessoptimierung mittels numerischer Optimalsteuerung

- **Rückblick Modellbildung Teil 1**
- **DIM - Toolbox**
- **Datengetriebene Modellbildung des Spritzgießprozesses**
- **Fallstudien**

- **Rückblick Modellbildung Teil 1**
  - Ablauf der datengetriebenen Modellbildung
  - Designentscheidungen
  - Datengetriebene Modellbildung mit CasADi
- DIM - Toolbox
- Datengetriebene Modellbildung des Spritzgießprozesses
- Fallstudien



- System und Modell werden mit geeigneten Testsignalen angeregt
- Der Modellansatz kann aus theoretischen Überlegungen (physikalisch) folgen, muss aber nicht (Black-Box)
- Aus den Ausgangssignalen (System  $y$  und Modell  $\hat{y}$ ) wird die Differenz  $e$  gebildet und anhand eines Gütekriteriums (Kostenfunktion) bewertet
- Das Ergebnis der Bewertung wird von einem Optimierungsverfahren verwendet, um die Modellparameter anzupassen
- Das Optimierungsverfahren wird beendet, sobald eine gewünschte Güte erreicht oder ein anderes Abbruchkriterium erfüllt ist



**Regressorselektion** Welche Eingänge sollen als Modelleingänge verwendet werden?

**Testsignal** Wie muss das Testsignal gewählt werden, damit das relevante Systemverhalten in den Daten enthalten ist?

**Modellarchitektur** Welche Funktion soll zur Approximation des Systems angesetzt werden? Polynom, Multilayer Perceptron, Takagi Sugeno Fuzzy, ...

**Dynamikansatz** Soll das System als statisches System oder als dynamisches System mit externer/interner Dynamik approximiert werden?

**Modellordnung** Falls ein dynamisches Modell gebildet werden soll, handelt es sich um ein System 1. Ordnung, 2. Ordnung, etc.

**Modellkomplexität** Wie flexibel muss die Modellarchitektur gewählt werden, um das deterministische Systemverhalten abbilden zu können?

**Modellparameter** Welches Optimierungsverfahren soll eingesetzt werden, um die Modellparameter zu schätzen?

1. Definieren der Modellgleichung als CasADi-Funktion, die Modellparameter müssen als symbolische Variablen definiert werden:

```
theta = cs.MX.sym('theta',2,1)
u = cs.MX.sym('u',2,1)
y = theta[0]*u[0] + theta[1]*u[1]
f_model = cs.Function('f_model',[u,theta],[y],[u,'theta'],['y'])
```

2. Auswerten der CasADi-Funktion auf den aufgenommenen Daten in der entsprechenden Konfiguration und Berechnung der "Kosten" basierend auf dem Prädiktionsfehler  $\hat{y}^i - y^i$

```
L = 0
for k in range(0,999):
    u_k = arx_data.loc[k][['u_k-1','y_k-1']].values.reshape((2,1))
    y_k = arx_data.loc[k]['y_k']
    y_hat = f_model(u=u_k, theta=theta)['y']
    L = L + 0.5*(y_hat - y_k)**2
```

3. Übergeben der Kosten an einen Optimierer, der die optimalen Modellparameter ermittelt

```
S = cs.qpsol('S', 'qpoases', {'x':theta, 'f':L})
r=S()
theta_opt = r['x']
```

**Quelle:** Tutorials/Dynamische Systemidentifikation mit CasADi.ipynb

- **Rückblick Modellbildung Teil 1**
- **DIM - Toolbox**
  - Aufbau der Toolbox
  - Modul model\_structures
  - Modul injection\_molding
  - Modul param\_optim
- **Datengetriebene Modellbildung des Spritzgießprozesses**
- **Fallstudien**

```
DigitalTwinInjectionMoulding/  
|  
├─ models/  
|   ├─ injection_molding.py  
|   └─ model_structures.py  
|  
├─ optim/  
|   ├─ common.py  
|   └─ control_optim.py  
|       └─ param_optim.py  
|           └─ hyperparam_optim.py  
|  
├─ tests/  
|   ├─ MultiStageOptimization.py  
|   └─ ...
```

## models

- model\_structures enthält als Klassen implementierte Modellarchitekturen, wie MLP (statisch und dynamisch), GRU und LSTM.
- injection\_molding enthält nur zwei Klassen: ProcessModel und QualityModel. Diese Klassen dienen der Verknüpfung mehrerer Modelle aus model\_structures zu einem Prozess- bzw. Qualitätsmodell

## models

- control\_optim enthält alle Methoden zur optimalsteuerungsbasierten Prozessoptimierung
- param\_optim enthält alle Methoden zur Parameteroptimierung
- hyperparam\_optim enthält eine partikelschwarmbasierte Methode zur Hyperparameteroptimierung

## tests

- Methoden und Skripte für den persönlichen Gebrauch des Entwicklers

```

590 def OneStepPrediction(self,u0,params=None):
591     """
592     OneStepPrediction() evaluates the model equation defined in
593     self.Function()
594
595     self.Function() takes initial state x0, input u0 and all model
596     parameters as input. The model parameters can either be optimization
597     variables themselves (as in system identification) or the take specific
598     values (when the estimated model is used for control)
599
600     Parameters
601     -----
602     u0 : array-like with dimension [self.dim_u, 1]
603         input
604     params : dictionary, optional
605         params is None: This is the case during model based control,
606         self.Function() is evaluated with the numerical
607         values of the model parameters saved in self.Parameters
608         params is dictionary of opti.variables: During system identification
609         the model parameters are optimization variables themselves, so a
610         dictionary of opti.variables is passed to self.Function()
611
612     Returns
613     -----
614     y : array-like with dimension [self.dim_x, 1]
615         output of the Feedforward Neural Network
616
617     """
618     if params==None:
619         params = self.Parameters
620
621     params_new = []
622
623     for name in self.Function.name_in():
624         try:
625             params_new.append(params[name])
626         except:
627             continue
628
629     y = self.Function(u0,*params_new)
630
631     return y
586     self.ParameterInitialization()

```

- `__init__()` ist die Konstrukturmethode
- Bei Erzeugung einer Instanz der Klasse müssen bestimmte Parameter übergeben werden, um die Modellstruktur (Anzahl Eingänge & Ausgänge, Anzahl Neuronen in verdeckter Schicht) festzulegen.
- `__init__()` ruft dann automatisch die `Initialize()` Methode auf, in welcher die Modellgleichungen als CasADi-Funktion generiert werden.
- `OneStepPrediction()` wertet die Modellgleichungen (CasADi-Funktion) für gegebene Werte der Eingangsgröße aus
- `Simulation()` ruft `OneStepPrediction()` in einer Schleife für eine gegebene Trajektorie an Eingangsgrößen auf
- Die letzteren beiden Methoden
  - sind für alle Modellstrukturen identisch (Copy&Paste für eigene Modellstrukturen)
  - müssen vom Nutzer für gewöhnlich nicht verwendet werden. Die Modellauswertung erfolgt mit den Funktionen `parallel_mode()`, `static_mode()` und `series_parallel_mode`

```
12
13 class ProcessModel():
14     '''
15     Container for the model which estimates the quality of the part given
16     trajectories of the process variables
17     '''
18     def __init__(self, subsystems, name):
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68     def Initialize(self):
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100    def Simulation(self, x0, u, params=None, switching_instances=None, **kwargs):
101
102
103
104
105
106
107
108
109
110
111
112
113
114
115
116
117
118
119
120
121
122
123
124
125
126
127
128
129
130
131
132
133
134
135
136
137
138
139
140
141
142
143
144
145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163
164
165
166
167
168
169
170    def ParameterInitialization(self):
171
172
173
174
175
176
177
178
179
180    def SetParameters(self, params):
181
182
183
184
185
186
187
188
189
190
191
192
193
194
195
196
197
198
199
200
201
202
203
204
205
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
226
227
228
229
230
231
232
233
234
235
236
237
238
239
240
241
242
243
244
245
246
247    def Simulation(self, c0, u, params=None, switching_instances=None):
248
249
250
251
252
253
254
255
256
257
258
259
260
261
262
263
264
265
266
267
268
269
270
271
272
273
274
275
276
277
278
279
280
281
282
283
284
285
286
287
288
289
290
291
292
293
294
295
296
297
298
299
300
301
302
303
304
305
306
307
308
309
310
311
312
313
314
315
316
317
318
319
320
321
322
323
324
325
326
327
328
329
330
331
332
333
334
335    def ParameterInitialization(self):
336
337
338
339
340
341
342
343
344
345    def SetParameters(self, params):
346
347
348
349
350
351
352
```

- ProcessModel() und QualityModel() ermöglichen ein dynamisches Prozess- bzw. Qualitätsmodell zu bilden, welches aus unterschiedlichen Submodellen besteht
- So kann das schaltende Verhalten des Spritzgießprozesses nachgebildet werden

### Wichtigste Funktionen des Moduls param\_optim für den Nutzer

```
10 inj_model = GRU(..., name='inj')
11
12 press_model = GRU(..., name='press')
13
14 cool_model = GRU(..., name='cool')
15
16 quality_model = QualityModel(subsystems=[inj_model, press_model, cool_model],
17                               name='q_model')
```

```

7
8 def ModelTraining(model,data_train,data_val,initializations=10, BFR=False,
9                   p_opts=None, s_opts=None,mode='parallel'):
10     ...
11
12 def ParallelModelTraining(model,data_train,data_val,initializations=10,
13                           BFR=False, p_opts=None, s_opts=None,mode='parallel',
14                           n_pool=5):
15     ...
16
17 def parallel_mode(model,data,params=None):
18     ...
19
20 def static_mode(model,data,params=None):
21     ...
22
23 def series_parallel_mode(model,data,params=None):
24     ...

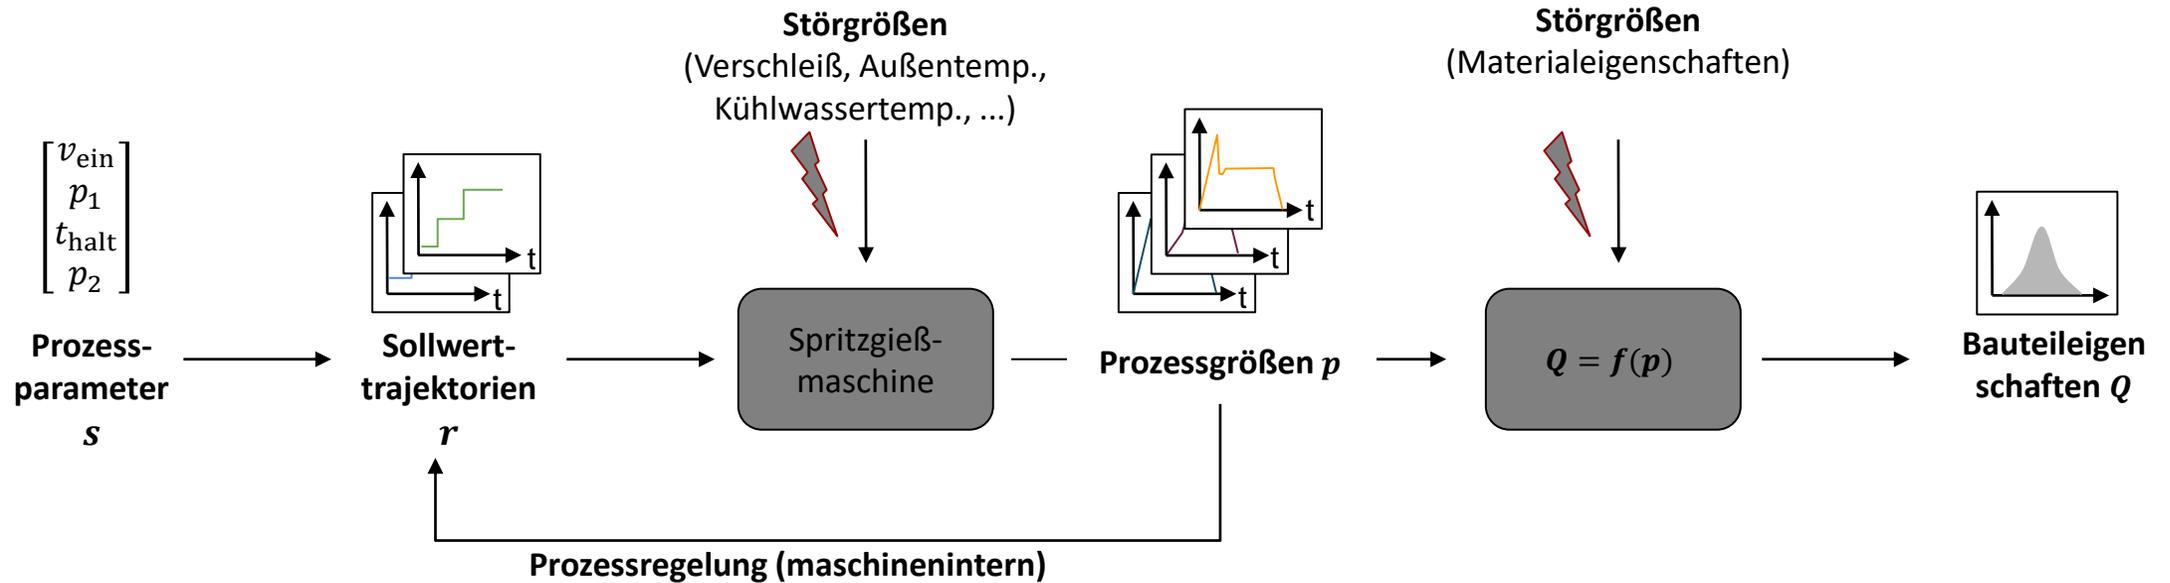
```

- **ModelTraining()** optimiert die Parameter eines Modells (model\_structure oder injection\_molding).
- Zur Parameterschätzung werden die Daten in data\_train verwendet. Zur Modellvalidierung die Daten in data\_val.
- Der Nutzer bestimmt, wie viele zufällige Initialisierungen mit anschließender Optimierung durchgeführt werden sollen.
- p\_opts und s\_opts sind Argumente, die an CasADi bzw. den Optimierer IPOPT übergeben werden können.

### Wichtigste Funktionen des Moduls param\_optim für den Nutzer

- Außerdem muss festgelegt werden, in welcher Konfiguration das Modell trainiert werden soll:
  - 'parallel': Modell wird auf den Simulationsfehler optimiert
  - 'series': Modell wird als Einschrittprädiktor trainiert
  - 'static': Statische Modellauswertung
- **ParallelModelTraining()** nutzt mehrere Kerne gleichzeitig, um mehrere Modell auf einmal zu trainieren. Die Anzahl an Kernen wird durch n\_pool festgelegt
- **parallel\_mode()**, **series\_parallel\_mode()** und **static\_mode()** werten ein Modell in der jeweiligen Konfiguration auf gegebenen Daten aus

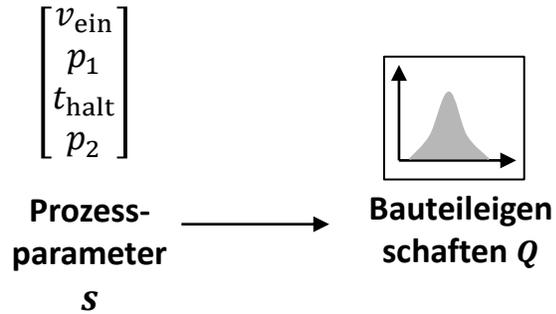
- Rückblick Modellbildung Teil 1
- DIM - Toolbox
- **Datengetriebene Modellbildung des Spritzgießprozesses**
  - Überblick Modellierungsansätze
  - Statische Setpoint Modellierung
  - Statische Feature Modellierung
  - Dynamische Modellierung
- Fallstudien



## Modellierungsansätze

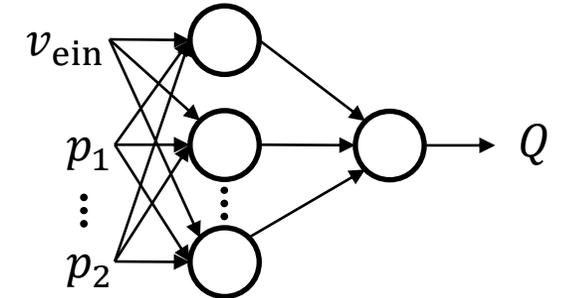
1. Statische Setpoint-Modelle: Direkte Abbildung von Prozessparametern (Setpoints)  $s$  auf die Qualitätsmerkmale  $Q$
2. Statische Feature-Modelle: Extraktion von Features  $f$  aus Prozessgrößen  $p$  basierend auf Expertenwissen. Dann Abbildung der Prozessparameter  $s$  und Features  $f$  auf die Qualitätsmerkmale  $Q$
3. Dynamische Modelle: Dynamische Abbildung der Sollwerttrajektorien  $r$  auf die Prozessgrößentrajektorien  $p$ . Anschließende dynamische Abbildung der Prozessgrößentrajektorien  $p$  auf die Qualitätsmerkmale  $Q$ .

- Realisierung bspw. mit polynomialem Modell oder Neuronalem Netz (NN)



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

Polynom 2. Grades ohne Interaktionsterme



NN mit beliebig vielen Neuronen in der verdeckten Schicht

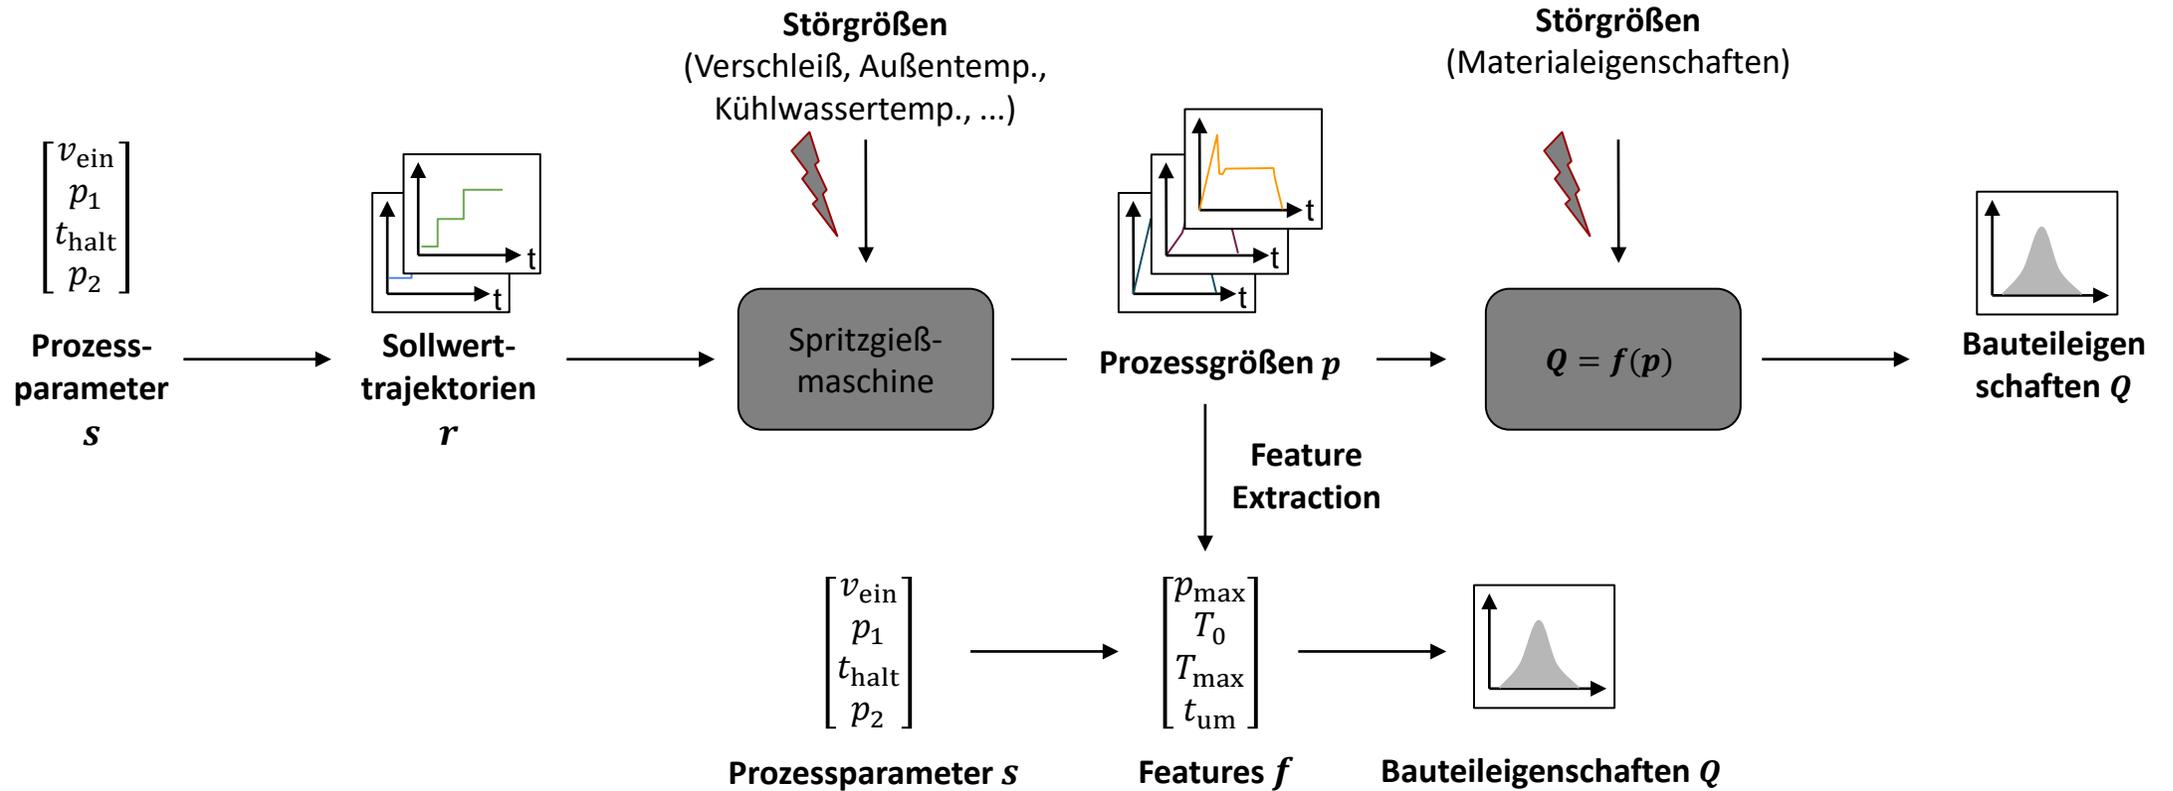
## Vorteile

- Am einfachsten zu implementierender Modellierungsansatz
- Falls Modell linear in den Parametern (LiP) ist, ist auch Optimierungsproblem LiP, d.h. optimale Modellparameter können in einem Schritt ermittelt werden
- Nur ein Modell für Modellierung des gesamten Spritzgießprozesses erforderlich

## Nachteile

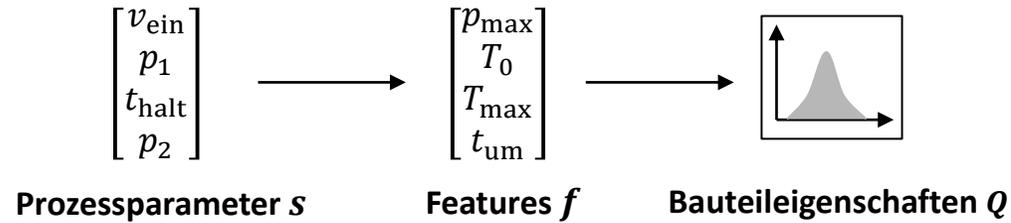
- Modellansatz mit den stärksten Vereinfachungen: Tatsächlicher Verlauf der Prozessgrößen wird bei Modellierung der Qualität nicht berücksichtigt
- Modell ist daher nur im stationären Betrieb gültig
- D.h. im transienten Betrieb (z.B. nach Änderung der Prozessparameter) kann die Bauteilqualität nicht zuverlässig prädiziert werden
- Wirkung von Störgrößen bleibt unbemerkt

Designentscheidung	Bemerkung
<b>Regressorselektion</b>	<ul style="list-style-type: none"> <li>Als Regressoren kommen alle Maschinenparameter in Frage, welche im Betrieb vom Anlagenführer variiert werden.</li> </ul>
<b>Testsignal</b>	<ul style="list-style-type: none"> <li>Nicht ganz zutreffend, da ein statisches Modell gebildet wird.</li> <li>Für die Erhebung von Trainingsdaten sollte idealerweise ein Versuchsplan durchgeführt werden, welcher den relevanten Betriebsbereich abdeckt.</li> <li>Nur Beobachtungen nach Abklingen der Einschwingvorgänge sollten zum Modelltraining verwendet werden.</li> </ul>
<b>Modellarchitektur</b>	<ul style="list-style-type: none"> <li>Die Güte linearer Modelle war nicht zufriedenstellend</li> <li>Polynome führten zu Modellen mit höchster Güte</li> <li>Multilayer Perceptron (MLP) führten zu zufriedenstellenden Modellen</li> </ul>
<b>Dynamikansatz</b>	-
<b>Modellordnung</b>	-
<b>Modellkomplexität</b>	<ul style="list-style-type: none"> <li>Polynome fünfter Ordnung und MLP mit mindestens vier Neuronen in der verdeckten Schicht führten zu Modellen mit guter Modellgüte</li> </ul>



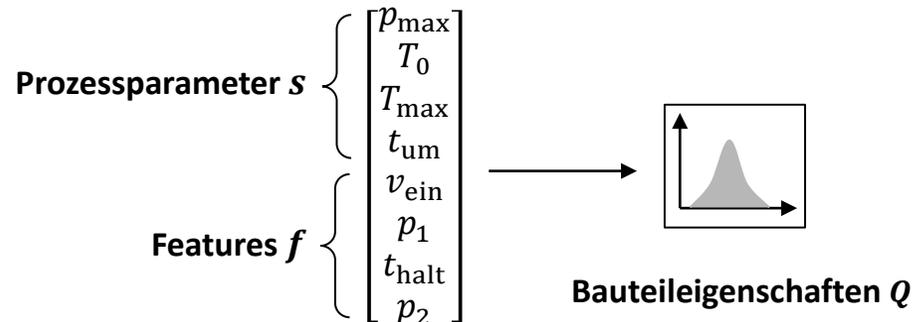
- Umgehung der Notwendigkeit der Bildung dynamischer Modelle, bei gleichzeitiger Ausnutzung dynamischer Information basierend auf Expertenwissen

## Variante 1

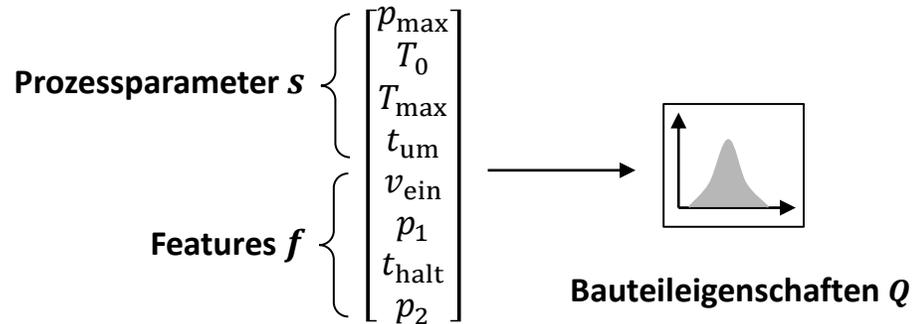


- Für die Abbildungen  $s \rightarrow \hat{f}$  und  $f \rightarrow \hat{Q}$  konnten jeweils sehr gute geschätzt werden
- Der akkumulierte Fehler bei der Abbildung  $s \rightarrow \hat{f} \rightarrow \hat{Q}$  war dann aber in derselben Größenordnung, wie bei der direkten statischen Modellbildung  $s \rightarrow \hat{Q}$

## Variante 2



- Aus diesem Grund wurden Setpoints  $s$  und Features  $f$  zu einem gemeinsamen Vektor  $\begin{bmatrix} s \\ f \end{bmatrix}$  konkateniert
- Der konkatenierte Vektor bildet die Eingangsgröße für ein statisches Modell, welches direkt auf die Bauteileigenschaften  $Q$  abbildet
- Die hierdurch erreichbaren Modellgüten übertrafen sowohl den Modellierungsansatz  $s \rightarrow \hat{Q}$  als auch  $s \rightarrow \hat{f} \rightarrow \hat{Q}$
- Grund: Im Gegensatz zu dem statischen Setpoint-Modell  $s \rightarrow \hat{Q}$  werden durch die Verwendung von Features bspw. unterschiedliche Anfangsbedingungen berücksichtigt. Im Gegensatz zu  $s \rightarrow \hat{f} \rightarrow \hat{Q}$  kommt zu keiner Fehlerakkumulation.



- Prozessmodell:  $s \rightarrow f$  (statisch)
- Qualitätsmodell:  $f \rightarrow Q$  (statisch)
- Realisierung der Modelle bspw. mit polynomialen Modellen oder Neuronalen Netzen (NN)

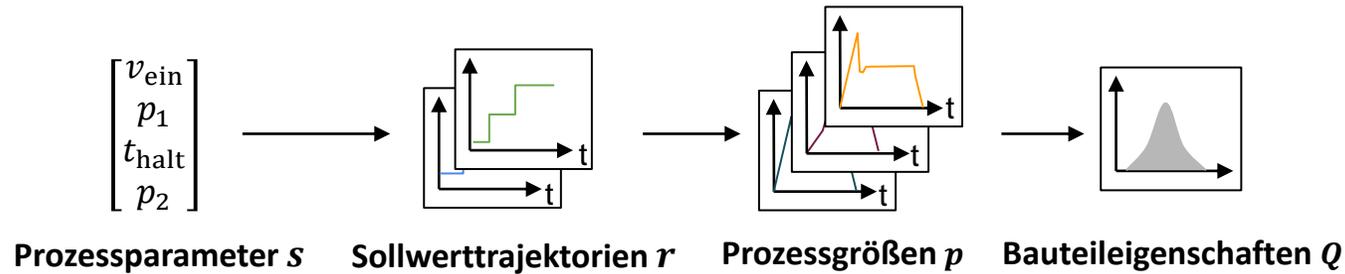
## Vorteile

- Relativ einfach zu implementieren
- Falls Modelle (LiP) sind, ist auch Optimierungsproblem LiP
- Guter Kompromiss zwischen Ausnutzung vorhandener (dynamischer) Informationen und Komplexität der Modellbildung
- Modelle bestenfalls auch im transienten Betrieb gültig

## Nachteile

- Expertise zur Auswahl aussagekräftiger Features erforderlich
- Keine Ausnutzung der "gesamten" dynamischen Information (d.h. der Prozessgrößentrajektorien)

Designentscheidung	Bemerkung
<b>Regressorselektion</b>	<ul style="list-style-type: none"> <li>Prozessmodell: Kandidaten sind Maschinenparameter und auf Expertenwissen basierende Features</li> </ul>
<b>Testsignal</b>	<ul style="list-style-type: none"> <li>Idealerweise Durchführung eines Versuchsplans, welcher den relevanten Betriebsbereich abdeckt.</li> <li>Features sind abhängige Größen, welche nicht beliebig manipuliert werden können. Daher keine Möglichkeit eine gleichmäßige Abdeckung des "Feature-Raums" zu gewährleisten.</li> </ul>
<b>Modellarchitektur</b>	<ul style="list-style-type: none"> <li>Polynom neigt zu oszillierender Interpolation, da Feature-Raum ungleichmäßig abgedeckt ist --&gt; MLP bessere Variante</li> </ul>
<b>Dynamikansatz</b>	-
<b>Modellordnung</b>	-
<b>Modellkomplexität</b>	<ul style="list-style-type: none"> <li>Polynome dritter Ordnung und MLP mit mindestens drei Neuronen in der verdeckten Schicht führten bereits zu Modellen mit guter Modellgüte</li> </ul>



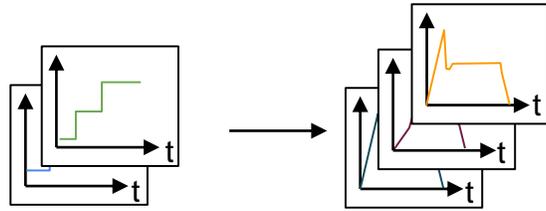
- Umrechnung  $s \rightarrow r$  bekannt (statisch)
- Prozessmodell:  $r \rightarrow p$  (dynamisch)
- Qualitätsmodell:  $p \rightarrow Q$  (dynamisch)

### Vorteile

- Keine Feature-Selektion erforderlich
- Ausnutzung der gesamten dynamischen Information durch Verwendung der Prozessgrößentrajektorien
- Prozessmodell und Qualitätsmodell im transienten Betrieb gültig

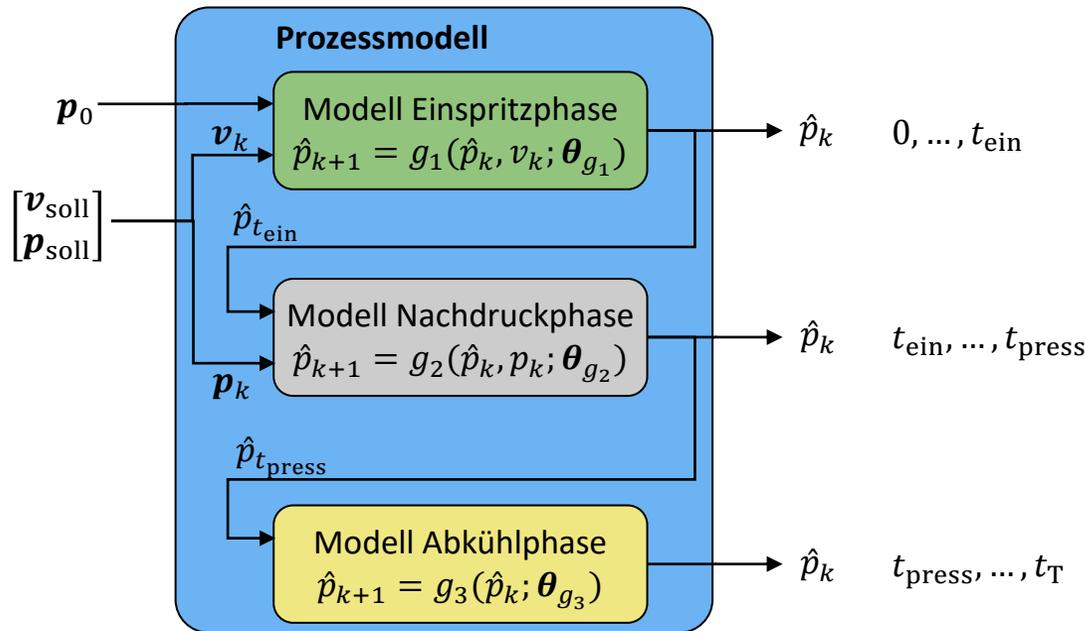
### Nachteile

- Sehr aufwändige Implementierung
- Sehr hohe Komplexität der Modellbildung
- Optimierungsprobleme sind immer nichtlinear, selbst wenn Modelle LiP sind

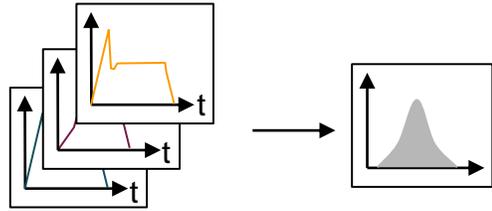


Sollwerttrajektorien  $r$     Prozessgrößen  $p$

- Der geregelte Spritzgießprozess ist ein schaltendes System:
  1. Einspritzphase ist geschwindigkeitsgeregelt
  2. Nachdruckphase ist druckgeregelt
  3. Abkühlphase ist ein rein autoregressiver Prozess
- Dieses Verhalten muss im Modellansatz berücksichtigt werden

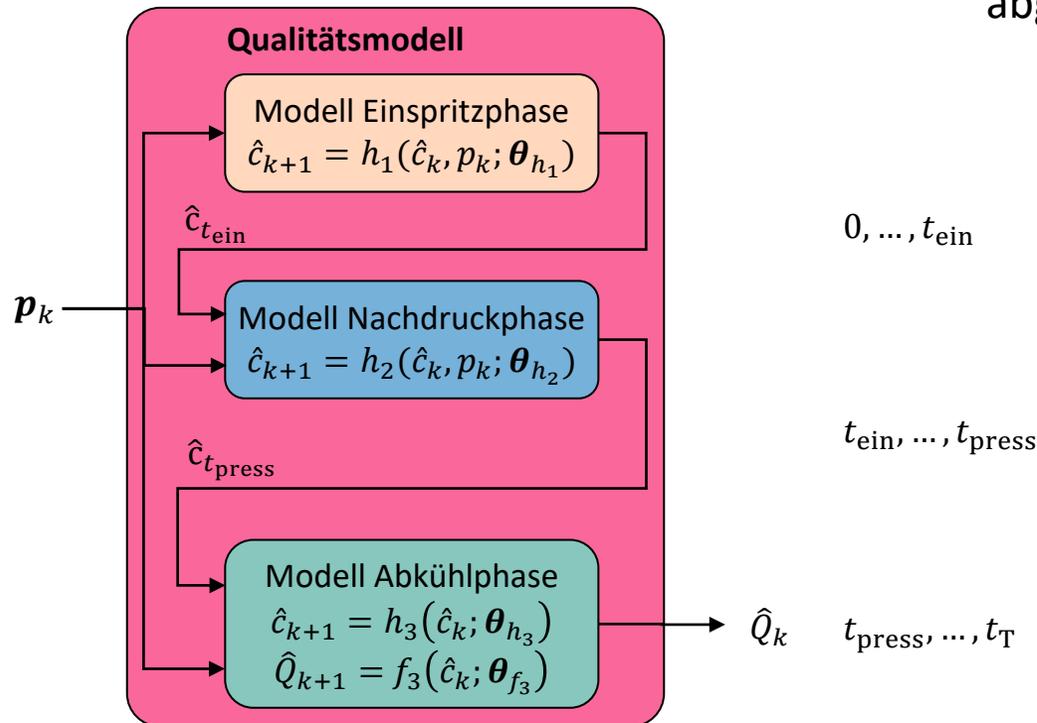


- Das Prozessmodell besteht aus drei unterschiedlichen Modellen, jeweils für die verschiedenen Phasen des Spritzgießprozesses
- Die Modelle sind an den jeweiligen Umschaltpunkten miteinander verknüpft



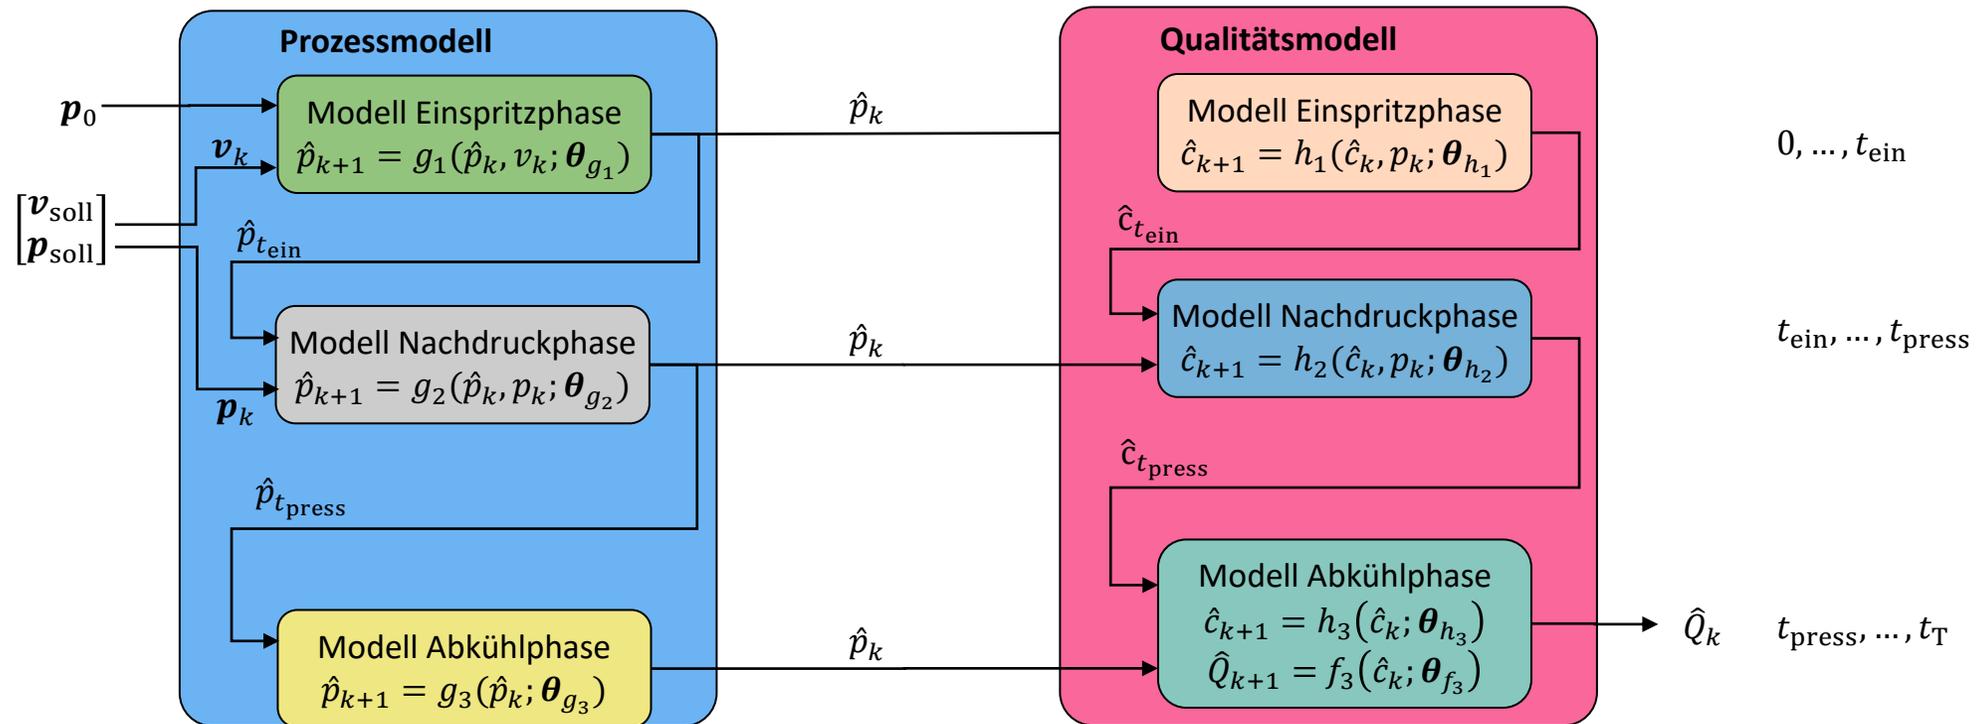
Prozessgrößen  $p$  Bauteileigenschaften  $Q$

- Das schaltende Verhalten des Spritzgießprozesses, bedeutet nicht, dass auch die Abbildung von Prozessgrößentrajektorien  $p$  auf Bauteileigenschaften  $Q$  durch ein schaltendes Modell beschrieben werden muss.
- Das Bauteil unterliegt jedoch unter anderem einem Wechsel des Aggregatzustandes, der ungefähr zum Beginn der Nachdruckphase abgeschlossen sein sollte.



- Es ist daher unwahrscheinlich, dass der Prozess der Ausbildung der Qualitätseigenschaften durch ein einziges Modell mit fixen Parametern beschrieben werden kann.
- Diese Vermutung wird auch durch Versuche empirisch gestützt
- Zwei Optionen:
  - Modellparameter ändern sich kontinuierlich. Realitätsnäher, führt zu sehr komplexem Optimierungsproblem
  - Modellparameter ändern sich zu diskreten Zeitpunkten, wie Prozessmodell. Einfacher und hinreichend realitätsnah.

- Prozess- und Qualitätsmodell werden in Reihe geschaltet, um die Bauteileigenschaften  $Q$  aus den eingestellten Setpoints  $s = \begin{bmatrix} v_{\text{soll}} \\ p_{\text{soll}} \end{bmatrix}$  zu präzisieren



Designentscheidung	Bemerkung
<b>Regressorselektion</b>	<ul style="list-style-type: none"><li>• Prozessmodell: Sollwerttrajektorien der Regler</li><li>• Qualitätsmodell: Kandidaten sind alle erfassten Prozessgrößen</li></ul>
<b>Testsignal</b>	<ul style="list-style-type: none"><li>• Prozessmodell: Idealerweise Durchführung eines Versuchsplans, welcher den relevanten Betriebsbereich abdeckt.</li><li>• Qualitätsmodell: Die resultierenden Prozessgrößentrajektorien sind abhängige Größen, die nicht gezielt manipuliert werden können.</li></ul>
<b>Modellarchitektur</b>	<ul style="list-style-type: none"><li>• Prozessmodell: Bisher MLP versucht, jedoch noch keine zufriedenstellenden Ergebnisse</li><li>• Qualitätsmodell: Modell mit interner Dynamik sollte verwendet werden, GRU führt zu besseren Ergebnissen als LSTM</li></ul>
<b>Dynamikansatz</b>	<ul style="list-style-type: none"><li>• Prozessmodell: Sowohl Modell mit externer als auch interner Dynamik anwendbar (?)</li><li>• Qualitätsmodell: Modell mit interner Dynamik empfohlen</li></ul>
<b>Modellordnung</b>	<ul style="list-style-type: none"><li>• Prozessmodell: Empfehlung wird ausgesprochen sobald gute Modelle geschätzt werden konnten</li><li>• Qualitätsmodell: Bereits ein GRU mit einem internen Zustand führt zu guten Ergebnissen</li></ul>
<b>Modellkomplexität</b>	<ul style="list-style-type: none"><li>• Prozessmodell: Empfehlung wird ausgesprochen sobald gute Modelle geschätzt werden konnten</li><li>• Qualitätsmodell: Bereits ein GRU mit einem internen Zustand und zehn verdeckten Neuronen in der Ausgabe führt zu guten Ergebnissen</li></ul>

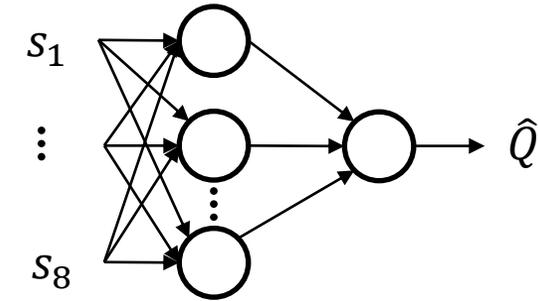
- Rückblick Modellbildung Teil 1
- DIM - Toolbox
- Datengetriebene Modellbildung des Spritzgießprozesses
- **Fallstudien**
  - Statisches Setpoint Qualitätsmodell mit MLP
  - Statisches Feature Qualitätsmodell mit MLP
  - Statisches Prozess- und Qualitätsmodell mit MLP
  - Dynamisches Qualitätsmodell mit GRU

**Ziel:** Bildung eines statischen Modells, welches Maschinenparameter  $s$  auf Qualitätsdaten  $Q$  abbildet.

**Modellansatz:** Multilayer Perceptron, implementiert durch die Klasse `Static_MLP`

**Eingangsgrößen  $u$ :** [Düsentemp., Werkzeugtemp., Einspritzgeschw., Umschaltpunkt, Nachdruckhöhe, Nachdruckzeit, Staudruck, Kühlzeit]

**Ausgangsgrößen  $Q$ :** [Durchmesser\_innen]



Datei: `QualityModel_static_MLP_Toolbox.ipynb`

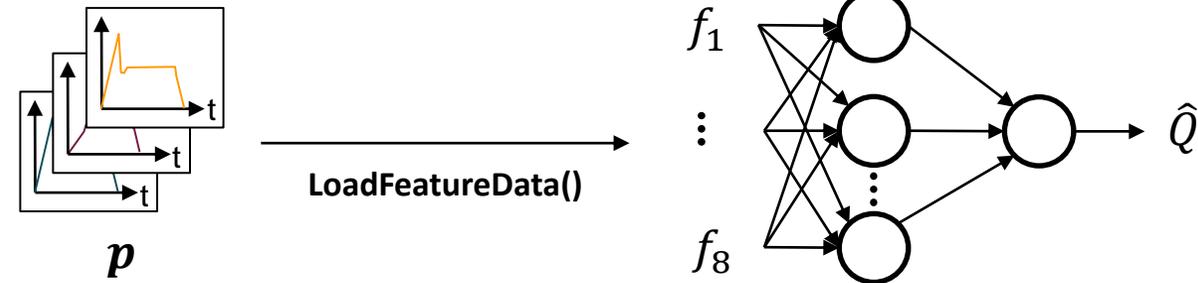
**Ziel:** Bildung eines statischen Modells, welches aus Prozessgrößen  $p$  extrahierte Features  $f$  auf Qualitätsdaten  $Q$  abbildet.

**Modellansatz:** Multilayer Perceptron, implementiert durch die Klasse `Static_MLP`

**Eingangsgrößen  $u$ :** [max. Werkzeuginnendruck., Zeitpunkt des Auftretens des max. Werkzeuginnendrucks, Zeitpunkt des Auftretens der max. Werkzeuginnentemp.]

**Ausgangsgrößen  $Q$ :** [Durchmesser\_innen]

Datei: `QualityModel_feature_MLP_Toolbox.ipynb`



**Ziel:** Das Feature-Qualitätsmodell kann die Bauteilqualität genauer vorhersagen, als das statische Qualitätsmodell. Das Ziel ist jedoch, zu ermitteln, wie die Maschine eingestellt werden muss, um eine bestimmte Bauteilqualität zu erzielen. Daher ist es erforderlich den Zusammenhang zwischen eingestellten Maschinenparametern  $s$  und resultierenden Features  $f$  zu modellieren.

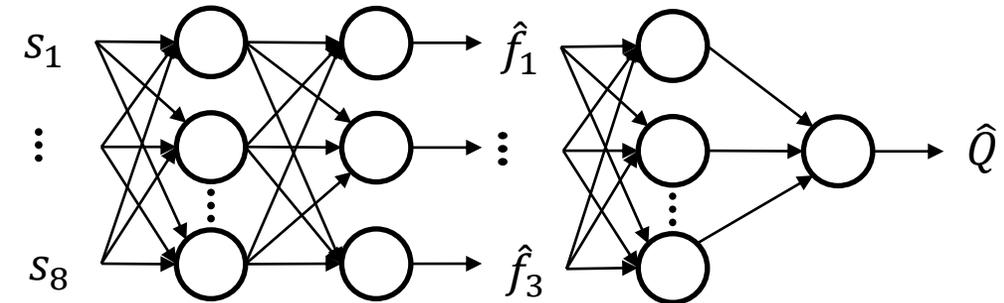
**Modellansatz:** Multilayer Perceptron, implementiert durch die Klasse `Static_MLP`

**Eingangsgrößen  $u$ :** [max. Werkzeuginnendruck., Zeitpunkt des Auftretens des max. Werkzeuginnendrucks, Zeitpunkt des Auftretens der max. Werkzeuginnentemp.]

**Ausgangsgrößen  $Q$ :** [Durchmesser\_innen]

Dateien: *ProcessModel\_feature\_MLP\_Toolbox.ipynb*

*MLP\_Feature\_Model\_Toolbox.ipynb*



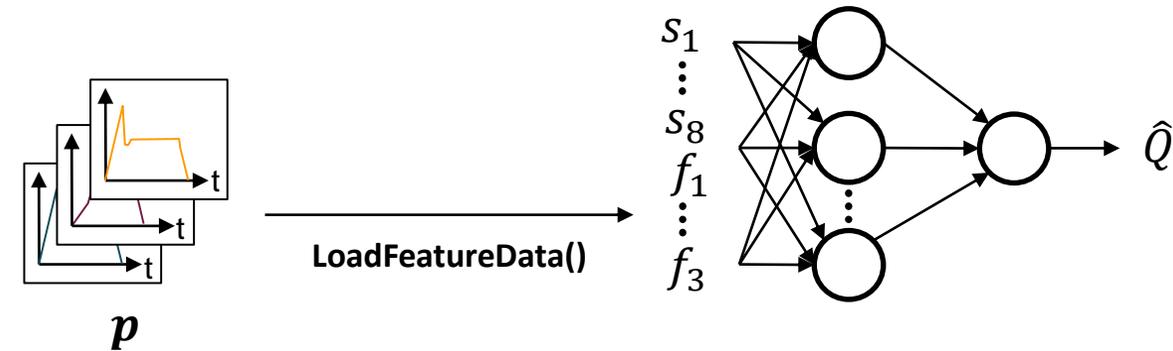
**Ziel:** Die verkettete Abbildung  $s \rightarrow \hat{f} \rightarrow \hat{Q}$  führt zu einer Fehlerakkumulation. Um dies zu vermeiden, werden Setpoints  $s$  und Features  $f$  zu einem Vektor konkateniert und direkt auf die Bauteilqualität abgebildet.

**Modellansatz:** Multilayer Perceptron, implementiert durch die Klasse Static\_MLP

**Eingangsgrößen  $u$ :** [max. Werkzeuginnendruck., Zeitpunkt des Auftretens des max. Werkzeuginnendrucks, Zeitpunkt des Auftretens der max. Werkzeuginnentemp.]

**Ausgangsgrößen  $Q$ :** [Durchmesser\_innen]

Datei: *CompleteModel\_feature\_MLPs\_Toolbox.ipynb*



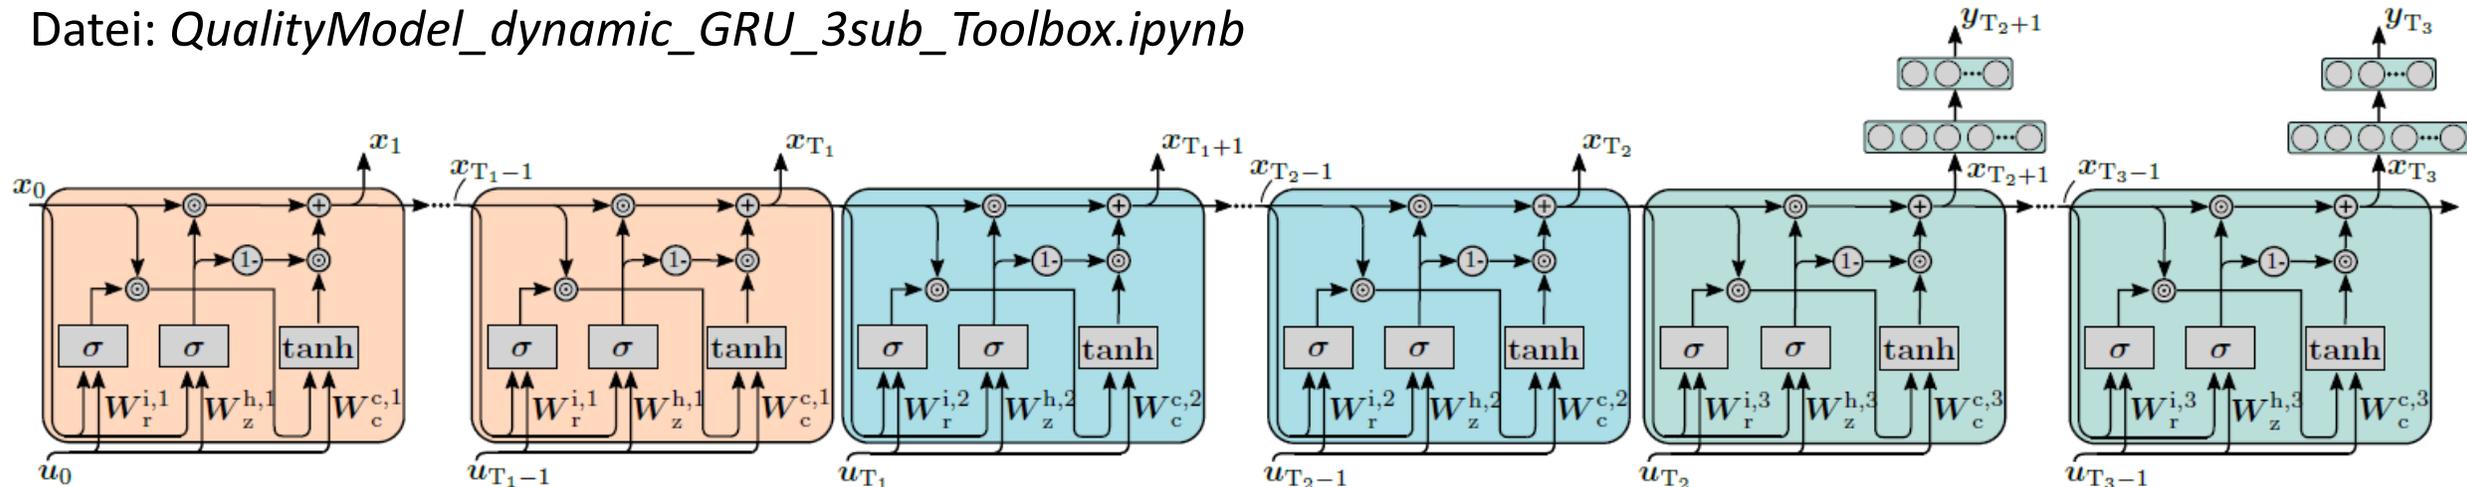
**Ziel:** Um die komplette in den Trajektorien enthaltene Information zur Prädiktion der Bauteilqualität zu nutzen, sollen diese durch ein dynamisches Modell direct auf die Bauteileigenschaften abgebildet werden.

**Modellansatz:** 3 Gated Recurrent Units, implementiert durch die Klasse GRU. Verknüpfung der drei Submodelle für die drei Phasen zu einem Qualitätsmodell durch die Klasse QualityModel

**Eingangsgrößen:** [Werkzeuginnendruck, Werkzeuginnentemperatur]

**Ausgangsgrößen:** [Durchmesser\_innen]

Datei: *QualityModel\_dynamic\_GRU\_3sub\_Toolbox.ipynb*



**Ziel:** Die Prädiktion der Bauteileigenschaften mit dem dynamischen Qualitätsmodell  $p \rightarrow Q$  führt zu den besten Ergebnissen. Allerdings soll letztendlich eine modellbasierte Prozessoptimierung bezüglich der einzustellenden Maschinenparameter  $s$  stattfinden. Es gilt also ein dynamisches Prozessmodell zu bilden, welches die Sollgrößentrajektorien  $r$  auf die Prozessgrößentrajektorien  $p$  abbildet. Der Zusammenhang  $s \rightarrow r$  ist bekannt und bedarf keiner Modellbildung.

**Modellansatz:** dynamisch nichtlinear

**Eingangsgrößen  $r$ :** [Soll-Einspritzgeschwindigkeit, Soll-Hydraulikdruck]

**Ausgangsgrößen  $p$ :** [Schneckenposition, Schneckengeschwindigkeit, Hydraulikdruck, Werkzeuginnendruck, Werkzeuginnentemperatur]

Datei: -