

Zeit- und kosteneffiziente Prozess- und Produktentwicklung für den Hochleistungs-Faserverbundleichtbau unterstützt durch Techniken des Maschinellen Lernens


Clemens Zimmerling¹, Luise Kärger¹, Stefan Carosella², Peter Middendorf², Frank Henning¹

¹ Institut für Fahrzeugsystemtechnik – Leichtbautechnologie

| KIT

² Institut für Flugzeugbau

| Universität Stuttgart

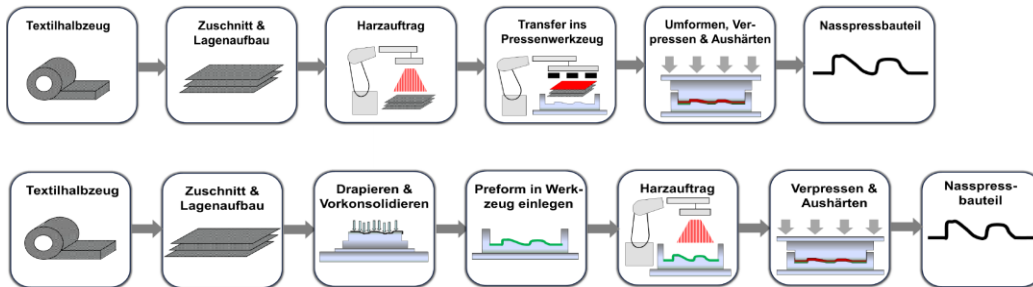


Projektziele

Forschungsbrücke Karlsruhe-Stuttgart

Fachliche Ziele


- Vergleich und Bewertung zweier Prozessrouten
- Physikalisch-basiertes Prozessverständnis



- Methodenentwicklung zur kombinierten Umformungs- und Formfüllsimulation
- Ganzheitliche Prozess- und Produktoptimierung Anhand einer virtuellen Prozesskette
- Optimierte Bauteilauslegung inklusive Fatigue-Betrachtung

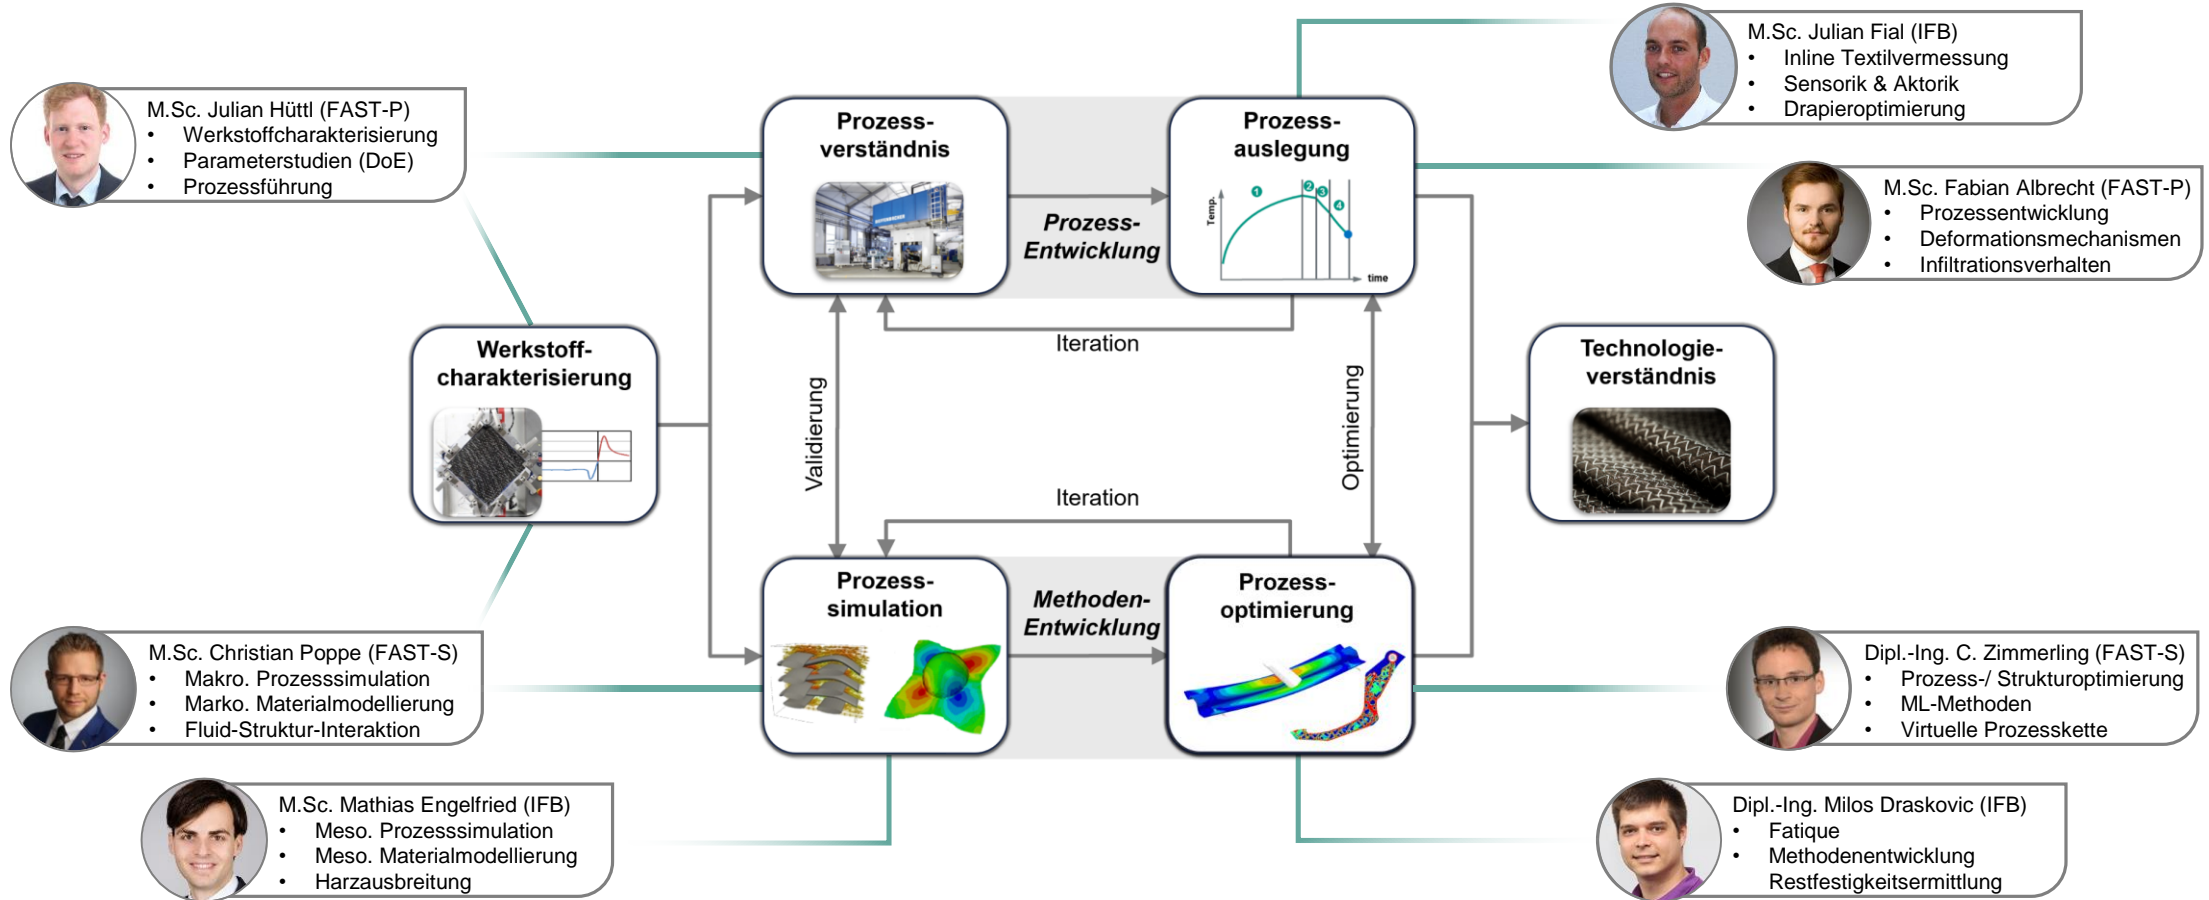
Strategische Ziele

- Kompetenzbündelung für den Leichtbau in BW
- Erhöhung der Sichtbarkeit



- Synergien nutzen und Redundanzen vermeiden
- Potential des Nasspressens für effiziente Prozesse aufzeigen
- Gemeinsame Drittmittelwerbung
- Stärkung der Industriekontakte
- Nutzen der Erfahrungen aus dem RTM-Prozess


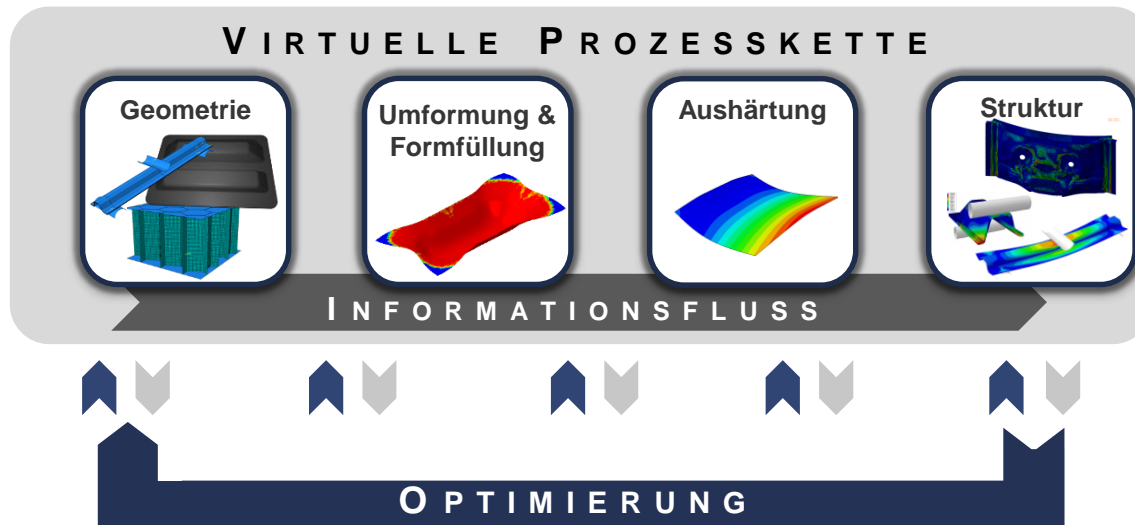
Fachliche Ziele



Motivation

Virtuelle Prozesskette

Simulationsmethoden



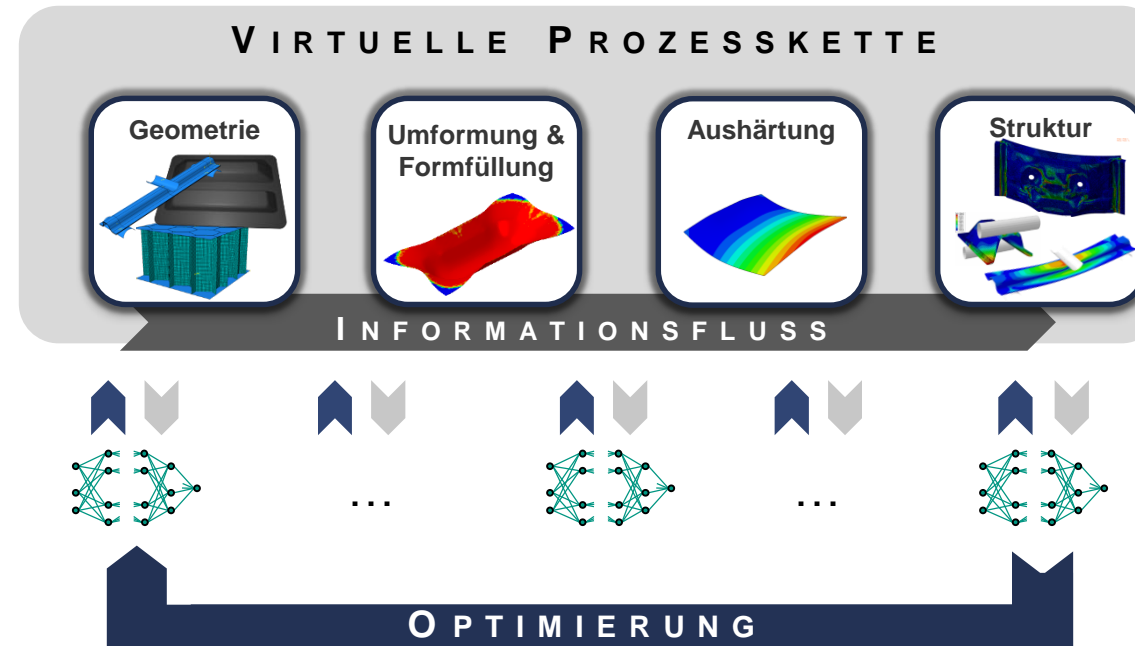
Simulation Nasspressen:
Simultane Umformung und Fluidausbreitung [1]

- Virtuelle Prozesskette zur Bewertung der Herstellbarkeit von FKV
- Berücksichtigung von Prozesseffekten in Struktursimulation
 - ✓ Reduktion teurer Trial-Error-Versuche (Material, Werkzeuge)
 - ⚙️ Rechenaufwand (iterative Optimierungen)

Motivation

Virtuelle Prozesskette

Prozessoptimierung



Ansatz zur weiteren Zeit- und Kostenreduktion

- Berücksichtigung verfügbaren Vorwissens in der virtuellen Produktentwicklung durch Techniken des Maschinenslernens (ML)
- Integration von ML-Methoden zur Prozessüberwachung und –steuerung (Sensorik, Aktorik)

Prozessoptimierung

Übersicht

Ausgangssituation

- Sicht auf Prozesssimulation

$$\varphi_{\text{sim}} : P \mapsto Q$$


Prozessparameter \uparrow \downarrow Beobachtete Prozessantwort

- Ziel: Optimaler Prozesspunkt



$$p_{\text{opt}} \in P \quad \text{mit} \quad q_{\text{opt}} = q(p_{\text{opt}}) \rightarrow \max, \min$$

- Herausforderung:
Zahlreiche Iterationen für globale Optima
→ Rechenzeit steigt

- Idee:
Integration von Vorwissen zur Konzentration
teurer Simulationen auf meistversprechende Punkte



Direkte Kopplung von Optimierer und Simulation



Verlauf der direkten Optimierung (Variation Angusspunkt)
Zahlreiche ‚untaugliche‘ Lösungsvorschläge berechnet

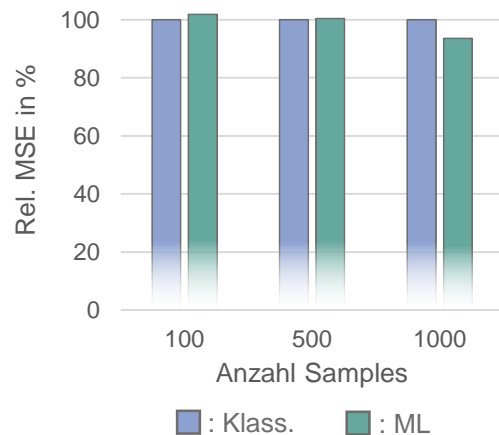
Prozessoptimierung

Ansätze

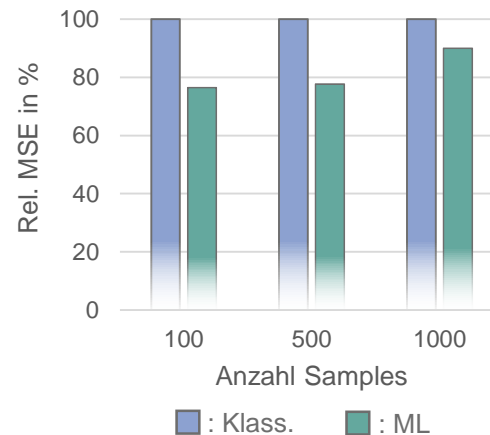
ML-Integration in Prozessoptimierung

- ML-Algorithmen anstelle klassischer Regressionstechniken
- Verbesserte Ausnutzung verfügbarer Daten insbesondere bei ...
 - ... wenigen Samples
 - ... höheren Dimensionen
 - ... komplexere Dynamiken

2 Prozessparameter




8 Prozessparameter



Klassisch



Regressionsmodell für Performance-Skalar



$$t_{\text{fill}} = 9.853 \text{ s}$$

Maschinelern-Ansatz

Erlernen des gesamten Systemverhaltens



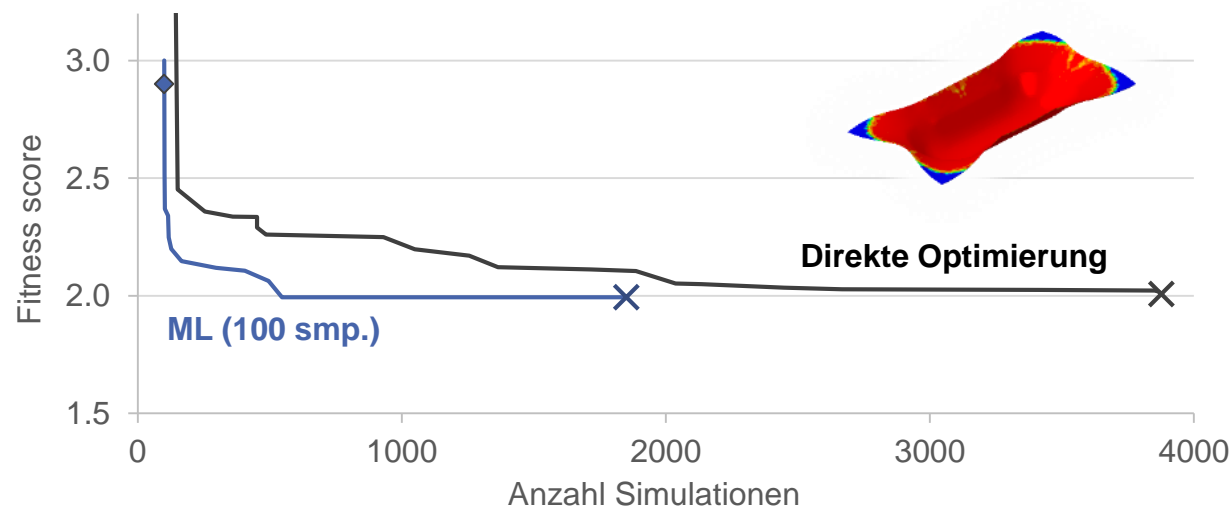
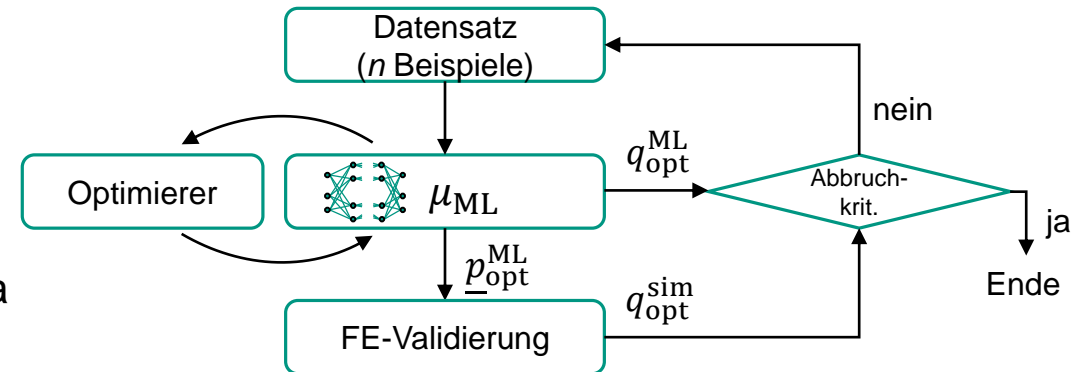
$$0 \quad t_{\text{fill}} \quad t_{\text{max}}$$

Prozessoptimierung

Beschleunigung der Optimierung

ML-Integration in Prozessoptimierung

- Optimierung auf Ersatzmodell
 - ML-Modell ‚leitet‘ die Suche des Optimierers
 - Rückführung in Datensatz
 - Sukzessive Verfeinerung des ML-Modells nahe Optima



- Ergebnis
 - Weniger Simulationsaufrufe
 - Schneller als direkte Optimierung
 - Besseres Ergebnis gefunden


Prozessoptimierung

Übersicht


ML-Integration in Prozessoptimierung

- Optimierung auf Ersatzmodell
 - Konzentration auf meist-versprechende Parameterräume
 - Untaugliche Lösungen vorab ausgeschlossen


direkt




ML-unterstützt



Iteration
1 ... 200



Iteration
400 ... 600

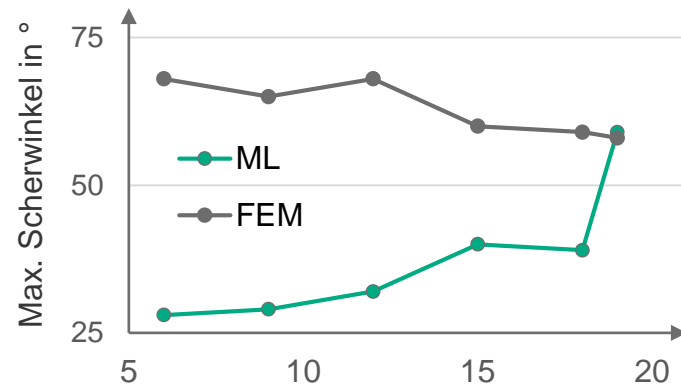



Prozessoptimierung

Umformung

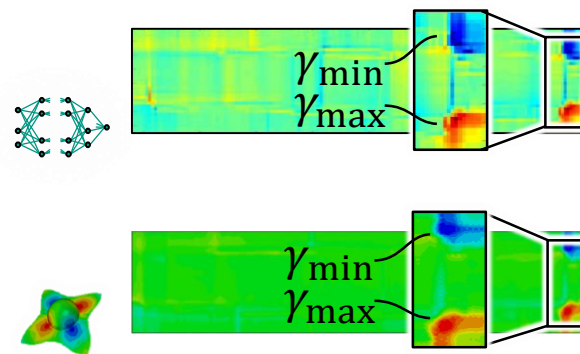
ML-Integration in Prozessoptimierung

- Anwendung in der Textilumformung
- Optimierung Materialzuführung (Greifer)
 - 50 Rückhaltekräfte
 - Scherwinkel minimiert



Quelle: [1]

Hinzugefügte Simulationen



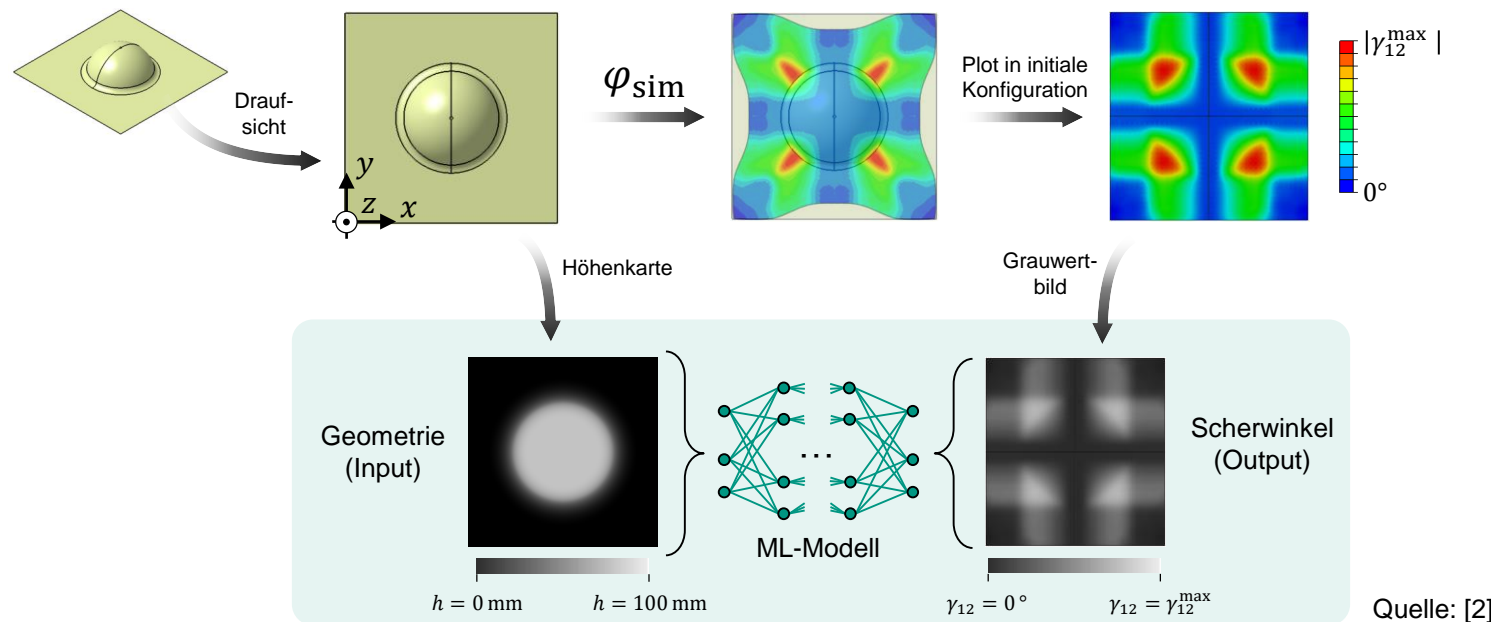
Vergleich ML-Modell und FE-Simulation

Ergebnis

- ML-Algorithmus sukzessive verfeinert
- wenige Modellupdates ausreichend
- Konzentration auf Optima

Berücksichtigung flexibler Geometrien

- Flexible Geometrien
 - Räumlicher Zusammenhang zwischen Bauteilkrümmung und Materialdehnung
 - Pixelbasierte Datenstruktur ermöglicht Einsatz von ML-Techniken der Bildverarbeitung



Quelle: [2]



Geometriebewertung

Umformung

Berücksichtigung flexibler Geometrien

■ Neuronale Faltungsnetze zur Bildregression

- Filtern von Eingangsdaten mit Kernel-Matrizen („Schablone“) (Convolution)
- Übereinstimmungen aktivieren Neuronen in nächster Schicht
- Schichtweise Komprimieren („Codieren“) drapierrelevanter Geometrieinformationen
- Interpretation der codierten Informationen durch Umkehroperationen (Deconvolution)




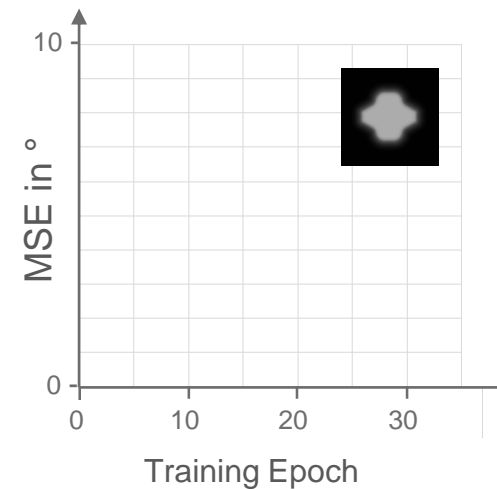
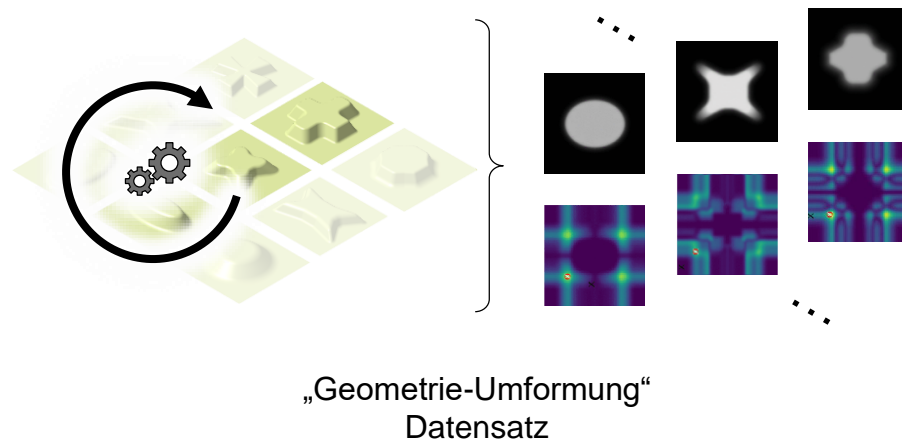
Quelle: [2]

Geometriebewertung


Umformung

Berücksichtigung flexibler Geometrien


- Training der Algorithmen
 - Drapiersimulationen für verschiedene Geometrien (einfach/doppelt gekrümmt, Konvex/Konkav,...)
 - Training: Anpassung der Filtermatrizen und neuronalen Gewichtungsfaktoren
 - Schrittweise Minimierung der Vorhersageabweichung (Mean Square Error)



Schervinkel
(Simulation)



○: Größte Abweichung
x: Höchste Verscherung



Schervinkel
(Neur. Netz)




Geometriebewertung

Umformung


Berücksichtigung flexibler Geometrien

- Unbekannte Geometrien
 - Test an Double-Dome-Geometrie (Drapier-Benchmark)
 - Keine Teilmenge der Trainingsdaten
 - Zufriedenstellende Übereinstimmung zwischen Simulation und ML-Schätzung
 - $\Delta(\gamma_{\max}) = 2.06^\circ$
 - $\Delta_{\text{rel}}(\gamma_{\max}) = 4.6\%$
- Bildbasierte Geometriebewertung grundsätzlich generalisierungsfähig





Geometry

Simulation




CNN



$$\gamma_{\max}^{\text{sim}} = 44.12^\circ$$

o: Größte Abweichung
x: Höchste Verscherung





$$\gamma_{\max}^{\text{ML}} = 42.06^\circ$$

Prozessoptimierung

Flexible Geometrien

Aktuelle Arbeiten

- Günstige Prozessführung schätzen mit ML
 - Materialzuführung lokal manipulierbar über Greifer
 - Kopplung *ML-Geometriebewertung* mit *ML-Prozessempfehlung*



Drapier-Prüfstand




Quelle: Fraunhofer, Pfinztal

Zusammenfassung

Maschinenlernen in der Prozessauslegung

Zusammenfassung

- Beschleunigung von Optimierungsrechnungen
 - ML-Modelle leiten den Optimierer
 - Konzentration ‚teurer‘ Simulationen auf meistversprechende Varianten
- Bewertung von Bauteilgeometrien
 - Pixelbasierte Datendarstellung ermöglicht Geometriebewertung
 - Numerisch effizient
- Prozessempfehlung für Bauteilentwürfe
 - Pixelbasierte Interpretation von Umformergebnissen
 - Geometrieübergreifende Empfehlung von Prozessparametern
- Ausblick
 - Algorithmen-Verfeinerung und Erweiterung Trainingsdaten
 - Praktische Erprobung



Vielen Dank



Baden-Württemberg

MINISTERIUM FÜR WISSENSCHAFT,
FORSCHUNG UND KUNST



Ansprechpartner

Dipl.-Ing. Clemens Zimmerling

clemens.zimmerling@kit.edu

+49 721 608-45409

KIT | Karlsruher Institut für Technologie

Institut für Fahrzeugsystemtechnik – Teilinstitut für Leichtbautechnologie

Rinheimer-Querallee 2 | Geb. 70.04

76131 Karlsruhe