

# Machine learning algorithms for efficient process optimisation of variable geometries at the example of fabric forming <sup>1</sup>

Clemens Zimmerling

Karlsruhe Institut für Technologie (KIT), Institut für Fahrzeugsystemtechnik – Institutsteil Leichtbau

## 1. Motivation

Für eine optimale Bauteilqualität erfordern industrielle Produktionssysteme eine sorgfältige Einstellung der eingesetzten Fertigungsprozesse. Dabei ist die Ermittlung der optimalen Prozessparameter, etwa Druck oder Temperatur, oft mit kostenintensiven Versuchsreihen verbunden. Dies gilt besonders für komplexe Prozesse und Materialien wie faserverstärkte Kunststoffe und macht die Prozessoptimierung bzw. den Produktionshochlauf zu einem wirtschaftlichen Flaschenhals für neue Bauteile und Prozesse.

Für eine optimale Herstellbarkeit müssen Bauteilgeometrie, Werkstoff und Prozess aufeinander abgestimmt sein. Numerische Simulationen, etwa mittels FEM<sup>2</sup>, können diese Prozessauslegung wirksam unterstützen und teure Prozessversuche reduzieren, jedoch sind deren Rechenzeiten oft eine erhebliche Hürde, insbesondere bei iterativen Optimierungsrechnungen. Bauteilindividualisierungen nach Kundenwunsch und kürzere Entwicklungszyklen verschärfen diese Situation zusätzlich. Entsprechend ist groß ist der Bedarf an effizienten Methoden zur Prozessoptimierung für variable Bauteilgeometrien.

In der Dissertation wird untersucht, wie jüngste Fortschritte im Maschinernen (ML) – im Speziellen bei neuronalen Netzen – die Prozessoptimierung bei veränderlichen Bauteilgeometrien unterstützen können. Dabei werden zwei Hauptaspekte betrachtet, nämlich

1. die Eignung von ML-Verfahren zur effizienten Abschätzung der Herstellbarkeit neuer Bauteilentwürfe und
2. ihr Potential zur effizienten Prozessoptimierung für variable Bauteilgeometrien.

Diese Fragestellungen werden am Beispiel der Textilumformung für endlosfaserverstärkte Kunststoffe untersucht, sind aber grundsätzlich technologieübergreifend anwendbar.

## 2. Lösungsansatz über Maschinernen

Das Grundkonzept der Arbeit ist in Abb. 1 dargestellt.

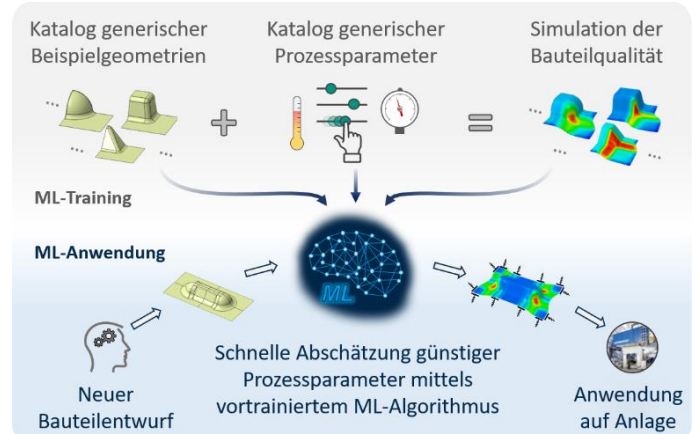


Abb. 1: Grundidee der Dissertation. Ein ML-Algorithmus lernt anhand von generischen Prozessbeispielen, die Herstellbarkeit und optimale Prozessführung für neue Bauteilvarianten zu schätzen.

Die Idee ist, dass ein ML-Algorithmus anhand von umfangreichen Prozessbeispielen den Zusammenhang zwischen Geometrie, Bauteilqualität und optimaler Prozessführung lernt. Nach dem Training soll er die Herstellbarkeit neuer Bauteilvarianten effizient abschätzen und Empfehlungen zur Prozesseinstellung aussprechen können.

Das Training des Algorithmus erfolgt mittels „Reinforcement Learning“ und ist in Abb. 2 veranschaulicht.

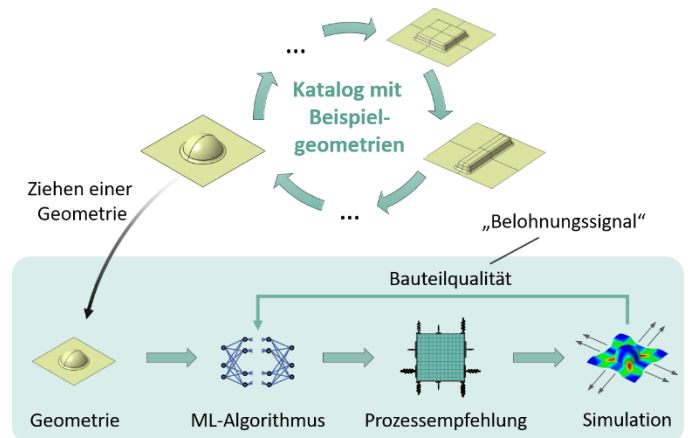


Abb. 2: Ablauf des ML-Trainings. Der Algorithmus zieht Geometrien, analysiert sie und gibt Prozessempfehlungen ab. Verbessern sie die Bauteilqualität, wird der Algorithmus „belohnt“.

<sup>1</sup> Maschinernen zur effizienten Prozessoptimierung bei veränderlichen Bauteilgeometrien am Beispiel der Textilumformung

<sup>2</sup> Finite Elemente Methode

Zunächst wird ein Katalog mit generischen Trainingsgeometrien definiert. Während des Trainings zieht der Algorithmus fortlaufend Geometrien aus dem Katalog, analysiert diese und gibt eine Prozessempfehlung ab. Verbessern diese Empfehlungen die Bauteilqualität, wird der Algorithmus „belohnt“, sodass er künftig bei ähnlichen Geometrien ähnliche Empfehlungen ausspricht. Über dieses Trial-Error-Verfahren lernt er schrittweise, welche Bauteilgeometrie welche Prozessführung erfordert. Aufgrund der Vielzahl der benötigten Daten wird das Training automatisiert mit FEM-Prozesssimulation durchgeführt.

### 3. Anwendungsbeispiel „Textilumformung“

Der ML-Ansatz wird in der Arbeit im Kontext der Textilumformung für Hochleistungs-Faserverbunde untersucht. Im Speziellen wird die Umformung von Kohlenstofffasergewebe mit Hilfe von Niederhaltern (NDH) betrachtet, vgl. Abbildung 3.




Abb. 3: Beispielumformung einer Quadergeometrie unterstützt durch Niederhalter. Je nach Position können die Niederhalter Faltenwurf während der Umformung reduzieren oder verstärken.

Die NDH können über den Umfang des Bauteils freipositioniert werden und beeinflussen je nach Position den Faltenwurf des Textils während der Umformung. Während des Trainings lernt der Algorithmus, die örtliche Verteilung der entstehenden Materialdehnungen (Maß für die Herstellbarkeit) und die optimalen NDH-Positionen zu schätzen. Dabei hängt die optimale NDH-Position stark von der Geometrie des Bauteils ab.

### 4. Ergebnisse

Nach dem Training mit generischen Geometrien, wird der Algorithmus genutzt, um für neue Geometrien eine Schätzung der Scherwinkel (Herstellbarkeit) und eine Optimierung der NDH-Positionen vorzunehmen. Die nachfolgenden Abbildungen zeigen einen Ausschnitt der Ergebnisse.

Abbildung 4 vergleicht die Simulation und ML-Schätzung der entstehenden Materialdehnungen (Scherwinkel) der untersuchten Geometrie. Obwohl die Geometrie neu für den ML-Algorithmus ist, liefert er eine technisch brauchbare Schätzung für die örtliche

Verteilung und der Größe der Dehnungen. Er hat also erfolgreich Wissen aus generischen Beispielen extrahiert und auf eine neue Auslegungssituation angewandt.




Abb. 4: Vergleich von Simulation und ML-Schätzung der entstehenden Materialdehnungen für eine neue Geometrie.

Abbildung 5 vergleicht die Optimierungsgeschwindigkeit des neuen ML-Algorithmus mit einem „klassischen“ Optimierer (genetischer Algorithmus).

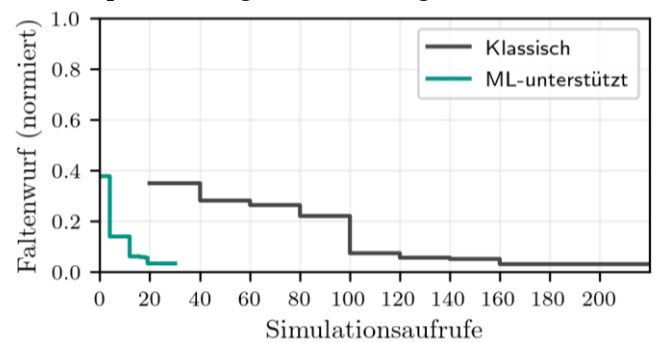


Abb. 5: Vergleich der Optimierungsgeschwindigkeit der ML-unterstützten Methode und eines „klassischen“ Optimierers.

Beide Methoden minimieren erfolgreich den Faltenwurf des Textils, allerdings benötigt die ML-Methode deutlich weniger Simulationsaufrufe (ca. 20 statt 160) und ist damit deutlich effizienter.

### 5. Zusammenfassung

Die vorliegende Arbeit zeigt, dass ML-Techniken die Prozess- und Produktoptimierung zu frühen Entwicklungszeitpunkten effizient unterstützen können. Ähnlich einem erfahrenen Prozessexperten, können sie die Herstellbarkeit neuer Bauteilvarianten schnell und treffend bewerten und Empfehlungen zur Prozessführung aussprechen. Damit reduzieren sie die Aufwände zur Prozesseinrichtung und sind ein wichtiger Schlüssel für die effiziente Produktion kleiner Losgrößen und individualisierter Bauteile.

Die Ergebnisse der Arbeit münden in Folgefragen zur Weiterentwicklung der Methoden: Beispielsweise die Übertragung auf andere Fertigungsprozesse oder die Integration physikalischer Bilanzgleichungen, um ML-Prognosen noch belastbarer zu machen.

### 6. Literatur

Alle Quellen sind in der Dissertationsschrift zu finden:

- C. Zimmerling. *Machine learning algorithms for efficient process optimization of variable geometries at the example of fabric forming*. Dissertation am Karlsruher Institut für Technologie (KIT), 2022 (zur Publikation angenommen).