

KI-Innovationen im Kunststoffspritzguss: Effizienzsteigerung durch Prozess-Simulationen in der Wasserinjektionstechnik

Florian Dirisamer (Digital Physics AI GmbH)

Eva Heiml, Markus Wimmer (Plastic Innovation GmbH)

Ziel dieses Artikels ist es, ein tiefgreifendes Verständnis für die vielseitigen Möglichkeiten von Künstlicher Intelligenz in Finite-Elemente- und Computational-Fluid-Dynamics-Simulationen zu vermitteln. Besonderes Augenmerk liegt dabei auf der Optimierung der Systemeffizienz und dem effektiven Umgang mit inversen Problemstellungen sowie systemspezifischer Black-Box-Komponenten. Der Einsatz von KI-Techniken eröffnet den Ingenieur*innen neue Wege zur Effizienzsteigerung und ermöglicht einen souveränen Umgang mit hochkomplexen Komponenten. Diese technologischen Fortschritte haben weitreichende Auswirkungen auf die Ingenieurspraxis und tragen weiters maßgeblich zur Entwicklung sicherer, innovativer und effizienter Systeme bei; das wiederum treibt Fortschritte in verschiedensten Industriezweigen voran.

In diesem Artikel wird anhand eines Schemabauteils die Ermittlung von notwendigen Prozess- und Maschinenparameter für die geforderte Bauteilqualität mithilfe der inversen Lösung durch das Training einer Künstlichen Intelligenz beschrieben, ohne dabei ein komplexes Optimierungsproblem lösen zu müssen.

Zusätzlich wird erläutert, wie durch die Umstellung der Problemstellung auf eine direkte Vorhersage die Wandstärkenverteilung in einem Bauteil ohne den Bedarf zusätzlicher Simulationen und Berechnungen bestimmt wird. Diese Vorhersagen der Prozess- und Maschinenparameter können, abhängig von der Datenverfügbarkeit, mit hinreichend hoher Genauigkeit realisiert werden. Dieser Ansatz präsentiert somit eine fortschrittliche Möglichkeit, Prozesse in der Ingenieurspraxis präzise zu steuern und verdeutlicht das Potenzial der KI in der Gestaltung zukünftiger Systeme.

Dieser innovative Ansatz ermöglicht eine erhebliche Reduktion der Entwicklungszeit und trägt dazu bei, den Material- und Ressourcenaufwand erheblich zu minimieren.

1. Motivation

Die Integration von Künstlicher Intelligenz (KI) hat in zahlreichen Branchen transformative Veränderungen bewirkt, und auch im Bereich des computergestützten Engineerings (CAE) zeigt sich ein nachhaltiger Einfluss. Ziel dieses Beitrags ist es, das Potenzial von KI in der Finite-Elemente-Methode (FEM) und der numerischen Strömungsmechanik (CFD) eingehend zu untersuchen, wobei besonderes Augenmerk auf der Optimierung der Systemeffizienz sowie der Bewältigung von Herausforderungen im Zusammenhang mit inversen Problemen und systemspezifischen Black-Box-Komponenten liegt.

Der Artikel präsentiert innovative Ansätze, wie KI dazu beitragen kann, FEM- und CFD-Simulationen nicht nur effizienter zu gestalten, sondern auch die Handhabung inverser Probleme und systemspezifischer Black-Box-Komponenten zu verbessern. Die Effizienzsteigerung spielt eine entscheidende Rolle in der technischen Entwicklung, da sie direkte Auswirkungen auf die zeitliche und ressourcenbezogene Zuweisung hat. Mithilfe von KI-Techniken wie maschinellem Lernen und Optimierungsalgorithmen können FEM- und CFD-Simulationen beschleunigt werden, ohne dabei an Genauigkeit einzubüßen. Dies ermöglicht nicht nur eine beschleunigte Entwicklung von Produkten und Systemen, sondern trägt auch zur Kostenreduktion und effizienteren Ressourcennutzung bei.

Ein weiterer signifikanter Aspekt ist die Bewältigung von Problemen im Zusammenhang mit Black-Box-Komponenten. KI-Modelle können dazu beitragen, komplexe Zusammenhänge in solchen Systemen zu

verstehen und vorherzusagen, selbst wenn die zugrunde liegenden Mechanismen nicht vollständig transparent sind. Dies eröffnet neue Möglichkeiten zur Lösung von Herausforderungen in verschiedenen technischen Anwendungen, bei denen herkömmliche Methoden an ihre Grenzen stoßen.

Insgesamt zeigt sich, dass die Integration von KI in FEM- und CFD-Simulationen nicht nur die Effizienz steigert, sondern auch die Innovationsfähigkeit in der technischen Entwicklung vorantreibt. Die Möglichkeiten, die sich durch den Einsatz von KI ergeben, sind vielfältig und versprechen tiefgreifende Veränderungen in der Art und Weise, wie komplexe Systeme analysiert, optimiert und gestaltet werden. Es wird klar, dass KI eine Schlüsselrolle in der Zukunft des computergestützten Engineerings spielen wird.

2. Ansatz

Vorge stellt wird eine Fallstudie aus dem Bereich der Wasserinjektionstechnik (WIT) in Kombination mit Kunststoffspritzguss.

Das Wasserinjektionstechnikverfahren ist eine Sondertechnologie des Kunststoffspritzgusses, die darauf abzielt, komplexe Hohlstrukturen zu erzeugen. Wie auch im konventionellen Spritzgussverfahren wird hier zuerst die Formteilkavität gefüllt. Nach der Füllung erstarrt der Kunststoff von der Formteilkavität beginnend, wobei im Inneren des Bauteils schmelzflüssiger Kunststoff bis zum Zeitpunkt der Wasserinjektion verbleibt. Anschließend strömt Wasser über einen Injektor ein und drückt den Schmelzekern je nach Verfahren entweder in die Überlaufkavitäten (Verfahrensvariante: Nebenkavitätsverfahren) oder zurück in die Plastifiziereinheit (Verfahrensvariante: Masserückdruckverfahren).

Vorteile des Verfahrens:

- **Leichtbaueigenschaften:** Das WIT-Verfahren ermöglicht die Herstellung von Bauteilen mit komplexen Hohlstrukturen, das zu einer verbesserten Leichtbauweise führt.
- **Wirtschaftlichkeit:** Die Herstellung komplexer Hohlstrukturen wird in einem Massenproduktionsverfahren ermöglicht.
- **Nachhaltigkeit:** WIT ermöglicht die Substitution von energieintensiven Materialien durch nachhaltige Kunststoffe.
- **Schnellere Zykluszeiten:** Die von innen nach außen gerichtete Kühlung des Bauteils durch das eingespritzte Wasser ermöglicht kürzere Zykluszeiten bei der Produktion.
- **Geringer Verzug und hochwertige Oberflächenqualität:** Der von innen wirkende Druck des Wassers minimiert den Verzug und trägt zur Erzielung einer hochwertigen Oberflächenqualität bei.

Das WIT-Verfahren findet in verschiedenen Bereichen Anwendung, darunter die Produktion von Fahrradrahmen, Schubkarren, Griffen, Medienleitungen und anderen Bauteilen, die komplexe Hohlstrukturen erfordern.

Die für dieses Verfahren benötigten Prozesssimulationen sind sehr zeitaufwändig. Die Herausforderung besteht vor allem darin, sinnvolle Randbedingungen zu ermitteln, da eine Vielzahl von Prozess- und Materialparametern erheblichen Einfluss auf die Restwandstärkenverteilung und damit auf die Bauteileigenschaften haben. Durch die Kombination zweier Prozesse, dem Kunststoffspritzguss zur Füllung der Bauteile und der Wasserinjektionstechnik zur Schaffung der Hohlstruktur, ist eine präzise Abstimmung erforderlich, um aussagekräftige Simulationsergebnisse zu erzielen.

Ein beispielhaftes Ergebnis einer Prozesssimulation des Schemabauteils (siehe Abbildung 1) ist in Abbildung 2 dargestellt. Die durch die Verdrängung der Kunststoffschmelze entstandene Hohlkammer ist dabei in grün dargestellt. Es wurden Prozesssimulationen mit variierenden Prozessparametern durchgeführt. Um die verbleibende Wandstärke zu ermitteln, wurde das hohle Schemabauteil in Segmente unterteilt, und die Abstände zwischen der Hohlkammer und der Außenwand des Bauteils wurden ermittelt. Dadurch können die minimale und maximale Wandstärke sowie deren Positionen (Koordinaten) ermittelt werden, was eine umfassende Beurteilung der Bauteileigenschaften ermöglicht.

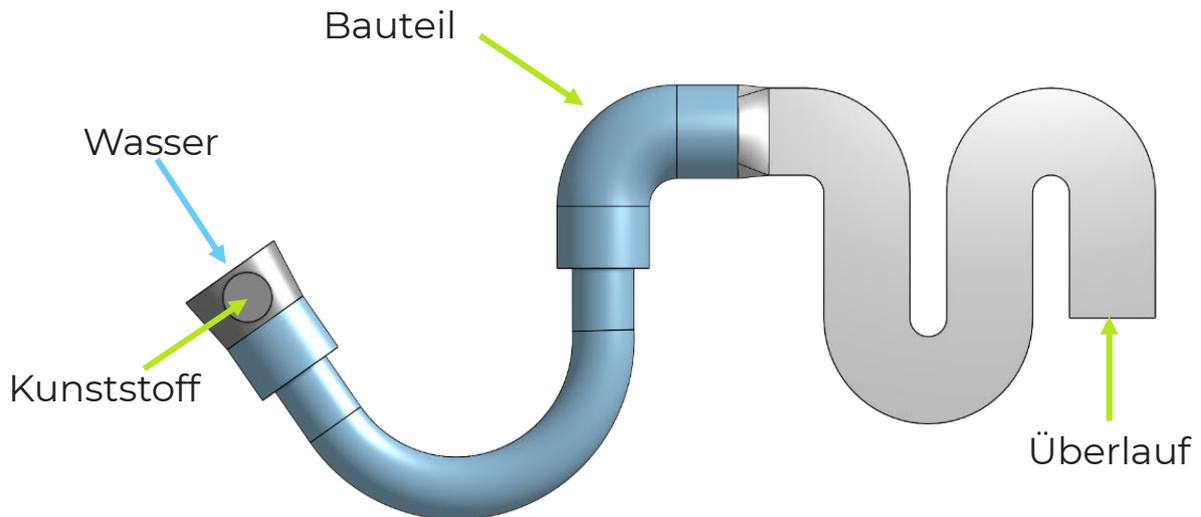


Abb. 1: Schemabauteil zur Darstellung der Anwendbarkeit von KI-Vorhersage im Kunststoffspritzguss mit Wasserinjektionstechnik mit Beschriftung der Einzelkomponenten

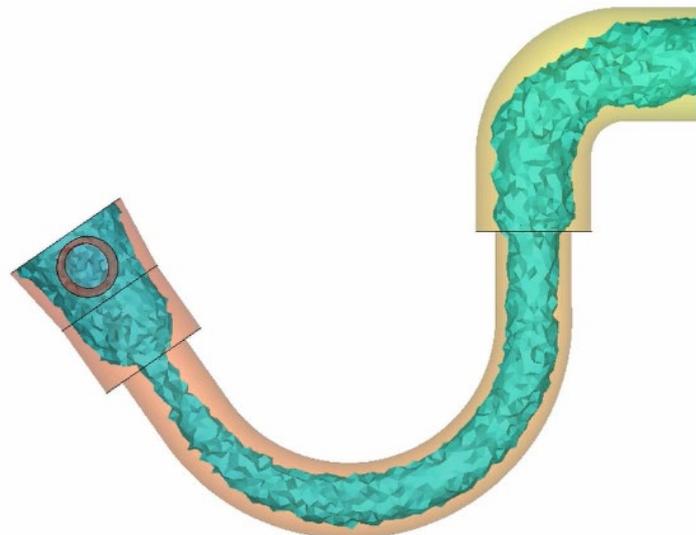


Abb. 2: Beispielhaftes Simulationsergebnis für ein Set an Material- und Prozessparameter eines durch Wasserinjektionstechnik im Kunststoffspritzguss hergestellten Bauteils mit der erzeugten Hohlkammer in grün

Die Integration von KI eröffnet neue Dimensionen in der Beschleunigung von Simulationen, insbesondere bei der effizienten Bewältigung inverser Problemstellungen. KI und vor allem Maschinelles Lernen (ML) sind revolutionäre Technologien, die in zahlreichen Industrien tiefgreifende Veränderungen bewirken. Im Zentrum des Maschinellen Lernens stehen neuronale Netze, die sich an der Funktionsweise des menschlichen Gehirns orientieren und die Fähigkeit besitzen, aus Daten zu lernen. Ein spezielles und besonders leistungsfähiges Modell eines neuronalen Netzes ist das Multilayer Perceptron (MLP). MLPs gehören zur Familie der Feedforward-Netzwerke, was bedeutet, dass die Daten durch das Netzwerk nur in eine Richtung fließen, von der Eingabe zur Ausgabe. Das Besondere an MLPs ist ihre Struktur, die aus mehreren Schichten (Layers) besteht: einer Eingabeschicht, mehreren verborgenen Schichten (Hidden Layers) und einer Ausgabeschicht. Jede Schicht ist aus Neuronen aufgebaut, die durch gewichtete Verbindungen miteinander kommunizieren. Diese Gewichte werden im Lernprozess ständig angepasst, um die Ausgabe des Netzes zu optimieren. MLPs sind besonders effektiv in der Mustererkennung und Vorhersage, da sie komplexe, nicht-lineare Beziehungen in den Daten identifizieren können. Die verwendete MLP-Struktur für die in Tabelle 1 dargestellten Parametersets wurde auf die aktuelle Anwendung angepasst und optimiert. Dabei hat sich für diese Aufgabenstellung eine MLP-Struktur mit 3

verborgenen Schichten und jeweils 32 Neuronen pro Schicht als besonders effektiv herausgestellt. Dies ist in Abbildung 3 dargestellt.

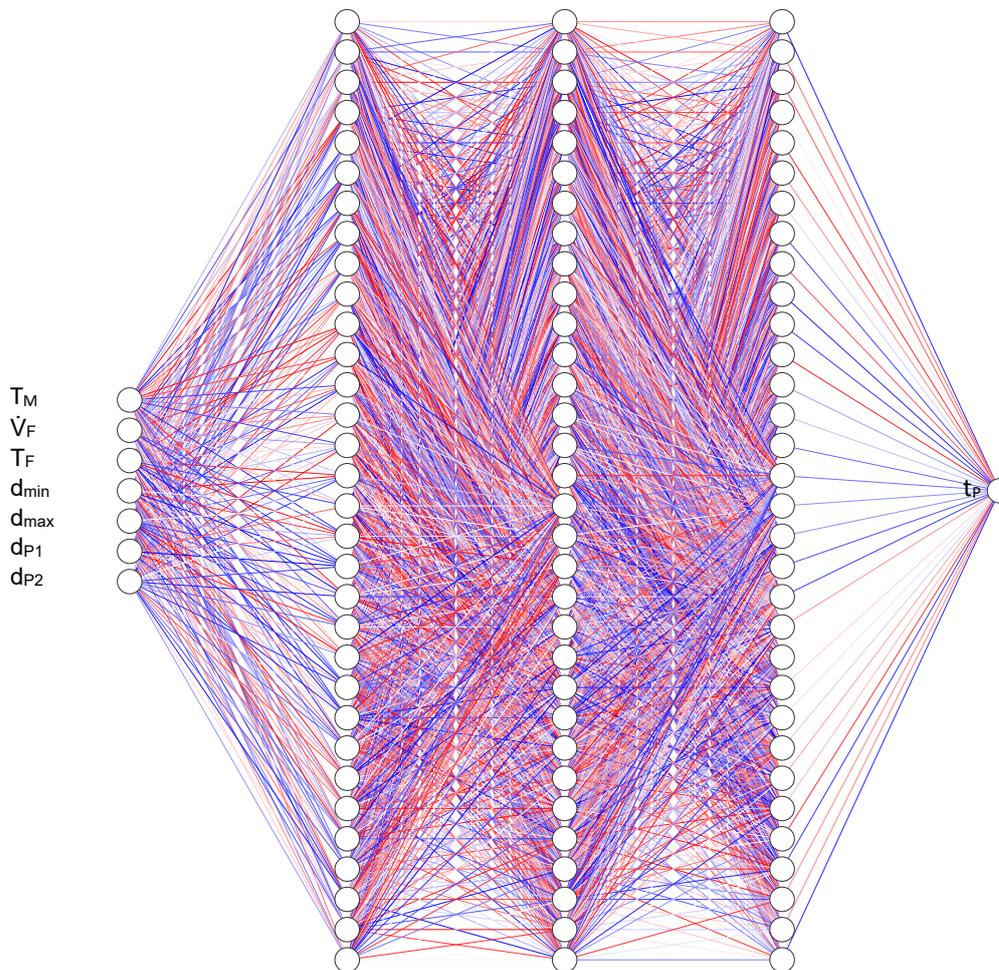


Abb. 3: Darstellung der verwendeten MLP-Struktur für die inverse Vorhersage mit beschrifteter Eingabe- und Ausgabeschicht

In der Anwendung auf inverse Probleme, wie sie im Kunststoffspritzguss auftreten, ermöglichen MLPs eine innovative Herangehensweise. Inverse Probleme sind dadurch gekennzeichnet, dass man aus einer bekannten Ausgabe (z.B. einem gewünschten Produktergebnis) auf die notwendigen Eingabeparameter (wie Temperatur, Druck usw. im Spritzgussprozess) schließen möchte. Dies ist oft komplex und rechenintensiv. MLPs können hier durch ihre Fähigkeit, Muster in Daten zu erkennen und Vorhersagen zu treffen, einen entscheidenden Beitrag leisten. Besonders in Kombination mit dem hier verwendeten No-Code KI-Tool „dAlve“, welches es ermöglicht, ohne tiefgreifende Programmierkenntnisse neuronale Netze zu erstellen und zu trainieren, öffnet sich ein breites Feld für innovative Lösungen und Effizienzsteigerungen in der Industrie.

Im hier gezeigten Beispiel können durch den Einsatz von KI auf Basis gewünschter Bauteileigenschaften und Materialeigenschaften Erkenntnisse über Prozessparameter gewonnen werden. Dies erfolgt durch die Kombination von maschinellem Lernen und Simulationsdaten, wodurch komplexe Zusammenhänge zwischen Eingangsparametern und gewünschten Ausgangsvariablen erfasst werden. Die in Tabelle 1 aufgeführten Parameter und ihre zugehörigen Wertebereiche geben detailliert an, welche Parameter in der Simulation als Randbedingungen (Eingangsparameter) festgelegt sind und welche Parameter durch die Simulation als Ergebnisse ermittelt werden (Ausgangsparameter).

Weiterhin wird verdeutlicht, welche Parameter von der KI als Eingangsparameter für die inverse Vorhersage genutzt werden und welche Parameter von der KI ermittelt werden sollen. Als Beispiele für Eingangsparameter während des KI-Trainings dienen die gewünschte Wandstärkenverteilung, Materialparameter sowie einige fixierte Prozessparameter. Als Ausgangsvariable wird dabei der noch fehlende Prozessparameter gewählt. Das durch das Training entwickelte KI-Modell ermöglicht daraufhin nicht nur schnelle Vorhersagen, sondern auch die Lösung inverser Probleme. Dies wiederum befähigt die Ingenieur*innen, optimale Maschineneinstellungen und Prozessparameter basierend auf den gewünschten Wandstärkenverteilungen zu bestimmen. Die Anwendung dieser innovativen Methodik verspricht somit nicht nur eine Beschleunigung von Simulationsprozessen, sondern auch präzise Lösungen für komplexe inverse Problemstellungen im Ingenieurwesen.

Tab. 1: Parameterset der verwendeten Prozess- und Geometrieparameter in der Simulation und für die inverse Vorhersage eines Prozessparameters

Kategorie	Parameter	Werte	Einheit	Simulation	KI
Prozessparameter	Werkzeugwandtemperatur T_M	60 125	°C	Eingang	Eingang
	Fluidvolumenstrom \dot{V}_F	150 550	cm ³ /s	Eingang	Eingang
	Fluidtemperatur T_F	20 40	°C	Eingang	Eingang
Geometrie	Wandstärke minimale d_{min}	4,5 6,5	mm	Ausgang	Eingang
	Wandstärke maximal d_{max}	21,5 23,5	mm	Ausgang	Eingang
	Wandstärke Position 1 d_{P1}	15 15,5	mm	Ausgang	Eingang
	Wandstärke Position 2 d_{P2}	24 29	mm	Ausgang	Eingang
Prozessparameter	Verzögerungszeit t_P	0,1 0,9	s	Eingang	Ausgang

Die vorgestellte Methodik stellt eine innovative Verknüpfung von physikalischen Simulationen und KI dar, die darauf abzielt, nicht nur zeitliche Einsparungen bei den Simulationen zu erzielen, sondern gleichzeitig optimierte Randbedingungen effektiv zu identifizieren. Dieser integrative Ansatz sichert die Beibehaltung der Vorhersagegenauigkeit und führt darüber hinaus zu einer substanziellen Effizienzsteigerung im Kunststoffspritzgussprozess.

Durch den Einsatz inverser Vorhersagen mittels KI können komplexe Problemstellungen, im Gegensatz zu einer schrittweisen Annäherung an die gewünschte Geometrie durch zahlreiche Simulationen mit individuellen Randbedingungen, schnell gelöst werden.

Die Bedeutung dieses Aspekts wird besonders evident, wenn statt auf Simulationen auf tatsächliche Messdaten von der Maschine und der dazugehörigen Bauteilherstellung zurückgegriffen wird. Diese Vorgehensweise ermöglicht eine erhebliche Reduzierung der Anzahl herzustellender Bauteile mit unterschiedlichen Parametersets und deren Optimierung durch KI. Diese Herangehensweise führt zu einer erheblichen Einsparung von Zeit, Ressourcen sowie Kosten und ist nachhaltig.

Ähnlich wie bei inversen Problemstellungen können auch komplexe Herausforderungen mithilfe der KI durch die Vorhersage bisher unbekannter Parametersets effizient und rasch gelöst werden. Als Beispiel hierfür wird die gesamte Wandstärkenverteilung durch 300 gleichmäßig verteilte Messpunkte entlang des gesamten Rohrverlaufs beschrieben. Tabelle 2 stellt die verwendeten Parameter und ihre zugehörigen Wertebereiche dar, wobei die Prozessparameter sowohl in der Simulation als auch in der KI-Vorhersage als Randbedingungen (Eingangsparameter) fungieren, während die Wandstärken an den 300 Positionen als Ergebnis der Simulation bzw. Vorhersage (Ausgangsparameter) dienen. Diese integrierte Vorgehensweise verspricht eine signifikante Effizienzsteigerung sowie eine präzise Lösung für komplexe Problemstellungen im Bereich des Kunststoffspritzgusses.

Tab. 2: Parameterset der verwendeten Prozess- und Geometrieparameter in der Simulation und für die Vorhersage der gesamten Wandstärkenverteilung

Kategorie	Parameter	Werte	Einheit	Simulation	KI
Prozessparameter	Werkzeugwandtemperatur T_M	60 125	°C	Eingang	Eingang
	Fluidvolumenstrom \dot{V}_F	150 550	cm ³ /s	Eingang	Eingang
	Fluidtemperatur T_F	20 40	°C	Eingang	Eingang
	Verzögerungszeit t_P	0,1 0,9	s	Eingang	Eingang
Geometrie	Wandstärke Pos 1-300 d_i	300 Parameter	mm	Ausgang	Ausgang

3. Ergebnisse

Durch die Anwendung der inversen Vorhersage wurde eine detaillierte Analyse der Verzögerungszeit durchgeführt, um folgende Aspekte aufzuschlüsseln. In einem ersten Schritt erfolgte die Vorhersage der Wandstärkenverteilung an den 300 gleichmäßig über den gesamten Rohrverlauf verteilten Positionen unter Einsatz von KI. Parallel dazu wurde eine Vergleichssimulation mit einem bisher unbekanntem Parameterset durchgeführt, und die resultierende Wandstärkenverteilung wurde eingehend analysiert. Die aus beiden Ansätzen gewonnenen Wandstärkenverteilungen wurden gegenübergestellt, wobei eine hinreichend genaue Übereinstimmung von ca. 98% zwischen den vorhergesagten und simulierten Wandstärken erzielt wurde (siehe Abbildung 3).

Darüber hinaus wurden die geforderten Wandstärken an den beiden festgelegten Positionen mit einer hohen Genauigkeit von ca. 95%, sowohl durch die Simulation als auch durch die KI-Vorhersage, im Vergleich zu den vorgegebenen Werten erreicht. Diese Übereinstimmung unterstreicht die Zuverlässigkeit sowie Genauigkeit und verdeutlicht die Leistungsfähigkeit der angewandten Methodik, die eine solide Grundlage für die effektive Gestaltung und Analyse von Wandstärkenverteilungen in diesem spezifischen Anwendungskontext bietet.

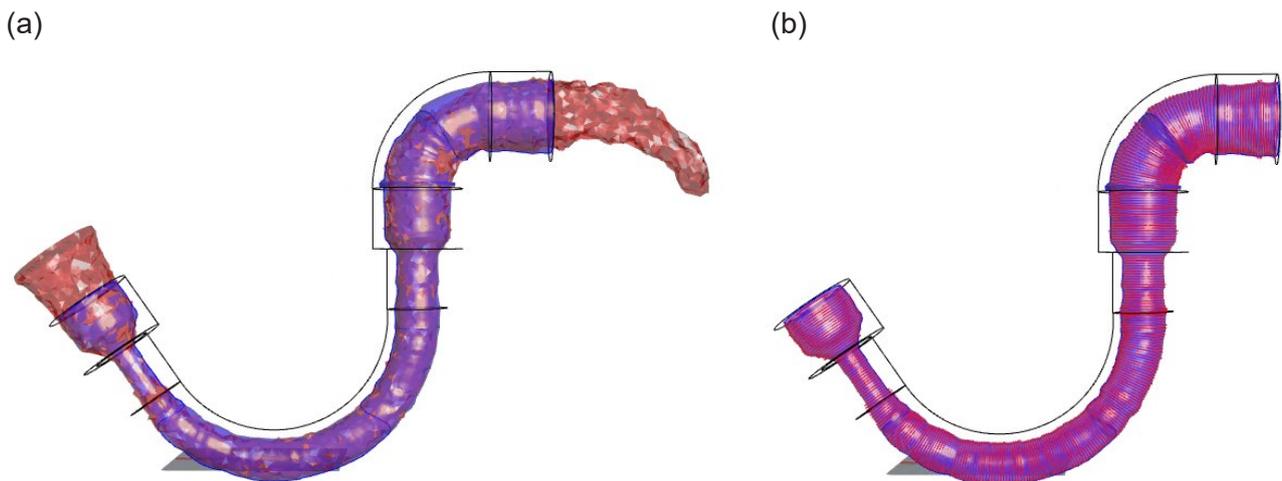


Abb. 4: (a) Gegenüberstellung des Simulationsergebnisses des Wasserkanals (rot) und der vorhergesagten Wandstärke (blau), (b) Gegenüberstellung der berechneten Wandstärke aus den Simulationsergebnissen (rot) und der vorhergesagten Wandstärke (blau)

Die weiterführende Analyse der Wandstärkenverteilung an den 300 gleichmäßig verteilten Punkten wurde durch vorangegangene Simulationen ermöglicht, die auf definierten Parametersets basieren und keine zusätzliche Simulationen erfordern. Die bereits verfügbaren Wandstärkenverteilungsdaten aus den vorherigen Simulationen boten eine effiziente Grundlage für die fortlaufende Analyse mit dem Vorteil der Zeit- und Ressourcenersparnis.

Die Effizienzsteigerung wurde weiter intensiviert, indem für das Training der KI die Struktur des bereits bestehenden Datensatzes umgestaltet wurde. Die KI konnte auf diese Weise mit einem präzisen und umfassenden Verständnis der Wandstärkenverteilung trainiert werden, ohne auf zusätzliche Simulationen zurückgreifen zu müssen. Diese effiziente Nutzung der bereits vorhandenen Daten trägt dazu bei, den Entwicklungsprozess nachhaltig zu optimieren.

Die Anwendung von Multilayer Perceptrons (MLPs) im spezifischen Kontext der Prozess-Simulation in der Wasserinjektionstechnik im Kunststoffspritzguss bietet somit mehrere signifikante Vorteile:

- **Verbesserte Genauigkeit bei der Prozessvorhersage:** MLPs können komplexe Muster und Beziehungen in den Daten erkennen, was zu präziseren Vorhersagen und Modellierungen führt. Diese erhöhte Genauigkeit ist entscheidend für die Optimierung des Spritzgussprozesses, insbesondere bei komplexen Formen und Materialien.
- **Effiziente Lösung inverser Probleme:** Inverse Probleme, bei denen aus einem bekannten Ergebnis auf unbekannte Eingabeparameter geschlossen werden muss, sind im Spritzguss häufig. MLPs sind besonders geeignet, um solche Probleme effizient zu lösen, indem sie die optimalen Prozessbedingungen vorhersagen, die zu einem gewünschten Produktergebnis führen.
- **Reduzierung von Produktionsausfallzeiten und Materialverschwendung:** Durch die präzisere Prozesskontrolle und -vorhersage, ermöglicht durch die MLPs, können Produktionsfehler und Fehlchargen reduziert werden. Dies führt zu einer Verringerung der Ausfallzeiten und des Materialverbrauchs, was sowohl wirtschaftlich als auch ökologisch vorteilhaft ist.
- **Erhöhte Flexibilität und Anpassungsfähigkeit:** MLPs können schnell an Veränderungen in den Produktionsbedingungen oder Materialien angepasst werden. Dies ermöglicht eine flexible Reaktion auf Kundenanforderungen oder die Einführung neuer Materialien und Prozessparameter ohne langwierige manuelle Anpassungen.
- **Einsparung von Zeit und Ressourcen in der Prozessentwicklung:** Der Einsatz von MLPs kann den Entwicklungszyklus für neue Produkte oder Prozessanpassungen erheblich verkürzen. Statt aufwendiger und zeitintensiver experimenteller Tests können MLPs genutzt werden, um schnell und effizient optimale Prozessparameter zu ermitteln, wodurch Entwicklungszeit und -kosten gespart werden.

4. Zusammenfassung

Dieser Beitrag strebt an, ein tiefgreifendes Verständnis für die Auswirkungen von KI in FEM und CFD-Simulationen zu vermitteln, insbesondere im Hinblick auf die Optimierung der Systemeffizienz und den effektiven Umgang mit inversen Problemstellungen sowie systemspezifischen Black-Box-Komponenten. Der Einsatz von KI-Techniken eröffnet Ingenieur*innen neue Perspektiven und ermöglicht einen souveränen Umgang mit komplexen Komponenten. Diese technologischen Fortschritte unterstützen Ingenieur*innen sicherere, innovativere und effizientere Systeme zu gestalten, wodurch sie einen bedeutenden Beitrag zu Fortschritten in verschiedensten Branchen leisten.

Es wird verdeutlicht, dass die Ermittlung notwendiger Prozess- und Maschinenparameter für die gewünschte Bauteilqualität mithilfe der inversen Lösung durch KI ohne den Einsatz von Optimierungsproblemen erreicht werden kann. In Abbildung 4 ist die Visualisierung der Methodik für die systematische Vorhersage der Restwandstärkenverteilung und Prozessparameter mittels Simulation und KI-Training dargestellt. Diese Vorgehensweise ermöglicht nicht nur eine erhebliche Reduzierung der Entwicklungszeit, sondern auch eine Minimierung des Material- und Ressourcenaufwands. Zusätzlich zeigt sich, dass durch die Umstellung der Problemstellung auf eine direkte Vorhersage die Wandstärkenverteilung in einem Bauteil ohne zusätzliche Simulationen und Berechnungen geschlossen werden kann. Die Prognosen der Prozess- und Maschinenparameter können, abhängig von der Datenverfügbarkeit, mit hoher Genauigkeit realisiert werden. Diese Methodik trägt somit zur Effizienzsteigerung und zur präzisen Steuerung von Prozessen in der Ingenieurspraxis bei.

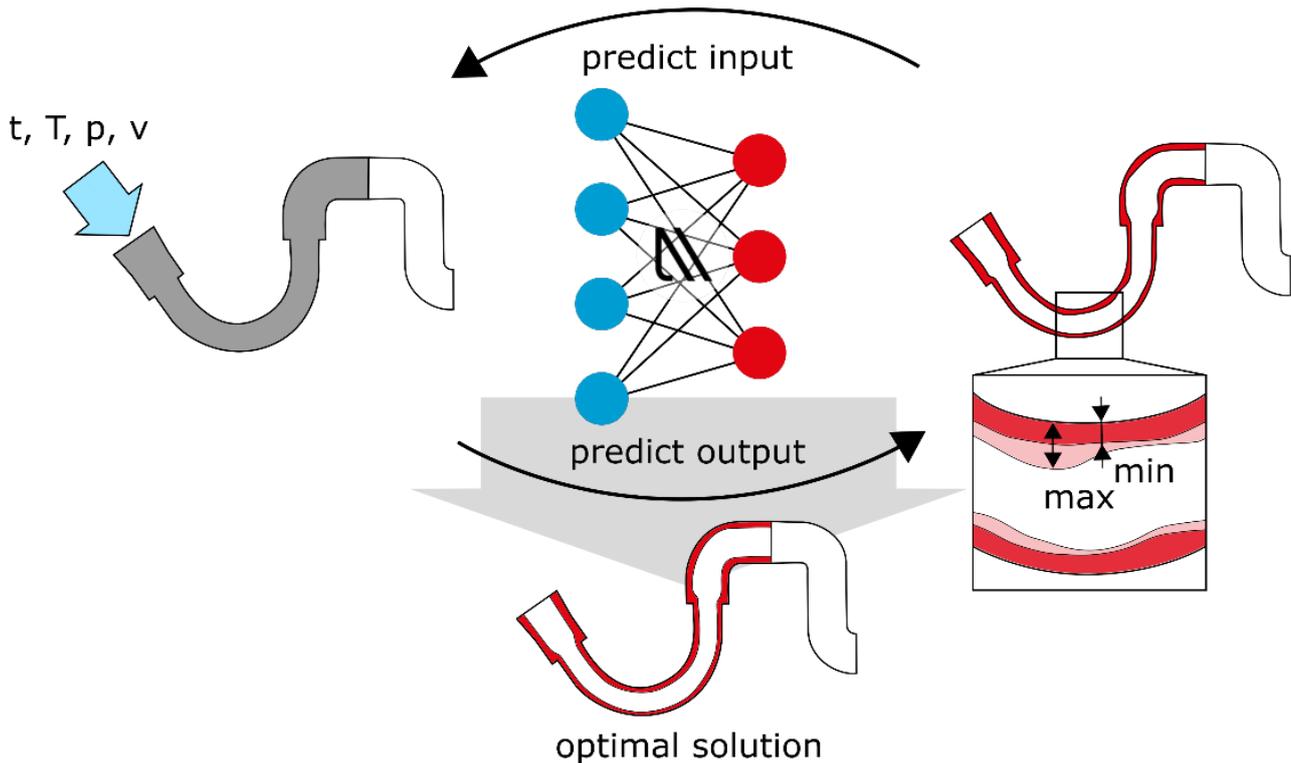


Abb. 5: Visualisierung der Vorhersage von Ausgangsparametern (predict output) und der inversen Vorhersage von Eingangsparametern (predict input) mithilfe von KI am Beispiel eines durch Wasserinjektionstechnik im Kunststoffspritzguss hergestellten Bauteils

Weiterführende Informationen zum Thema sind zu finden unter:

- Anwendung von KI im Computer-Aided Engineering (CAE):**
 Für weitere Informationen zu den neuesten Entwicklungen und Forschungen im Bereich der Anwendung von Künstlicher Intelligenz im Computer-Aided Engineering, kontaktieren Sie bitte den Autor dieses Artikels direkt unter florian.dirisamer@digital-physics.com oder besuchen Sie die Webseite des Unternehmens unter www.digital-physics.com
- Anwendung von Wasserinjektionstechnik im Kunststoffspritzguss und Simulation:**
 Für detaillierte Einblicke in die Wasserinjektionstechnik im Kunststoffspritzguss und deren Simulation kontaktieren Sie bitte Eva Heimpl unter eva.heimpl@plasticinnovation.at oder besuchen Sie die Webseite des Unternehmens unter www.plasticinnovation.at
- Das eingesetzte KI-Tool:**
 Ausführliche Informationen zum eingesetzten No-Code KI-Tool „dAlve“, einschließlich technischer Details und Anwendungsfälle, erhalten Sie durch direkten Kontakt mit dem Entwicklerteam unter info@daive.de oder auf der offiziellen Webseite www.daive.de
- Für **Schulungen und Webinare** zum effektiven Einsatz dieses Tools, besuchen Sie www.daive.de oder treten Sie direkt mit dem Team in Kontakt unter support@daive.de