


# Techniken des Maschinenlernens zur effizienten Prozessoptimierung bei veränderlichen Bauteilgeometrien am Beispiel der Textillumformung

*Machine learning algorithms for efficient process optimisation of variable geometries at the example of fabric forming*

22. März 2022

Vortrag zum SAMPE-Innovationspreis „Dissertation“  
27. Nationales SAMPE Symposium, München

Clemens Zimmerling  
KIT – Institut für Fahrzeugsystemtechnik - Leichtbau



### Leichtbaulösungen

- Erzielbarer Leichtbaugrad ↔ Auslegungsaufwand

### Simulationstechnik als Auslegungswerkzeug

- Frühe Bewertung der Herstellbarkeit
- Struktursimulation mit Prozesseffekten



Reduktion teurer Versuche

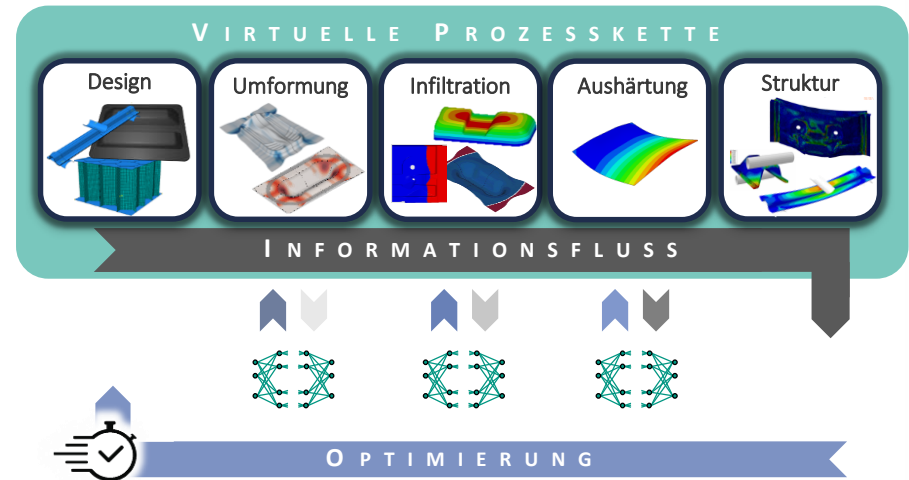


Rechenaufwände (iterative Optimierung!)

### Ziel: Prozessoptimierungen beschleunigen

- Integration von Vorwissen aus ähnlichen Bauteilen durch Techniken des Maschinenlernens (ML)

adaptiert aus [Kärger et al. 2015]



Virtuelle Prozesskette endlosfaserverstärkter Kunststoffe  
am Beispiel des Resin-Transfer-Moulding

### Leichtbaulösungen

- Erzielbarer Leichtbaugrad ↔ Auslegungsaufwand

### Simulationstechnik als Auslegungswerkzeug

- Frühe Bewertung der Herstellbarkeit
- Struktursimulation mit Prozesseffekten



Reduktion teurer Versuche

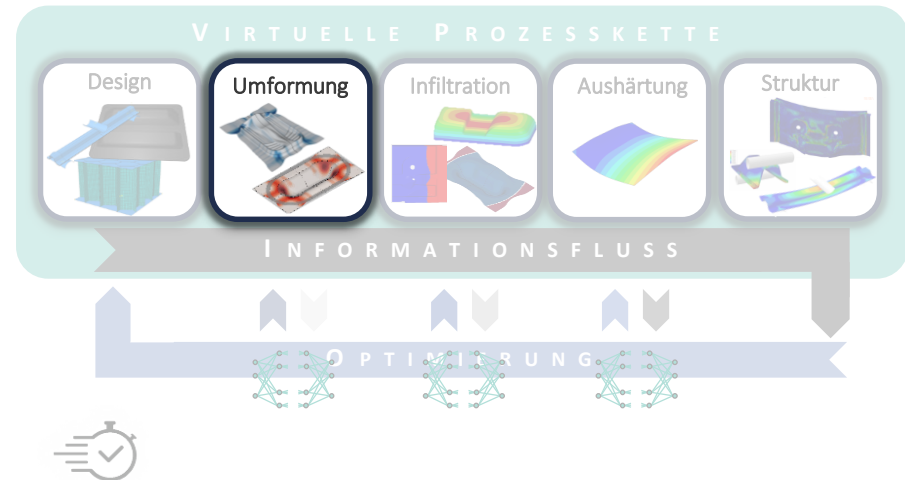


Rechenaufwände (iterative Optimierung!)

### Ziel: Prozessoptimierungen beschleunigen

- Integration von Vorwissen aus ähnlichen Bauteilen durch Techniken des Maschinenlernens (ML)
- Beispielprozess: Umformung technischer Textilien

adaptiert aus [Kärger et al. 2015]



Virtuelle Prozesskette endlosfaserverstärkter Kunststoffe  
am Beispiel des Resin-Transfer-Moulding



Motivation

Stand der Technik und Forschungsfragen


Methodik

Anwendungsbeispiel

Zusammenfassung und Ausblick

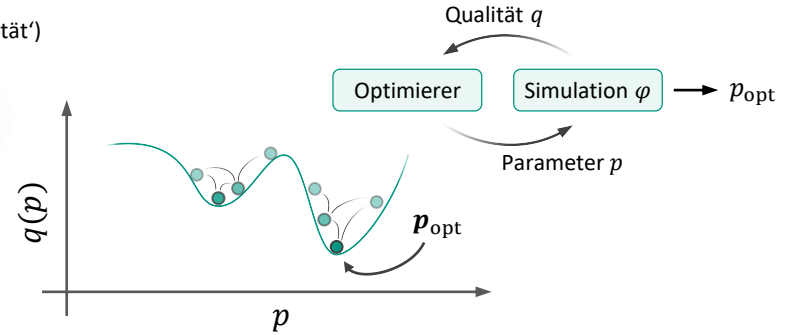
### Virtuelle Prozessoptimierung

- Prozesssimulation als Funktion





- Ziel: Parameteroptimum  $\mathbf{p}_{opt}$  mit  $q_{opt} = q(\mathbf{p}_{opt}) \rightarrow \min$

- Klassische Lösung: Optimierungsalgorithmen




### Herausforderung

- Komplexe Zielfunktion, mehrere Parameter  
→ zahlreiche Iterationen → Rechenzeit steigt



Kippmoment  
je Sockelposition



### Effizienzmaßnahme

- Integration von „Vorwissen“ in die Optimierung
- Gedankenexperiment

### Vorwissen

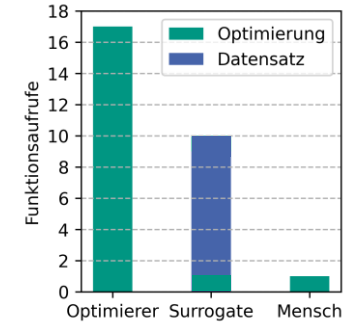


- Schnelles Näherungsmodell („Surrogate“)

$$\mu_{\text{srg}}: P \mapsto Q$$

mit


$$\mu_{\text{srg}} \approx \varphi$$

- Statistisches Modell



### Surrogate-gestützte Optimierung



- Surrogate leitet die Suche des Optimierers
- Identifikation vielversprechender Kombinationen
- Nachrechnen und Rückführung in Datensatz  
→ sukzessive Surrogate-Verfeinerung




adaptiert von  
Bonte et al. 2007

### Textilumformung mit Spanrahmen [Zimmerling et al. 2021]

- FE-Umformsimulation (Gewebemodell [Pope et al. 2018, 2019])
- Optimierung der Materialzuführung (60 Greifer)
- Ziel: Minimierung Scherwinkel  $\gamma$




Visualisierung Scherwinkel  $\gamma$



Plot der Scherwinkel  $\gamma$  nach der Umformung

### Vergleich Optimierung mit und ohne Surrogate

- Surrogate schneller als direkte Optimierung
- Weniger Simulationsaufrufe




### Surrogate-Modelle ...

✓ ... unterstützen die Konvergenz in vielen Fällen, ...


⚙️ ...aber sind sehr aufgabenspezifisch

- Bauteilvarianten nur sehr begrenzt abbildbar
- je Bauteil neues Sampling und Training



### Beobachtung und Idee

- ML-Techniken können komplexe Dynamiken lernen
- Eignung für geometrieübergreifendes Surrogate?





### Hypothese 1


Es ist möglich, mit ML-Verfahren und Simulationstechnik Wissen aus generischen Prozessbeispielen zu extrahieren und auf neue Geometrien anzuwenden

### Hypothese 2

Einmal trainiert, beschleunigt dieses ML-Modell die Optimierung ähnlich wie ein klassisches, geometrie-spezifisches Surrogate

### ■ Anwendungsbeispiel

Materialzuführung bei der Umformung technischer Textilien (Gewebe)





Motivation

Stand der Technik und Forschungsfragen

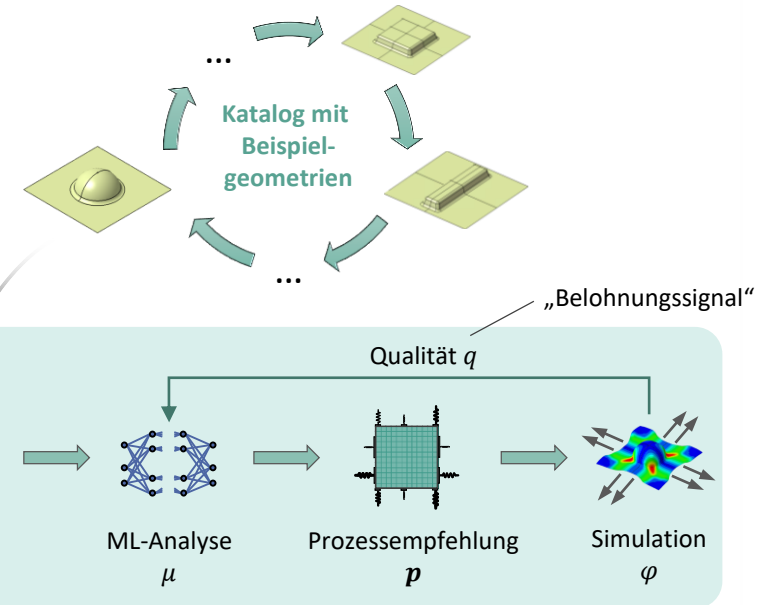
**Methodik**

Anwendungsbeispiel

Zusammenfassung und Ausblick

### Idee

- Ersatz der klassischen Surrogates  $\mu_{\text{SRG}} : P \xrightarrow{G} Q$  + Optimierung
- durch eine allgemeinere Funktion  $\mu : G \mapsto P^*$



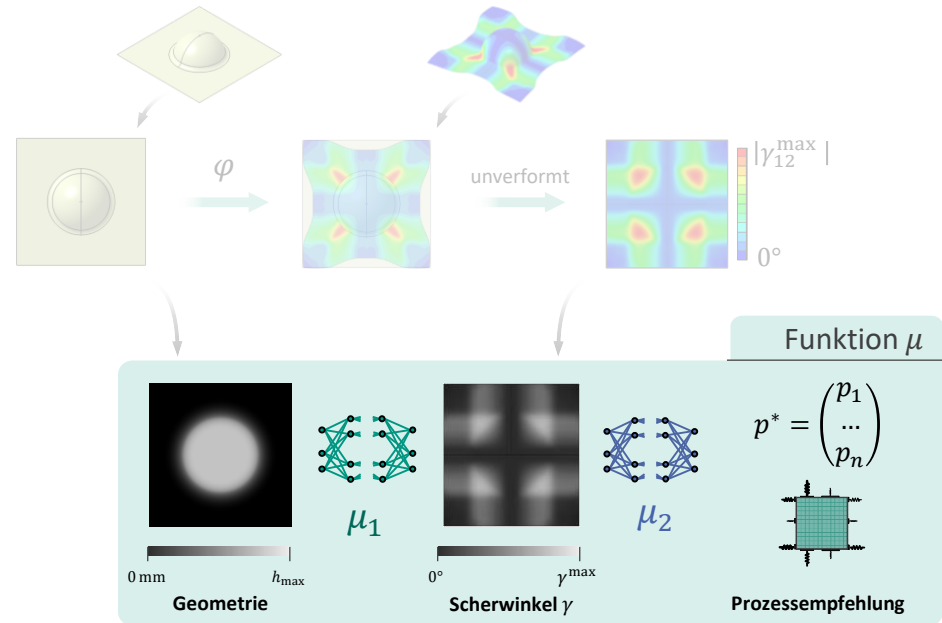
### Reinforcement Learning [Sutton and Barto, 2018]

#### Trial-Error-Training mit Simulationsumgebung

1. Ziehen einer Geometrie  $g$  aus einem Katalog
2.  $\mu$  analysiert  $g$  und gibt eine Prozessempfehlungen  $p$
3. Prozesssimulation  $\varphi(p)$  bestimmt Qualität  $q$
4. Rückführung von  $q$  und Anpassung von  $\mu$

### Geometrieinformation integrieren


- Örtlicher Zusammenhang zwischen Geometrie und Materialdehnung [Zimmerling et al. 2019]
  - Gut darstellbar in Grauwertbildern
  - Einsatz von ML-Techniken der Bildverarbeitung (Neuronale Faltungsnetze)
- Zweistufige Funktion  $\mu$  [Zimmerling et al. 2020]
  1.  $\mu_1$  : Abschätzen des Dehnungsfelds  $\gamma$
  2.  $\mu_2$  : Interpretation des Dehnungsfelds, Ableiten günstiger Prozessparameter



[Zimmerling et al. 2020]


# Prozessoptimierung für variable Geometrien

## Trainingsverlauf




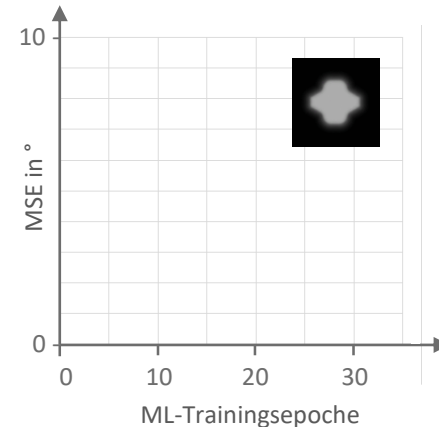
### Training von $\mu_1$

- Datensatz mit Drapiersimulationen
- Training: Iterative Anpassung der Kernel- und Netzparameter
- Minimierung der Vorhersageabweichung (MSE)




Datensatz mit Prozessbeispielen

$$\text{MSE} = \frac{1}{n_s} \sum_{j=1}^{n_s} (\hat{y}_j - r_j)^2$$



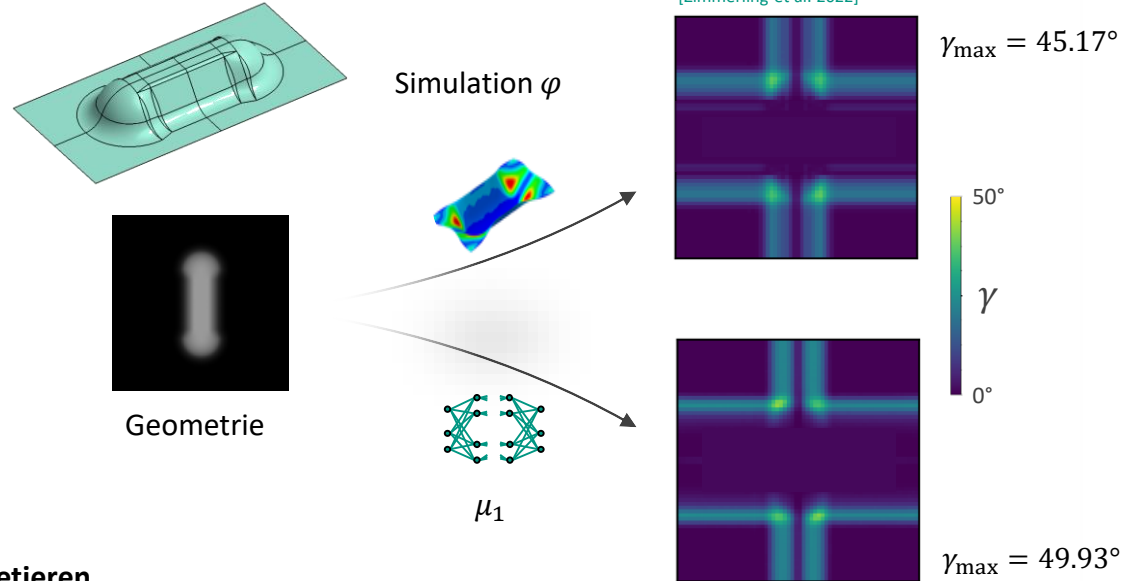
Darstellung aus [Trippe, 2019]



### Test von $\mu_1$ (Beispiel)

- Double-Dome Geometrie
- Keine Teilmenge der Trainingsdaten
- Validierung der ML-Schätzung
  - Sinnvolles Dehnungsfeld
  - $\Delta(\gamma)_{\max} = 4.8^\circ$  ( $\approx 10.4\%$ )
- Genauigkeit vom Datensatz abhängig
  - Anzahl Drapiersimulationen
  - Geometrievielfalt (!)

→ **Bildbasierte Ansatz geeignet  
veränderliche Geometrien zu interpretieren**





Motivation

Stand der Technik und Forschungsfragen

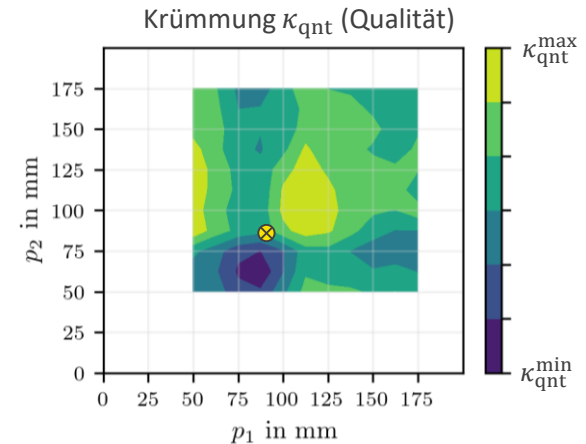

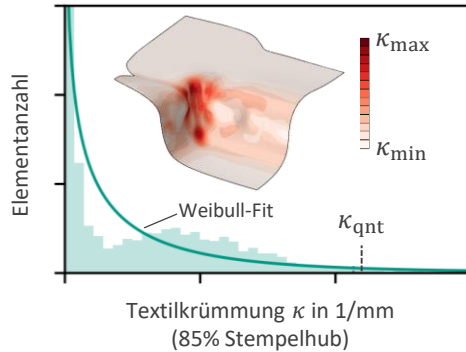

Methodik

**Anwendungsbeispiel**

Zusammenfassung und Ausblick

### Niederhalterunterstützte Textilumformung [Zimmerling et al. 2022b]

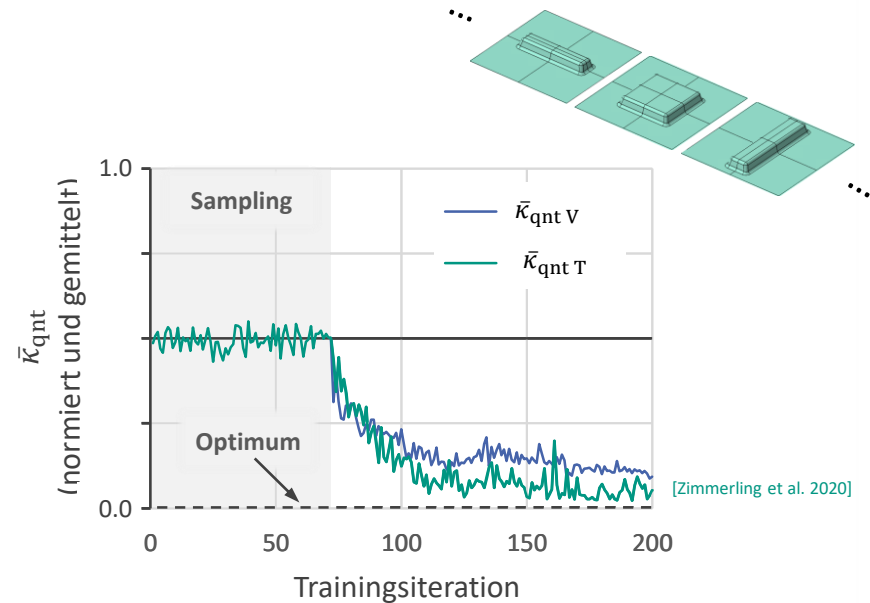

- Geometriekatalog: Quadergeometrien
- Positionierbare Niederhalter am Umfang
- Ziel: Textil möglichst glatt in die Form ziehen  
→ Textilkrümmungen messen Qualität





### Reinforcement Learning [Sutton/Barto 2018]

- Samplingphase mit Zufallsparametern
- Minimierung der Textilkrümmungen  $\kappa$  für...
  - 14 Trainingsgeometrien
  - 5 ‚unbekannte‘ Validierungsgeometrien




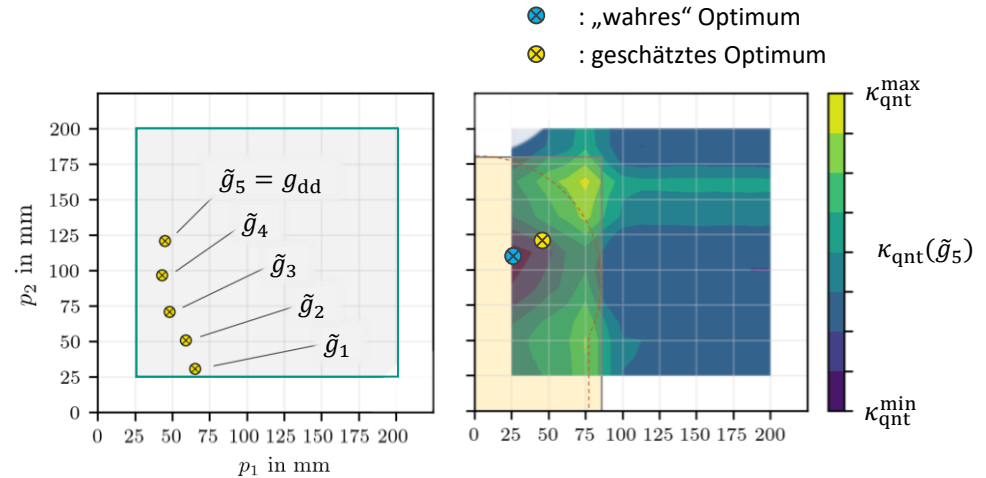
### Nach ML-Training

- Erprobung an neuen Geometrievarianten
  - Doppelt-symmetrisch und weitgehend konvex
  - Außerhalb der Quader-Geometrien
- ML-Empfehlungen folgen Geometrievariation
- Brauchbare Prozessempfehlung (ca. 10% Abweichung)

### Hypothese 1



Es ist möglich, mit ML-Verfahren und Simulationstechnik Prozesswissen aus generischen Beispielen zu extrahieren und auf neue Geometrien anzuwenden



[Zimmerling et al. 2022b]

# Prozessoptimierung für variable Geometrien

## Ergebnisse




### Beobachtung

- Prozessempfehlung brauchbar, aber noch nicht optimal

### Daher

- Fortsetzung des Trainings auf Zielgeometrie (Double-Dome)
- Konvergenz in die Nähe des Optimums
- Schrittweise Reduktion der Textilkrümmungen

→ erfolgreiche Optimierung



### Vergleich der drei Verfahren

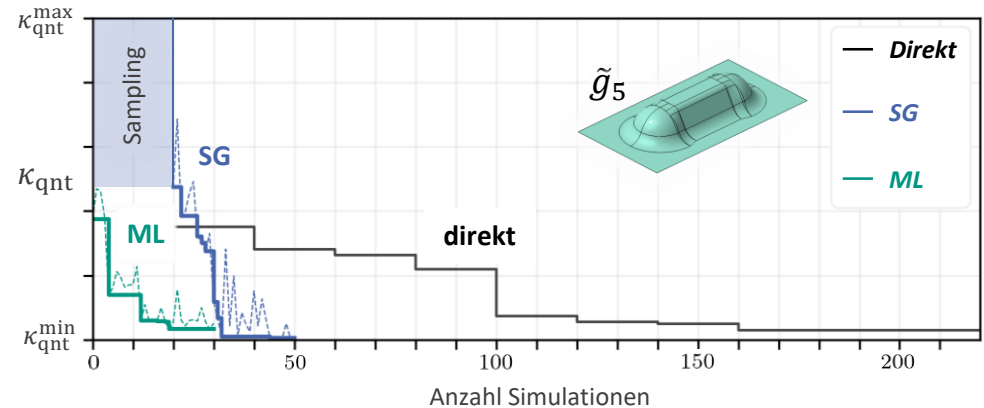
- **Direkt** (ohne Surrogate)
- **SG** (Surrogate nach SdT)
- **ML** (Surrogate mit Geometrieinformation)

### Beobachtung

- **SG** und **ML** schneller als **direkt**  
→ Integration von Vorwissen
- **ML** erscheint schneller als **SG**  
→ Einsparung des bauteilspezifischen Samplings

### ML-Algorithmus vortrainiert

- Erheblicher Aufwand
- Entkopplung von Vortraining und Anwendung



### Hypothese 2



Einmal (vor-)trainiert, kann so ein ML-Modell die Optimierung beschleunigen, ähnlich wie ein klassisches Surrogate

# Agenda



Motivation

Stand der Technik und Forschungsfragen

Methodik

Anwendungsbeispiel

**Zusammenfassung und Ausblick**

### Ausgangssituation




- Surrogate-Modelle unterstützen Optimierungsrechnungen, erweisen sich aber als unhandlich bei variablen Geometrien

### Methodik

- Zweistufige, ML-basierte Optimierungsmethodik für variable Geometrien
- Validierung auf ‚neuen‘ Geometrien und Vergleich mit klassischen Optimierern


### Ergebnisse

- Prozessdynamik aus generischen Beispielen erlern- und übertragbar
- Prozessempfehlungen konvergieren zum Optimum ähnlich zu einem klassischem Surrogate



### Anwendungsfall

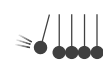


- Komplexere Szenarien
  - Komplexere Geometriecharakteristiken
  - Weitere Prozessparameter oder zeitliche Auflösung
- Weitere Prozesse



[nabertherm.com]


### Weiteres Vorwissen

- Integration physikalischer Gesetze im Training (PINNs) [Raissi et al. 2019]  
→ Physikalisch konsistentes Surrogate für Optimierung [Würth 2022]


$$\sum_{l=1}^3 \frac{\partial \sigma_{lk}}{\partial x_l} + f_k = \rho \frac{\partial^2 u_k}{\partial t^2}$$

$$\frac{\partial \rho}{\partial t} + \nabla(\rho u) = 0$$

$$\frac{\partial T}{\partial t} - a \Delta T = h_{inh}$$

### Komplexere ML-Ansätze

- Graph Neural Networks für weitere Generalisierung




## Alphabetisch geordnet

- Albrecht et al. 2019** F. Albrecht, C. Zimmerling, C. Poppe, L. Kärger, F. Henning:  
Development of a modular draping test bench for analysis of infiltrated woven fabrics in wet compression molding. *Key Engineering Materials*, 809, 2019
- Bonte et al. 2007** M.H.A. Bonte, A.H. van den Boogaard, J. Huétink:  
A Metamodel Based Optimisation Algorithm for Metal Forming Processes, *Advanced Methods in Material Forming*, 2007
- Guo et al. 2016** X. Guo, W. Li and F. Iorio:  
Convolutional neural networks for steady flow approximation. *Proceedings of the 22nd ACM*, 2016
- ISO TR 581** ISO Technical Report 581. *Weldability of metallic materials - General principles*, 2005.
- Kärger et al. 2015** L. Kärger, A. Bernath, F. Fritz, S. Galkin, D. magagnato, A. Oeckerath, A. Schön, F. Henning:  
Development and validation of a CAE chain for unidirectional fibre reinforced composite components, *Composite Structures*, 132, 2015
- Pfrommer et al. 2018** J. Pfrommer, C. Zimmerling, J. Liu, F. Henning, L. Kärger, J. Beyerer:  
Optimisation of manufacturing process parameters using eep neural networks as surrogate models, *Procedia CIRP*, 72, 2018
- Poppe et al. 2018** C. Poppe, D. Dörr, F. Henning, L. Kärger:  
Experimental and numerical investigation of the shear behaviour of infiltrated woven fabrics, *Composites Part A*, 114, 2018.
- Poppe et al. 2019** C. Poppe, T. Rosenkranz, D. Dörr, L. Kärger:  
Comparative experimental and numerical analysis of bending behaviour of dry and low viscous infiltrated woven fabrics, *Composite Part A*, 124, 2019.
- Raissi et al. 2019** M. Raissi, P. Perdikaris and G. E. Karniadakis:  
PINNs: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Comput. Physics*, 378, 2019.



- Sutton and Barto 2018** R.S. Sutton and A. Barto:  
Reinforcement learning - An introduction. *MIT Press*, Cambridge/USA and London/United Kingdom, 2 edition, 2018
- Trippe 2019** D. Trippe: Untersuchung der Eignung tiefer neuronaler Netze zur zeiteffizienten Bewertung der Drapierbarkeit endlosfaserverstärkter Bauteile.  
Masterarbeit (Betreuer C. Zimmerling), Karlsruher Institut für Technologie - Institute für Fahrzeugsystemtechnik (KIT-FAST), Karlsruhe, 2019.
- Würth 2022** T. Würth: Solving parametric PDEs with physics-informed neural networks – An example from composite manufacturing.  
Masterarbeit (Betreuer C. Krauß und C. Zimmerling), Karlsruher Institut für Technologie - Institut für Fahrzeugsystemtechnik (KIT-FAST), Karlsruhe, 2019.
- Zimmerling et al. 2019** C. Zimmerling, D. Trippe, B. Fengler, L. Kärger: An approach for rapid prediction of textile draping results for variable composite component geometries using deep neural networks. *AIP Conference Proceedings*, 2113: Art. 020007, ESAFORM 2019, Vittoria-Gasteiz/Spain, 2019
- Zimmerling et al. 2020** C. Zimmerling, C. Poppe, L. Kärger: Estimating optimum process parameters in textile draping of variable part geometries - A reinforcement learning approach. *Procedia manufacturing*, 47, ESAFORM 2020, Cottbus/Germany, 2020
- Zimmerling et al. 2021** C. Zimmerling, P. Schindler, J. Seuffert, L. Kärger: Deep neural networks as surrogate models for time-efficient manufacturing process optimisation. *PoPuPS of ULiège Library*, DOI: 10.25518/esaform21.3882, ESAFORM 2021, Liège/Belgium, 2021
- Zimmerling et al. 2022** C. Zimmerling, B. Fengler, L. Kärger: Formability Assessment of Variable Geometries using Machine Learning – Analysis of the Influence of the Database. *Key Engineering Materials*, 926, ESAFORM 2022, Braga/Portugal, 2022
- Zimmerling et al. 2022b** C. Zimmerling, C. Poppe, O. Stein, L. Kärger: Optimisation of manufacturing process parameters for variable component geometries using reinforcement learning, *Materials and Design*, 214, 2022



# Vielen Dank

für die Förderung und Unterstützung.

