

---

---

# KI-gestützte Regelung von unsicherheitsbehafteten Umformprozessen auf redundanten Mehrpunkt-Servopressen

---

Zur Erlangung des akademischen Grades Doktor-Ingenieur (Dr.-Ing.)  
Genehmigte Dissertation von Dirk Alexander Molitor, M.Sc. M.Sc. aus  
Gummersbach

Tag der Einreichung: 11.12.2023, Tag der Prüfung: 08.05.2024

1. Gutachten: Prof. Dr.-Ing. Dipl.-Wirtsch.-Ing. Peter Groche

2. Gutachten: Prof. Dr.-Ing. Rolf Findeisen

Darmstadt – D17

Darmstadt, Technische Universität Darmstadt

Veröffentlichungsjahr der Dissertation auf TUprints: 2024



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

Fachbereich  
Maschinenbau

Institut für  
Produktionstechnik und  
Umformmaschinen

KI-gestützte Regelung von unsicherheitsbehafteten Umformprozessen auf redundanten Mehrpunkt-Servopressen

Genehmigte Dissertation von Dirk Alexander Molitor, M.Sc. M.Sc.

Tag der Einreichung: 11.12.2023

Tag der Prüfung: 08.05.2024

Darmstadt – D17

Darmstadt, Technische Universität Darmstadt

Veröffentlichungsjahr der Dissertation auf TUprints: 2024

Bitte zitieren Sie dieses Dokument als:

URN: urn:nbn:de:tuda-tuprints-278548

URL: <http://tuprints.ulb.tu-darmstadt.de/27854>

Dieses Dokument wird bereitgestellt von tuprints,

E-Publishing-Service der TU Darmstadt

<http://tuprints.ulb.tu-darmstadt.de>

[tuprints@ulb.tu-darmstadt.de](mailto:tuprints@ulb.tu-darmstadt.de)

CC-BY-SA-4.0

---

## **Erklärungen laut Promotionsordnung**

### **§ 8 Abs. 1 lit. c PromO**

Ich versichere hiermit, dass die elektronische Version meiner Dissertation mit der schriftlichen Version übereinstimmt.

### **§ 8 Abs. 1 lit. d PromO**

Ich versichere hiermit, dass zu einem vorherigen Zeitpunkt noch keine Promotion versucht wurde. In diesem Fall sind nähere Angaben über Zeitpunkt, Hochschule, Dissertationsthema und Ergebnis dieses Versuchs mitzuteilen.

### **§ 9 Abs. 1 PromO**

Ich versichere hiermit, dass die vorliegende Dissertation selbstständig und nur unter Verwendung der angegebenen Quellen verfasst wurde.

### **§ 9 Abs. 2 PromO**

Die Arbeit hat bisher noch nicht zu Prüfungszwecken gedient.

Darmstadt, 11.12.2023

---

D. A. Molitor

---

## Vorwort und Danksagung

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Produktionstechnik und Umformmaschinen (PtU) der TU Darmstadt. Für die Promotionsmöglichkeit und das damit langjährig entgegengebrachte Vertrauen bedanke ich mich bei Erstgutachter Prof. Dr.-Ing. Dipl.-Wirtsch.-Ing. Peter Groche. Ebenfalls gilt Prof. Dr.-Ing. Rolf Findeisen ein Dank für die Übernahme des Zweitgutachtens und die gewissenhafte Durchsicht der Arbeit.

Zuallererst möchte ich mich beim gesamten Kollegium des PtU für die vertrauensvolle Zusammenarbeit bedanken. Besonders bedanke ich mich bei meinem langjährigen Bürokollegen Viktor Arne, mit dem ich gemeinsam die 3D-Servo-Pressen betreuen und Beiträge zur Maschineninbetriebnahme leisten durfte. Der fachliche und persönliche Austausch mit ihm zeichnete sich stets durch Vertrauen, Unterstützung als auch beidseitigen Respekt aus und leistete nicht zu unterschätzende Beiträge zum Gelingen der Arbeit. Weiterhin danke ich Christian Kubik für die erfolgreichen Zusammenarbeiten und den Rückhalt, welchen er mir stets bot. Ein weiterer Dank gilt meinem Vorgänger Dr.-Ing. Florian Hoppe, der das Forschungsprojekt der 3D-Servo-Pressen in hervorragendem Zustand an seine Nachfolger übergab und dessen ausgezeichnete Vorarbeiten fundamental für die in der vorliegenden Arbeit dargelegten Erkenntnisse sind. Auch bei Studenten, deren Abschlussarbeiten ich in den letzten Jahren betreuen durfte, bedanke ich mich herzlich. Besonders hervorzuheben sind die Leistungen von Felix Georgi, Ruben Hetfleisch, Robin Krämer, Gabriel Noemark, Marvin Rojahn und Ciarán Veitenheimer. Für gewissenhafte Durchsichten der Arbeit möchte ich mich bei allen Korrekturleserinnen und Korrekturlesern bedanken.

Nicht zuletzt bedanke ich mich zutiefst bei meinen Freunden und meiner Familie, die meinen akademischen Werdegang begleitet, unterstützt und gar ermöglicht haben. Der größte Dank gilt meinen Eltern Peter Molitor und Andrea Maria Molitor für die bedingungslose Unterstützung und die unzählbaren Stunden, die sie in meine persönliche Förderung investiert haben. Ihnen sei die Arbeit gewidmet.

Darmstadt, der 27.08.2023

Dirk Alexander Molitor

---

## Kurzfassung

Umformtechnische Unternehmen stehen derzeit vor der Herausforderung, die Automatisierungsgrade ihrer Produktionsprozesse zu steigern, um eine wirtschaftliche Produktherstellung zu gewährleisten. Einen vielversprechenden Ansatz stellen auf künstlicher Intelligenz (KI) beruhende Algorithmen dar, die sich sowohl zur Überwachung als auch zur Regelung der Prozesse eignen. Deren Anwendung ist in der industriellen Praxis derzeit noch nicht weit verbreitet, bietet jedoch erhebliche Potenziale und könnte zukünftig einen entscheidenden Wettbewerbsvorteil für Unternehmen der metallverarbeitenden Industrie darstellen.

Im Rahmen der vorliegenden Arbeit wird untersucht, inwiefern KI-Algorithmen zu performanteren Prozess- und Maschinenregelungen in umformtechnischen Prozessen beitragen können. Dabei werden Prozesse auf redundanten Mehrpunkt-Servopressen, die sich durch mehrere Abtriebsfreiheitsgrade charakterisieren, analysiert. Es werden einerseits KI-Ansätze zur Steigerung der Genauigkeit bestehender Positionsregelungen vorgestellt und andererseits die Eignung von unterschiedlichen KI-Modellen zur Regelung von Produkteigenschaften in umformtechnischen Prozessen geprüft. Weiterhin stellt die Redundanz bzw. Überaktuierung der für die Untersuchungen genutzten Mehrpunkt-Servopresse eine Möglichkeit zur KI-gestützten Optimierung des Maschinenverhaltens dar. So führen unterschiedliche Antriebsbewegungen zu gleichen Abtriebsbewegungen, unterscheiden sich jedoch hinsichtlich Geschwindigkeits- sowie Kraftübersetzungen und müssen bei der Planung von Antriebspfaden berücksichtigt werden. In der Arbeit wird ein Vergleich zwischen einem modellprädiktiven Regler und bestärkenden Lernalgorithmen vorgestellt, bei dem beide Ansätze das Ziel verfolgen, optimale Antriebspfade unter Berücksichtigung multipler Optimierungskriterien zu identifizieren.

---

## **Abstract**

Forming technology companies are currently facing the challenge of increasing the level of automation in their manufacturing processes in order to ensure cost-effective product manufacturing. Algorithms based on artificial intelligence (AI), which are suitable for both monitoring and closed-loop controlling processes, represent a promising approach. Their application is not yet widespread in industrial practice, but they offer considerable potential and could represent a decisive competitive advantage for companies in the metalworking industry in the future.

This thesis examines where AI algorithms can contribute to higher-performance process and machine control in forming processes. Processes on redundant multi-point servo presses, which are characterized by several ram degrees of freedom, are analyzed. On the one hand, AI approaches for increasing the accuracy of existing position controls are presented and, on the other hand, the suitability of different AI models for the control of product properties in forming processes is evaluated. Furthermore, the redundancy or over-actuation of the multi-point servo press used for the investigations represents a possibility for AI-supported optimization of machine behavior. Different drive paths lead to the same ram movements, but differ in terms of velocity and force transmission and must be taken into account when planning drive paths. The thesis presents a comparison between a model predictive controller and reinforcement learning algorithms, where both approaches aim to identify optimal drive paths considering multiple optimization criteria.

---

# Inhaltsverzeichnis

---

<b>1. Einleitung</b>	<b>1</b>
<b>2. Stand der Technik</b>	<b>3</b>
2.1. Unsicherheit in umformtechnischen Prozessen . . . . .	3
2.1.1. Werkzeugseitige Unsicherheit . . . . .	5
2.1.2. Halbzeugseitige Unsicherheit . . . . .	7
2.1.3. Maschinenseitige Unsicherheit . . . . .	9
2.1.4. Umweltseitige Unsicherheit . . . . .	12
2.2. Ansätze zur Beherrschung von Unsicherheit . . . . .	13
2.2.1. Modelle zur Beschreibung umformtechnischer Prozesse . . . . .	14
2.2.2. Flexibilität in der Umformtechnik . . . . .	27
2.2.3. Regelung von Bauteileigenschaften . . . . .	29
2.2.4. Selbstoptimierende Werkzeugmaschinen . . . . .	33
2.3. Überführung von Qualitätsdaten in Antriebsgrößen . . . . .	35
2.3.1. Qualitätsdaten in Abtriebsgrößen . . . . .	37
2.3.2. Abtriebsgrößen in Antriebsgrößen . . . . .	38
2.4. Zwischenfazit . . . . .	46
<b>3. Zielsetzung und Vorgehensweise</b>	<b>47</b>
3.1. Zielsetzung . . . . .	47
3.2. Vorgehensweise . . . . .	50
<b>4. Versuchsstände und deren Regelung</b>	<b>52</b>
4.1. Beschreibung der Versuchsstände . . . . .	52
4.2. Validierung der Positionsregelung . . . . .	56



4.3.	Optimierung der Positionsregelung mittels Gain-Scheduling . . . . .	65
4.3.1.	Analytische Herleitung variabler Verstärkungsfaktoren . . . . .	66
4.3.2.	Erprobung der Regelung in simulativer Umgebung . . . . .	70
4.3.3.	Experimentelle Validierung im Lochwalzprozess . . . . .	74
4.4.	Zwischenfazit . . . . .	82
<b>5.</b>	<b>KI-gestützte Eigenschaftsregelungen</b>	<b>84</b>
5.1.	Anwendung überwachter Lernalgorithmen auf Freibiegeprozess . . . . .	84
5.1.1.	Versuchsaufbau . . . . .	86
5.1.2.	Regelungskonzept . . . . .	87
5.1.3.	Entwurf des KI-gestützten Produktreglers . . . . .	89
5.1.4.	Experimentelle Ergebnisse . . . . .	93
5.1.5.	Performanzvergleich weißer und schwarzer Modelle . . . . .	101
5.2.	Anwendung bestärkender Lernalgorithmen auf Gesenkbiegeprozess . . . . .	106
5.2.1.	Versuchsaufbau . . . . .	106
5.2.2.	Regelungskonzept . . . . .	108
5.2.3.	Entwurf des KI-gestützten Produktreglers . . . . .	110
5.2.4.	Simulative und experimentelle Ergebnisse . . . . .	113
5.3.	Anwendung bestärkender Lernalgorithmen auf SPIF-Prozess . . . . .	121
5.3.1.	Versuchsaufbau . . . . .	123
5.3.2.	Regelungskonzept . . . . .	123
5.3.3.	Entwurf des KI-gestützten Produktreglers . . . . .	125
5.3.4.	Experimentelle Ergebnisse . . . . .	127
5.4.	Zwischenfazit . . . . .	130
<b>6.</b>	<b>Simulationsgestützte Optimierung von Antriebstrajektorien</b>	<b>134</b>
6.1.	Einführung in die Problemstellung . . . . .	134
6.2.	Formulierung des modellprädiktiven Reglers . . . . .	138
6.3.	Formulierung des Actor-Critic-Ansatzes . . . . .	143
6.4.	Performanzvergleich anhand Beispielprozessen . . . . .	146
6.4.1.	Stauhen . . . . .	146
6.4.2.	Taumelschmieden . . . . .	153
6.5.	Zwischenfazit . . . . .	159
<b>7.</b>	<b>Zusammenfassung und Ausblick</b>	<b>161</b>

**A. Anhang****196**

- A.1. Kinematik und Kraftübersetzung des Prototypens der 3D-Servo-Pressen 197
- A.2. Bestimmung der Antriebszeitkonstanten . . . . . 199
- A.3. Weitere Messdaten aus geregelten Stauchprozessen bei außermittiger  
Krafteinwirkung . . . . . 201
- A.4. Simulativer Performanzvergleich der 3DSP-Positionsregelung mit kon-  
stanten und adaptiven Verstärkungsfaktoren . . . . . 203
- A.5. Performanzvergleich Positionsregelung am Beispiel einer Taumel-  
schmiedebewegungsbahn . . . . . 204
- A.6. Optische Bauteilvermessung mittels Hexagon AB Absolute Arm . . . 207
- A.7. Bilder realer Bauteile aus dem Lochwalzprozess unter Anwendung  
unterschiedlicher Regelgesetze . . . . . 208
- A.8. Grundlagen des überwachten Lernens . . . . . 209
  - A.8.1. Multiple, lineare Regression . . . . . 209
  - A.8.2. Neuronale Netze . . . . . 210
  - A.8.3. Faltende, neuronale Netze . . . . . 213
  - A.8.4. Bewertungsmetriken regressierender Lernalgorithmen . . . . 214
- A.9. Grundlagen des bestärkenden Lernens . . . . . 216
  - A.9.1. Markov-Entscheidungsprozesse und Lösungsansätze . . . . . 216
  - A.9.2. Parametrisierbare Bewertungsfunktionen und Entscheidungs-  
strategien . . . . . 219
  - A.9.3. Soft-Actor-Critic . . . . . 222
- A.10. Grundlagen der nichtlinearen, modellprädiktiven Regelung . . . . . 226
- A.11. Zusätzliche Angaben zur Anwendung überwachter Lernalgorithmen  
auf Freibiegeprozesse . . . . . 229
- A.12. Metriken zur Bewertung der Ähnlichkeit beliebiger, diskreter Wahr-  
scheinlichkeitsdichtefunktionen . . . . . 232
- A.13. Wasserstein-Distanz zur Bewertung der Ähnlichkeit multivariater  
Normalverteilungen . . . . . 234
- A.14. Zusätzliche Angaben zur Anwendung bestärkender Lernalgorithmen  
auf Gesenkbiegeprozesse . . . . . 235



A.15. Zusätzliche Angaben zur Anwendung bestärkender Lernalgorithmen  
auf SPIF-Prozesse . . . . . 242

A.16. Schematische Darstellung der Kraftbegrenzung von Servopressen mit  
nichtlinearer Kinematik . . . . . 245

A.17. Zusätzliche Angaben zur Anwendung von modellprädiktiver Regelung  
auf die Positionsregelung der 3D-Servo-Presse . . . . . 246

A.18. Zusätzliche Angaben zur Anwendung von Actor-Critic-Algorithmen  
auf die Positionsregelung der 3D-Servo-Presse . . . . . 251

**B. Symbole, Abkürzungen und Verzeichnisse 261**

B.1. Allgemein . . . . . 261

B.2. Kapitel 2 und 3 . . . . . 264

B.3. Kapitel 4 . . . . . 267

B.4. Kapitel 5 . . . . . 270

B.5. Kapitel 6 . . . . . 273

---

# 1. Einleitung

---

Disruptive Innovationen auf den Gebieten der Bildverarbeitung [KSH17], tiefen Sprachmodelle [Vas17; Rad19] und lernenden Robotik [KBP13] haben in den vergangenen Jahren die Bekanntheit und mediale Präsenz von Künstliche Intelligenz (KI)-Anwendungen amplifiziert. KI wird mittlerweile als Schlüsseltechnologie angesehen, die eine Grundlage für Wachstum, Wohlstand, Wettbewerbsfähigkeit und gesellschaftlichen Mehrwert darstellt. Aus diesem Grund fördert die deutsche Bundesregierung im Rahmen der 2018 verabschiedeten KI-Strategie [Bun23] den Ausbau von Infrastruktur und Aufbau von Kompetenzen. Eine Intensivierung dieser Bemühungen erfolgte kürzlich im Rahmen des KI-Aktionsplanes [BMB23] durch das Bundesministerium für Bildung und Forschung (BMBF), wodurch der Wirtschafts- und Forschungsstandort Deutschland nachhaltig gestärkt werden soll. Ein besonders von KI profitierender Anwendungsbereich ist die Produktionstechnik, in der aufgrund der zunehmenden Verbreitung von Automatisierungs- und Digitalisierungslösungen große Datenmengen erhebbbar sind. [Gao20] Die wissenschaftliche Gesellschaft für Produktionstechnik (WGP) diskutiert in ihrem KI-Standpunktpapier die daraus hervorgehenden Potenziale für Unternehmen, die durch die Identifikation von für Menschen kaum wahrnehmbaren Mustern in Daten ausgeschöpft werden können. Die WGP prognostiziert, dass Implementierungen von KI-Lösungen die Wettbewerbsfähigkeit von Unternehmen elementar antreiben werden. [Krü20]

Insbesondere umformtechnische Prozesse bieten ideale Rahmenbedingungen, um von den Potenzialen von KI zu profitieren. Die aus Umformprozessen hervorgehenden Bauteile unterliegen Unsicherheit, da sich schwankende Einflüsse aus Halbzeug, Werkzeug, Maschinen und Umwelt auf Bauteileigenschaften auswirken. Um jene Auswirkungen zu begrenzen und eine Produktion bei möglichst gleichbleibender Qualität zu gewährleisten, befassen sich wissenschaftliche Vereinigungen mit der

---

Beforschung von Ansätzen, die eine Detektion und Kompensation von Eigenschaftsschwankungen durch regelungstechnische Lösungen [All16] und Interaktionen zwischen gemessenen Bauteileigenschaften und den Regelungen der Werkzeugmaschinen adressieren [Möh20]. Voraussetzung für solche Lösungsansätze sind Modelle, die Zusammenhänge zwischen den sich oftmals erst nach Prozessende einstellenden Bauteileigenschaften und Abtriebs- bzw. Antriebspfaden der Umformmaschine quantifizieren. In den letzten Jahren rücken KI-Algorithmen in den Fokus solcher Modellbildungen, die die oftmals nichtlinearen, interdependenten und hochdimensionalen Zusammenhänge mathematisch abbilden können. Eine weitere Voraussetzung stellen flexible Umformmaschinen dar, deren Abtriebspfade adaptierbar sind, wodurch die Manipulierbarkeit der geregelten Bauteileigenschaften sichergestellt wird.

Mit der Verbreitung von Servopressen stehen produzierenden Unternehmen heutzutage Umformmaschinen zur Verfügung, die sich durch frei programmierbare Abtriebspfade charakterisieren [Osa11] und die die erforderliche Flexibilität bereitstellen. [Yan18] Innovative Pressenkonzepte, wie etwa die 3D-Servo-Pressen (3DSP) [Gro10], stellen redundante Mehrpunkt-Servopressen dar, die einerseits aufgrund einer kinematisch entkoppelten Ansteuerung dreier Stößeldruckpunkte dreidimensionale Bewegungspfade der Stößelpose realisieren können und andererseits über mehr Antriebsfreiheitsgrade als Abtriebsfreiheitsgrade verfügen. Die damit einhergehende Überaktuierung wird in Robotikanwendungen als Redundanz bezeichnet [Sic90] und ermöglicht es Anwendern von redundanten Werkzeugmaschinen, zusätzliche Nebenbedingungen für deren Regelungen vorzusehen.

Während Positionsregelungen von redundanten Mehrpunkt-Servopressen in jüngster Vergangenheit intensiv beforscht worden sind [Hop21], stellt sich die Frage, inwiefern KI-gestützte Modellbildungen qualitätsfördernde Interaktionen zwischen Maschinenregelung und Bauteileigenschaften ermöglichen. Weiterhin stellt sich die Frage, welche modellbasierten Methoden optimierte Antriebspfade unter Kenntnis vorgegebener Abtriebspfade ermitteln und welche Beiträge KI-Methoden dazu leisten können. Die vorliegende Arbeit setzt sich daher das Ziel, Beiträge zur Beantwortung der geschilderten Problemstellungen zu leisten und am Beispiel unterschiedlicher Umformprozesse die Potenziale als auch Herausforderungen der Anwendung von KI-Algorithmen aufzuzeigen.

---

## 2. Stand der Technik

---

### 2.1. Unsicherheit in umformtechnischen Prozessen

Unsicherheit ist allgegenwärtig in Produktionsprozessen [WAN09] und verhindert eine reproduzierbare Fertigung von Bauteilen bei gleichbleibender Qualität. Die Sicherstellung von Bauteilqualität ist ein zentrales Ziel produktionstechnischer Prozesse und umfasst die Einstellung aller Eigenschaften und Merkmale eines Bauteils, die maßgeblich für die Erfüllung aller an das Bauteil gestellten Anforderungen sind. Aus diesem Grund berücksichtigen Produktentwickler Unsicherheit im gesamten Produktentstehungsprozess [Mor18] und betreiben enorme Aufwände, um diese bereits in Produktentwurfsphasen bestmöglich zu minimieren [LA00]. Nach Srinivasan [Sri03; Sri07] gelten sowohl für den Produktentwurf als auch die Produktfertigung zwei unumstößliche Axiome:

- Axiom der Imperfektion von Produktionsprozessen: Alle Produktionsprozesse sind inhärent unpräzise und produzierte Bauteileigenschaften unterliegen Streuungen.
- Axiom der Messunsicherheit: Keine Messung ist absolut genau und mit jeder Messung geht eine endliche Unsicherheit bezüglich des Messattributes oder Messwertes einher.

Unsicherheit spiegelt sich somit stets in veränderlichen Prozessrandbedingungen und schwankenden Bauteileigenschaften wider, die bei Überschreitung vordefinierter Toleranzgrenzen zu erhöhten Ausschussraten führen. Gleichzeitig führen Maßnahmen zur Reduktion von Unsicherheit zu erhöhten Kosten, weshalb eine gezielte Festlegung von Toleranzen als Kostenoptimierungsproblem angesehen werden kann

---

und in der Literatur oftmals unter Anwendung nichtlinearer Optimierungsmethoden gelöst wird [HSW20; Wan19]. Unsicherheit lässt sich weiterhin in aleatorische und epistemische Unsicherheit untergliedern, wobei aleatorische Unsicherheit auf stochastische Prozesse zurückzuführen und damit unkontrollierbar ist, während epistemische Unsicherheit grundsätzlich kontrollierbar, jedoch aufgrund von mangelndem System- und Prozessverständnis durch den jeweiligen Anwender nicht beherrschbar ist [BC01]. Weitere Arbeiten von Wissenschaftlern klassifizieren den Begriff der Unsicherheit feingliedriger [Thu03; WSW14] und nutzen beispielsweise Kenntnisse über deren Auswirkungen oder Auftretenswahrscheinlichkeiten als Klassifikationsmerkmal [Pel21a], weisen als Gemeinsamkeit jedoch die Einteilung in kontrollierbare und unkontrollierbare Unsicherheit auf. Analysiert man umformtechnische Prozesse bezüglich unsicherer Einflüsse, wirken sich eine Vielzahl an Einflussparametern auf Bauteileigenschaften aus [HS18]. Erste Ansätze zur Quantifizierung von Unsicherheit in umformtechnischen Prozessen können Unsicherheit einzelner Einflussfaktoren wie etwa Werkstoffeigenschaften, Prozesszuständen und geometrischen Eigenschaften abschätzen [APB18], erlauben aus Komplexitätsgründen jedoch noch keine holistische, kausale und nach Einflussfaktoren separierte Ursache-Wirkungs-Analyse zwischen Einflussfaktoren und Bauteileigenschaften. Abbildung 2.1 klassifiziert Einflussfaktoren auf Bauteileigenschaften gemäß den Teilsystemen eines umformtechnischen Prozesses in werkzeug-, halbzeug-, maschinen- und umweltseitige Einflüsse und stellt beispielhaft ausgewählte, unsicherheitsbehaftete Einflussfaktoren auf Bauteileigenschaften vor.<sup>1</sup> Die finalen Eigenschaften eines umformtechnisch hergestellten Bauteils sind somit als Resultat einer Vielzahl an unsicheren Einflussfaktoren anzusehen. In der Literatur sind eine Reihe an Untersuchungen vorzufinden, die die Auswirkungen einzelner Einflussfaktoren auf Bauteileigenschaften untersuchen und oftmals den Ansatz wählen, weitere Einflussfaktoren in den durchgeführten Versuchsreihen bestmöglich konstant zu halten. In den folgenden Unterkapiteln wird eine Auswahl dieser Veröffentlichungen vorgestellt, wobei die Unterkapitel gemäß Abbildung 2.1 nach den vorgestellten Teilsystemen gegliedert werden.

---

<sup>1</sup>Im Qualitätsmanagement werden Einflussfaktoren oftmals nach der 5M- bzw. 6M-Methode untergliedert, die die Klassen Mensch, Maschine, Material, Methode, Umwelt und ggf. Messmittel beinhaltet. [Lil16] Die vorliegende Arbeit greift auf die in Abbildung 2.1 vorgestellte Klassifizierung zurück, um einerseits Übersichtlichkeit zu gewährleisten, andererseits stärkeren Fokus auf Einflüsse der umformtechnischen Prozesse zu legen.

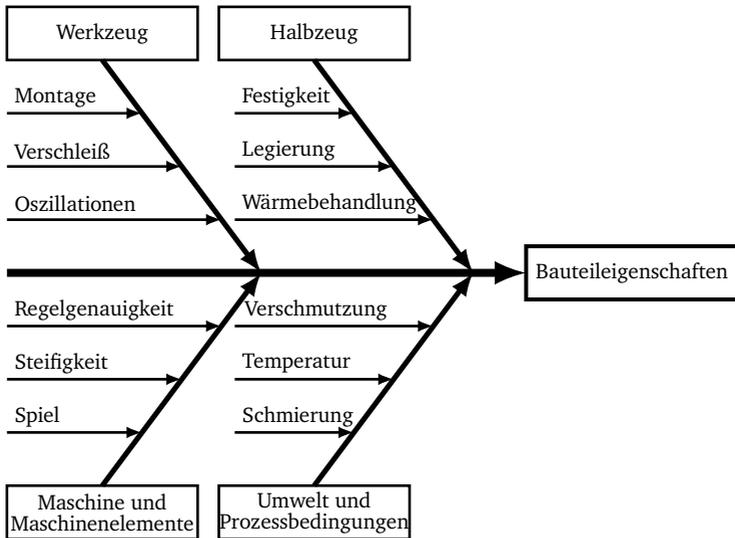


Abbildung 2.1.: Ursache-Wirkungs-Diagramm zwischen ausgewählten, unsicherheitsbehafteten Einflussfaktoren und Bauteileigenschaften in umformtechnischen Prozessen

### 2.1.1. Werkzeugseitige Unsicherheit

Umformtechnische Werkzeuge sind als Bindeglied zwischen Maschine und Umformzone anzusehen und müssen Anforderungen hinsichtlich Geometriegenauigkeit, Oberflächengüte, Verschleißresistenz, Ermüdungsverhalten, Wartbarkeit und Kosten erfüllen [Cao19]. Ihr Eingriff in das Halbzeug führt zur Umformung, wodurch hohe Kontaktnormalspannungen als auch Relativgeschwindigkeiten zwischen Halbzeug- und Werkzeugoberflächen entstehen. Ein besonders relevanter Einflussfaktor ist das Auftreten von unterschiedlichen Verschleißphänomenen an den Werkzeugoberflächen. So können in umformtechnischen Prozessen adhäsive Verschleißeffekte beobachtet werden, die durch einen Materialübertrag von Halbzeug auf Werkzeug charakterisiert sind. Adhäsiver Verschleiß ist oftmals in schmiermittelfreien Tiefziehprozessen zu beobachten [SM15] und kann entweder durch den Einsatz geeigneter Schmiermittel oder eine Beschichtung der Werkzeugoberflächen [HYI12; HSV12; Ten17] vermieden werden. Auch in Schmiedeprozessen treten adhäsive Effekte auf

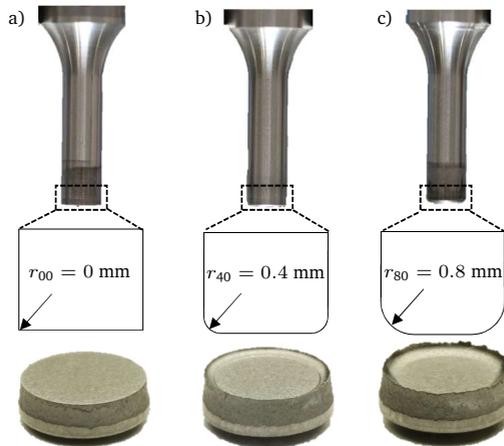


Abbildung 2.2.: Bauteile aus einem Scherschneidprozess gefertigt durch unterschiedlich stark verrundete Schneidstempel [E15]

und verursachen Geometrieabweichungen als auch hohe Wartungskosten. Pelcastre et al. zeigen auf, dass Rauigkeiten der Werkzeugoberflächen und deren Orientierungen wichtige Parameter zur Beeinflussung von adhäsivem Verschleiß sind und eine gezielte Einstellung der Rauigkeit Materialübertrag vorbeugt. [PHP12] Hohe Rauigkeiten begünstigen ebenfalls abrasive Verschleißeffekte, bei denen Rauigkeitsspitzen eines Reibkörpers in die Randschicht des Reibpartners eindringen und somit zu einem Materialabtrag am Werkzeug führen. In spanenden Prozessen kommt es dabei oftmals zu Gratbildungen [Aur09], die ebenfalls in Scherschneidprozessen durch eine Verrundung der Schneidkante hervorgerufen werden [KHG21; Fei17] und abrasiven Verschleiß darstellen. Dieser Effekt konnte anhand von Bauteilbildern visualisiert werden (siehe Abbildung 2.2), die durch Schneidstempel mit Kantenverrundungen zwischen 0 mm (neuwertig) und 0.8 mm (vollständig verschlissen) gefertigt worden sind. [E15] Die Topographie von Werkzeugoberflächen ist auch in anderen Umformprozessen entscheidend für resultierende Reibkräfte, wodurch auf den Materialfluss eingewirkt werden kann. Sowohl in der Blechmassivumformung [Löf16; Ker16] als auch beim Streckbiegen [Ber10] konnte nachgewiesen werden, dass sich Modifikationen der Werkzeugoberflächen auf den Materialfluss und die resultierende Bauteilgeometrie auswirken. Darüber hinaus geht mit zunehmender Reibung erhöh-

---

ter Wärmeeintrag in Umformprozesse einher. Kott et al. zeigen am Beispiel eines industriellen Tiefziehprozesses von Karosserieteilen aus der Automobilindustrie, dass auf den Prozess einwirkende Reibkräfte stark von der Temperatur abhängen und insbesondere Einlaufphasen, in denen der Temperaturverlauf stark instationär ist, kritisch für Bauteileigenschaften sind. Eine qualitätsgerechte Produktion der Bauteile ist nur dann möglich, wenn Niederhalterkräfte und Schmierbedingungen an Werkzeugtemperaturen angepasst werden, andernfalls drohen Blechausdünnungen oder -risse. [Kot20] Gleichzeitig können hohe Kräfte in Tiefziehprozessen zu elastischen Deformationen des Niederhalters [Neu06b] oder Ziehkissens [GRO08] führen und sich somit auf den Materialfluss des Bauteils auswirken. Daraus ergeben sich inhomogene Blechdickenverteilungen und über dem Umfang variierende Flanschlängen, wodurch Risse in der Umformzone oder Falten im Flanscbereich begünstigt werden. Elastische Deformationen sind jedoch nicht nur in Teilen der Werkzeuge mit direktem Kontakt zum Halbzeug zu erwarten, sondern ebenfalls in angrenzenden Komponenten. Kurth et al. weisen am Beispiel von sensorisch überwachten T-Nuten nach, dass hohe Umformkräfte elastische Deformationen der Spannvorrichtungen bewirken. [Kur21] Um das Verhalten von Werkzeugkomponenten bereits während der Konstruktion zu berücksichtigen, werden fortschreitend neue Werkzeugwerkstoffe beforscht, die hohe Anforderungen bezüglich Härte, Nachgiebigkeit sowie thermischen und tribologischen Eigenschaften gerecht werden müssen. [KOM11]

### **2.1.2. Halbzeugeitige Unsicherheit**

Viele bedeutende Einflussfaktoren von resultierenden Bauteileigenschaften hängen unmittelbar mit dem dem Umformprozess zugeführten Halbzeug zusammen. Halbzeugeigenschaften sind das Produkt vorgelagerter Prozesse mit unterschiedlichen thermischen, mechanischen und zeitlichen Einwirkungen und können darüber hinaus durch gezielte Einbringung von Legierungselementen anwendungsspezifisch modifiziert werden. Mechanische Werkstoffeigenschaften, wie etwa die für umformtechnische Prozesse relevanten Zugfestigkeiten, Streckgrenzen oder Verfestigungsexponenten, als auch geometrische Eigenschaften des Halbzeugs unterliegen Unsicherheit und werden als stochastisch schwankende Einflussparameter auf Umformprozesse angesehen, deren Streuung sich aus schwankenden Prozessparametern

---

vorgelagerter Gieß- [Ade21; GPP15] und Walzprozesse [ASH12; JE00] ergibt. Besonders relevant für Blechumformprozesse sind losspezifische und -übergreifende Schwankungen des Blechmaterials, wobei Streuungen variierender Stärke innerhalb eines Loses, zwischen Blechcoils eines Loses und innerhalb eines Blechcoils vorliegen können. Hora et al. zeigen unter Nutzung eines wirbelstrombasierten Messverfahrens Korrelationen zwischen Zugfestigkeit, Streckgrenze und Gleichmaßdehnung für DC06-Blechmaterial aus unterschiedlichen Coils auf. Die Messwerte einzelner Coils bilden dabei Cluster, die bezüglich genannter Werkstoffeigenschaften unterschiedlich stark streuen. [Hor11] De Souza und Rolfe untersuchen die Auswirkungen stochastisch schwankender Material- und Prozessparameter auf das Rückfederungsverhalten von Tiefziehbauteilen und resümieren, dass mechanische Eigenschaften des Blechmaterials die Rückfederungen am stärksten beeinflussen. [DR10] Held et al. führen Zugversuche von DP600-Werkstoffproben durch, die an unterschiedlichen Stellen des Blechcoils und in unterschiedlichen Orientierungen bezüglich der Walzrichtung entnommen werden. Die Autoren stellen fest, dass die untersuchten Materialkennwerte (Streckgrenze, Zugfestigkeit, Verfestigungsexponent und Anisotropiekennwert) sowohl über der Coillänge, -breite und -richtung streuen und beispielsweise Festigkeitskennwerte über der Coillänge zunehmen, da Coilabschnitte durch den Aufhaspelvorgang unterschiedlich stark vorverfestigt werden. [HLS09] Ähnliche Untersuchungen führt Kott durch, der neben den von Held et al. untersuchten Materialkennwerten auch geometrische Abmaße von Blechplatten vermisst und somit imstande ist, Streuungen der Blechdicke zu quantifizieren. Eine Auswahl der Messergebnisse ist in Abbildung 2.3 als Häufigkeitsverteilung mit korrespondierenden, normalverteilten Wahrscheinlichkeitsdichtefunktionen (WDF) dargestellt. Als Materialkennwerte werden die Zugfestigkeit  $R_m$  und Streckgrenze  $R_e$  in Walzrichtung ( $0^\circ$ ) und quer zur Walzrichtung ( $90^\circ$ ), als geometrischer Parameter die Blechdicke  $t_b$  dargestellt. Während Streuungen von bis zu 6% für die Zugfestigkeit und von bis zu 17% für die Streckgrenze bezogen auf entsprechende Mittelwerte auftreten, beträgt die relative Maximalstreuung der Blechdicke bei deutlich höherer Stichprobenanzahl 5%. Schwankende Halbzeugeigenschaften motivieren Wissenschaftler, Forschungsbemühungen zur Inline-Charakterisierung von Materialeigenschaften zu betreiben. Unterberg et al. stellen unter Beweis, dass sie mithilfe von Barkhausen-Sensorik und Einspeisung entsprechender Signale in maschinelle Lernverfahren (engl.: Machine Learning) (ML) klassifizieren können,

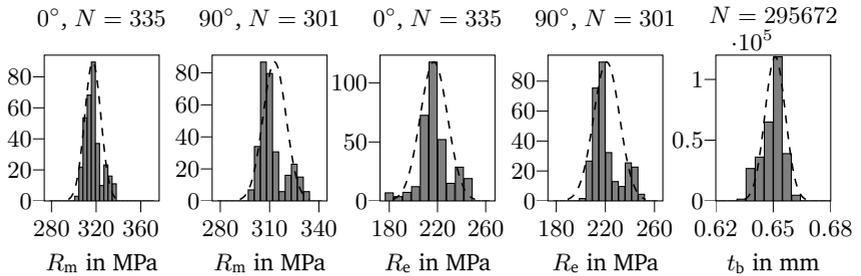


Abbildung 2.3.: Aus uniaxialen Zugversuchen ermittelte Häufigkeitsverteilungen und WDF der Zugfestigkeit  $R_m$  und Streckgrenze  $R_e$  in Walzrichtung ( $0^\circ$ ) und quer zur Walzrichtung ( $90^\circ$ ) sowie entsprechende Angaben für Blechdickenmessungen  $t_b$  [Kot22]

ob Coilabschnitte dem Anfang, der Mitte oder dem Ende des Blechcoils zugehörig sind. [Unt19] Weiterhin gilt es als gesichert, dass Kraftsignale aus Stanzprozessen Informationen beinhalten, um Halbzeugeigenschaften durch neuronale Netze (NN) zu schätzen. [Sch22] In mehrstufigen Umformprozessen weisen Kraftsignale vorgelegter Stufen Korrelationen zu Bauteileigenschaften auf, die erst in nachgelagerten Umformstufen eingestellt werden. [HV17] Solche Korrelationen können genutzt werden, um nachgelagerte Prozesse adaptiv vorzusteuern, was simulativ [Hav18] und experimentell [Gro16] bereits unter Beweis gestellt wurde.

### 2.1.3. Maschinenseitige Unsicherheit

Unsicherheit wird ebenfalls durch die genutzten Umformmaschinen in Umformprozesse induziert. Die durch Umformmaschinen realisierten Bewegungsprofile sind fehlerbehaftet und wirken sich negativ auf Bauteileigenschaften aus [Li22], was einerseits in begrenzten zeitlichen und räumlichen Messauflösungen genutzter Sensoren begründet liegt, andererseits in Imperfektionen verbauter Maschinenkomponenten. So unterliegen die zur Transformation von Antriebs- in Abtriebspositionen bzw. -geschwindigkeiten notwendigen kinematischen Modelle Unsicherheit, die durch vordefinierte Toleranzen der Getriebeglieder begrenzt wird. Die Längen der Getriebeglieder werden ebenfalls von thermischen Effekten beeinflusst, sodass Er-

---

wärmungen der Maschine in geometrischen Abweichungen der Werkzeugspitze resultieren. [Wec95; May12] Die Kompensation geometrischer Abweichungen in Werkzeugmaschinen ist Gegenstand weitläufiger Forschungsbemühungen [Sch08] und kann beispielsweise durch die Integration adaptiver Komponenten in die Nähe der Kontaktzone zwischen Werkzeug und Halbzeug realisiert werden [Neu06b; NDW07; Ble23]. Auch elastostatische und dynamische Effekte in Werkzeugmaschinen [Weg21; BEW09] führen zu Ungenauigkeiten der Abtriebspositionen, die sich auf Bauteilqualitäten auswirken und bei hohen Anforderungen an Maßhaltigkeiten einer Kompensation bedürfen. Die vor allem in der Massivumformung hohen Kraftspitzen bewirken eine Einfederung der Umformmaschinen [DL80], sodass bei der Berechnung von Stößelpositionen unter Annahme von Starrkörpermodellen Geometrieabweichungen in den Bauteilen entstehen. Besonders kritisch sind dabei orthogonal zur Hubrichtung wirkende Querkräfte oder außermittig angreifende Kräfte relativ zur Hochachse des Stößels, aus denen Drehmomente um den Mittelpunkt des Stößels resultieren. Damit gehen Stößelkippungen einher [Beh07; CCL13; SS94], welche durch zusätzliche Aktorik im Werkzeug kompensiert werden können [Mat16]. Nachgiebigkeiten von Pressen können entweder simulativ mithilfe der Finite-Elemente-Methode (FEM) [TPB20] oder experimentell [Beh07] bestimmt und somit bei der Auslegung von Stößelbewegungsprofilen berücksichtigt werden. Ansätze zur FEM-basierten Kopplung von Umformmaschine und Prozess finden sich in der Literatur beispielsweise für Tiefzieh- [Beh08] und Schmiedeprozesse [Kro08]. Nachteilig bei simulativen Ansätzen ist die mangelnde Berücksichtigung nichtlinearer, von unterschiedlichen Einflüssen wie Drehzahl und Schmierung abhängiger Lagersteifigkeiten [SKG19], die in besonderem Maße die Steifigkeit parallelkinematischer Maschinen beeinflussen [Bon09]. Lagersteifigkeiten parallelkinematischer Maschinen weisen oftmals ein ausgeprägtes Hystereseverhalten auf [Pri00] und reduzieren damit die Vorteile, die sich aus dem versteifenden Effekt der parallelkinematischen Maschinentopologie ergeben. Weite Teile parallelkinematischer Maschinen kennzeichnen sich durch nichtlineare Übersetzungsverhältnisse von Antriebs- und Abtriebspositionen und -kräften, weisen kinematische Singularitäten auf [Pri00; WS02] und bedürfen demzufolge der Anwendung anspruchsvoller Regelungsstrategien [WS00]. Groche et al. zeigen am Beispiel des Prototypens der 3DSP auf, dass sich Nichtlinearitäten nicht nur auf Kraft- und Geschwindigkeitsübersetzungen begrenzen, sondern ebenfalls das Steifigkeitsverhalten der Presse betreffen. [GHS17]

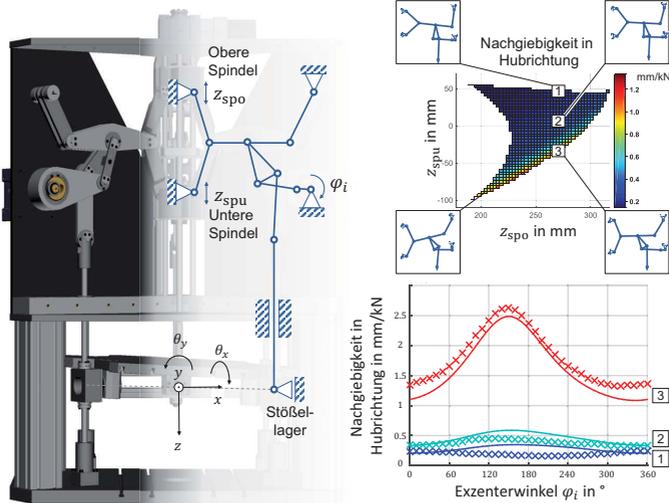


Abbildung 2.4.: Nichtlineares Steifigkeitsverhalten des Prototypens der 3DSP in Hubrichtung in Abhängigkeit der Spindelpositionen (oben) und des Exzenterantriebs bei festgelegten Spindelpositionen (unten) [GHS17]

Abbildung 2.4 stellt die parallelkinematische Topologie (links) und dazugehörige Nachgiebigkeitskennfelder der 3DSP in Abhängigkeit der Antriebspositionen (rechts) dar. Das als Stabmodell abstrahierte, blau eingezeichnete Getriebesystem findet sich in dreifacher Ausführung in der Maschine wieder, wobei die jeweiligen Ausführungen um  $120^\circ$  versetzt zueinander angeordnet sind. Die Spindelantriebe  $z_{spu}$  (untere Spindel) und  $z_{spo}$  (obere Spindel) sind über Spindelsterne mit allen drei Getriebesystemen verbunden. Der für das  $i$ -te Getriebesystem vorgesehene Exzenterantrieb  $\varphi_i$  manipuliert die vertikale Position des  $i$ -ten Stößellagers und resultiert bei phasenversetztem Betrieb der Exzenterantriebe in Kippbewegungen des Stößels um die eingezeichneten, raumfesten  $x$ - und  $y$ -Achsen. Die Redundanz der Presse ergibt sich aus dem Umstand, dass fünf Antriebe drei Abtriebsfreiheitsgrade manipulieren und demzufolge unterschiedliche Antriebsstellungen die gleiche Abtriebspose erzeugen können. Aus den Nachgiebigkeitskennlinien ist ersichtlich, dass die Pressensteifigkeit stark nichtlinear von den Antriebspositionen abhängig ist und niedrige Steifigkeitswerte vorliegen, sofern sich die Spindelantriebe voneinander entfernen und hohe

---

Hubhöhen zulassen. [GHS17] Dies lässt darauf schließen, dass insbesondere komplexe Maschinenkinematiken mit redundanter und parallelkinematischer Topologie hoher Unsicherheit ausgesetzt sind und eine Vielzahl an Einflüssen identifiziert, berücksichtigt und - falls möglich - kompensiert werden müssen, um die Vorteile solcher Kinematiken ganzheitlich auszunutzen. [PD12]

#### **2.1.4. Umweltseitige Unsicherheit**

Nicht zuletzt wirken sich Einflussfaktoren aus der direkten Prozessumgebung auf Bauteileigenschaften aus. Im Zusammenwirken von Halbzeug und Werkzeug übernehmen Schmierstoffe eine besonders wichtige Rolle, da ihr gezielter Einsatz Reibkräfte derartig beeinflussen kann, dass Umformprozesse qualitätsgerecht und wirtschaftlich betrieben werden können. So entscheiden die durch Schmierstoffe eingestellten Reibkräfte und der damit induzierte Wärmeeintrag oftmals über das lokale Fließverhalten des Materials, sodass über die Wahl der Art und Menge des Schmierstoffes Optimierungen der Umformgeschwindigkeiten und Bauteilmaßhaltigkeiten vorgenommen werden können. Hansen et al. zeigen auf, dass die Schmierstoffverteilung auf einem Blechcoil über dessen Länge und Breite schwankt und das Rissverhalten von Karoserierteilen aus der Automobilindustrie maßgeblich determiniert. [Han21] Darüber hinaus wirken Schmierstoffe Aufreibungen der Werkstücke entgegen [Doh21] und beeinflussen über deren Wärmeleitfähigkeit die in der Umformzone entstehenden Temperaturen [Yin17]. Neben prozess- und eigenschaftszentrierten Optimierungen werden seit geraumer Zeit gesteigerte Anforderungen an die Umweltverträglichkeit von Schmierstoffen gestellt. [Bay10] So zeigen Rao und Xie am Beispiel von umweltfreundlichen Borsäure-Schmiermitteln, dass diese sich in diversen Umformprozessen positiv auf Oberflächenqualitäten der Bauteile auswirken und dass die Mehrzahl der untersuchten Schmiermittel Reibkoeffizienten signifikant reduzieren. [RX06] Ähnliche Ergebnisse bezüglich der Effekte von Schmiermitteln auf Oberflächenrauheiten erzielen Herrmann et al. in einem Rundknetprozess. [HSK16]

Neben einer externen Zuführung von Schmierstoff sind Wärmeeinleitungen in die Umformzone ein probates Mittel, um die Umformbarkeit der Halbzeuge zu steigern. Dabei können die Halbzeuge entweder vor dem Prozess ohne Werkzeugkontakt, während des Prozesses mit Werkzeugkontakt oder kombiniert vor und während des Prozesses erhitzt werden, wobei sich lokale Erwärmungen oder ungewünschte

---

Temperaturgradienten negativ auf Bauteilqualitäten auswirken können [Neu06a]. Besonders starke Auswirkungen der Erwärmungen auf Umformbarkeiten sind in temperaturabhängigen Fließkurven von Aluminium- [Gro02], Magnesiumlegierungen [Cha00] und hoch-, höher- oder ultrahochfesten Stählen [MLG06] ersichtlich, woraus die Potentiale zur Erweiterung von Prozessgrenzen in temperierten Umformprozessen hervorgehen. Gleichzeitig führen inhomogene Temperaturverteilungen in allen drei Raumrichtungen des Halbzeuges zu inhomogenen, räumlichen Verteilungen von Bauteileigenschaften. Dies spiegelt sich in räumlich unterschiedlichen Umformbarkeiten und Rückfederungen wider [Mor17], betrifft ebenfalls Abschreckvorgänge und die aus jeweiligen Abschreckkurven hervorgehenden Gefügezusammensetzungen der Bauteile [TC18]. Inhomogene Bauteileigenschaften müssen jedoch nicht zwangsläufig ein aus einwirkender Unsicherheit entstehender, ungewünschter Effekt der Temperaturverteilungen von Bauteilen sein, sondern können - beispielsweise durch eine gezielte, lokale Erwärmung der Werkzeuge [MMM13] - bewusst hervorgerufen werden. Damit einhergehende gradierte Eigenschaften sind dennoch Gegenstand einwirkender Unsicherheit und können nicht beliebig genau eingestellt werden. Nicht zuletzt gehen mit Umformvorgängen bei hohen Temperaturen bislang unbekannte Herausforderungen einher, die die Wahl der Schmierstoffe und die Instrumente zur Bestimmung von Reibkoeffizienten einschränken und damit zusätzlich Unsicherheit in die Prozesse induzieren. [Doh15]

Ein weiterer Einflussfaktor auf Bauteileigenschaften sind Vibrationen oder akustische Emissionen benachbarter Prozesse oder Maschinen. Insbesondere Prozesse auf Maschinen, die in gleichen Räumen und auf gleichem Untergrund betrieben werden, interagieren miteinander und induzieren Schwingungen in benachbarte Systeme. [Weg21] Um jene Wechselwirkungen zu reduzieren, werden in besonders schwingungsanfällige Systeme dämpfende Elemente integriert [WXN94] oder Positionierungen zueinander optimiert [MY10; Oh11].

## **2.2. Ansätze zur Beherrschung von Unsicherheit**

Die in Kapitel 2.1 beschriebenen Quellen der Unsicherheit bedürfen eines systematischen Umgangs bei der Auslegung, dem Betrieb, der Überwachung und der Regelung von umformtechnischen Prozessen. In der produktionstechnischen Li-

---

teratur sind dazu unterschiedliche, mitunter verwandte Ansätze zu finden, die unsicheren Einflussgrößen Rechnung tragen und das Ziel verfolgen, Auswirkungen zu kompensieren und Reaktionsfähigkeiten auf Schwankungen sicherzustellen. Pelz et al. führen Strategien zur Beherrschung von Unsicherheit ein, die in die Klassen Robustheit, Flexibilität und Resilienz unterteilt werden. Während Robustheit auf die Fähigkeit eines Systems abzielt, vordefinierte Funktionen in unterschiedlichen, unsicherheitsbehafteten Arbeitspunkten bereitzustellen, zielt ein flexibles System darauf ab, auf unterschiedliche Arbeitspunkte zu adaptieren und eine Mehrzahl an Funktionen in diesen zu erfüllen. Resiliente Systeme sind als Weiterentwicklung robuster und flexibler Systeme anzusehen, die auf unbekannte Situationen reagieren können, indem sowohl das Systemverhalten als auch die bereitgestellten Funktionen zeitlich evolvieren. [Pel21a] Anforderungen an gesteigerte Robustheits-, Flexibilisierungs- und Resilienzgrade der Prozesse sind mit erhöhten adaptronischen Anforderungen an Maschinen und Werkzeuge verknüpft, wodurch sich neue Forschungsfelder eröffnen. Jene Forschungsfelder adressieren Fragen der optimalen Integration aktorischer und sensorischer Komponenten in die genutzten, mechatronischen Systeme und untersuchen deren Fähigkeit, intelligent miteinander zu interagieren. Bei der Entwicklung von Automatisierungslösungen sind nicht nur Hürden der technischen Realisierbarkeit zu überwinden, sondern ebenfalls wirtschaftliche Gesichtspunkte zu berücksichtigen. In den folgenden Unterkapiteln werden ausgewählte Ansätze aus der produktionstechnischen Forschung zur Beherrschung von Unsicherheit vorgestellt und deren Schnittmengen als auch Abgrenzungen diskutiert. Als Gemeinsamkeit weisen alle Ansätze auf, dass auf Modelle zurückgegriffen wird, die die Interaktionen zwischen Maschine, Werkzeug, Halbzeug und Umwelt beschreiben oder präzisieren können. Daher wird in Kapitel 2.2.1 in die Definition, Zielsetzung und Klassifikation von Modellen eingeführt, die sich als elementar für das Verständnis der darauf aufbauenden Forschungsansätze zur Beherrschung von Unsicherheit erweisen.

### **2.2.1. Modelle zur Beschreibung umformtechnischer Prozesse**

Die in Kapitel 2.1 beschriebene, auf Umformprozesse einwirkende Unsicherheit schlägt sich in minderwertigen Qualitäten von Bauteileigenschaften nieder, weswegen produzierende Unternehmen vor der Herausforderung stehen, solche Unsicher-

---

heit zu erfassen, zu quantifizieren und schlussendlich zu beherrschen. Ein besonders vielversprechendes Instrument im Umgang mit Unsicherheit ist die Aufstellung abstrahierter, mathematischer Zusammenhänge zwischen sensorisch erfassbaren Größen und Bauteileigenschaften. Um jene Zusammenhänge mathematisch zu beschreiben, sind Modelle erforderlich, die hinsichtlich physikalischer Interpretierbarkeit, Detaillierungsgrad und Robustheit massiv voneinander abweichen können. Im Folgenden werden die Definition und Zielsetzung von Modellen beschrieben, anschließend erfolgt die Vorstellung einer Klassifikation unterschiedlicher Modelltypen und deren Anwendungen in der Umformtechnik.

### Definition und Zielsetzung von Modellen

Modelle stellen mathematische Abstraktionen physikalischer Zusammenhänge dar und können gemäß [Pel21b] in impliziter Form mithilfe von

$$f(\mathbf{u}, \mathbf{y}, \mathbf{z}, \mathbf{m}) = 0 \quad (2.1)$$

beschrieben werden. Dabei stellen  $\mathbf{u}$  und  $\mathbf{z}$  die Ein- bzw. Ausgangsgrößen der Modelle,  $\mathbf{y}$  die meist zeitlich veränderlichen, internen Variablen wie etwa Zustände und  $\mathbf{m}$  die Modellparameter dar. Dabei trifft die von Box formulierte Aussagen „*Alle Modelle sind falsch, aber einige sind nützlich*“ [Box79] grundsätzlich auf jegliche Modelle zu, da jedes entwickelte Modell Unsicherheit beinhaltet und lediglich eine Approximation physikalischer Zusammenhänge darstellt. Der reale, physikalische Zusammenhang kann durch die Einführung eines Residualterms  $\delta f(\dots)$  beschrieben werden, der Abweichungen zwischen Modell- und realem Systemverhalten abbildet und üblichen Modellierungsungenauigkeiten - induziert durch beispielsweise mangelndes Wissen über das System oder numerische Fehler - Rechnung trägt. Damit erweitert sich die in impliziter Form gegebene Gleichung 2.1 zu

$$f(\mathbf{u}, \mathbf{y}, \mathbf{z}, \mathbf{m}) + \delta f(\dots) = 0. \quad (2.2)$$

Das übergeordnete Ziel von Modellen ist demnach die möglichst realitätsnahe Abbildung physikalischer Eingangs-Ausgangsgrößen-Beziehungen, was einer Minimierung entsprechender Residuen  $\delta f(\dots)$  zwischen Modell- und Systemausgängen entspricht. Unter der Voraussetzung, dass die Modellfunktion  $f(\cdot)$  differenzierbar und dessen

---

Ableitung nach den internen Variablen  $y$  invertierbar ist, kann die implizite Form nach Gleichung 2.1 in ein reduziertes Modell  $\eta$  überführt werden. Dieser Zusammenhang zwischen Eingangsgrößen  $\mathbf{u}$  und relevanten Ausgangsgrößen  $\mathbf{z}$  kann in expliziter Form

$$\eta(\mathbf{u}, \mathbf{m}) = \mathbf{z} \quad (2.3)$$

dargestellt werden und ermöglicht eine direkte Berechnung der Ausgangsgrößen. Modellunsicherheit kann ebenfalls in der expliziten Darstellungsweise abgebildet werden, wobei deterministische oder probabilistische Ansätze zur Quantifizierung auftretender Residuen herangezogen werden. Bei deterministischen Ansätzen können Polynomfunktionen  $p_f$  die Residuen annähern und über deren Polynomkoeffizienten  $\theta$  die Abweichungen zwischen Modell- und Systemverhalten minimieren, sodass sich für die explizite Form

$$\eta(\mathbf{u}, \mathbf{m}) + p_f(\mathbf{u}, \mathbf{m}, \theta) = \mathbf{z} \quad (2.4)$$

ergibt. Eine Methode probabilistischer Ansätze sind Einführungen von stochastischen Prozessen  $\delta$  und stochastischem Rauschen  $\epsilon$ , was auf die explizite Form

$$\eta(\mathbf{u}, \mathbf{m}) + \delta(\mathbf{u}, \mathbf{m}, \theta) + \epsilon = \mathbf{z} \quad (2.5)$$

führt, bei denen  $\theta$  wiederum Hyperparameter des stochastischen Prozesses darstellen, die oftmals über mathematische Optimierungen bestimmt werden. [Pel21b]

## Klassifikation von Modellen

Die in der Literatur üblichste Klassifikation von Modellen ist deren Einteilung in White-, Grey- und Black-Box-Modelle. [Ise05; Vol19; KK12; KGS09] White-Box-Modelle beruhen vollständig auf validierten mathematisch-physikalischen Gleichungen und damit auf wissenschaftlicher Evidenz, wohingegen Black-Box-Modelle auf statistische Instrumente zurückgreifen und Beziehungen zwischen Ein- und Ausgangsgrößen mithilfe der Identifikation von weitestgehend nichtlinearen Korrelationen schätzen. Die Kombination von White- und Black-Box-Modellen führt auf Grey-Box-Modelle, deren weiße bzw. schwarze Anteile stark variieren können. Grey-Box-Modelle mit hohem weißen Anteil beruhen ebenfalls auf mathematisch-

physikalischen Gleichungen, adaptieren einzelne Modellparameter  $m$  jedoch mit dem Ziel, Residuen nach Gleichung 2.2 und demnach Abweichungen zwischen Modellen und in realen Systemen durchgeführten Messungen zu minimieren. Demgegenüber gehen Grey-Box-Modelle mit hohem schwarzen Anteil aus rein statistischen Analysen hervor, wobei die Vereinbarkeit derer Ergebnisse mit Gesetzen der Physik, beispielsweise unter Anwendung zusätzlicher Regularisierungen [Kar21], grundsätzlich sichergestellt wird.

Volk et al. [Vol19] stellen in ihrem Keynote-Paper den aktuellen wissenschaftlichen Erkenntnisstand zu in umformtechnischen Prozessen eingesetzten Modellen vor. Darin präsentieren sie ebenfalls eine Unterteilung in White-, Grey- und Black-Box-Modelle und bieten genauere Definitionen der einzelnen Modellklassen. Abbildung 2.5 bildet eine Übersicht der Klassifikation und entsprechenden Definitionen ab. Neben den bereits beschriebenen Unterteilungen unterscheiden die Autoren heuris-

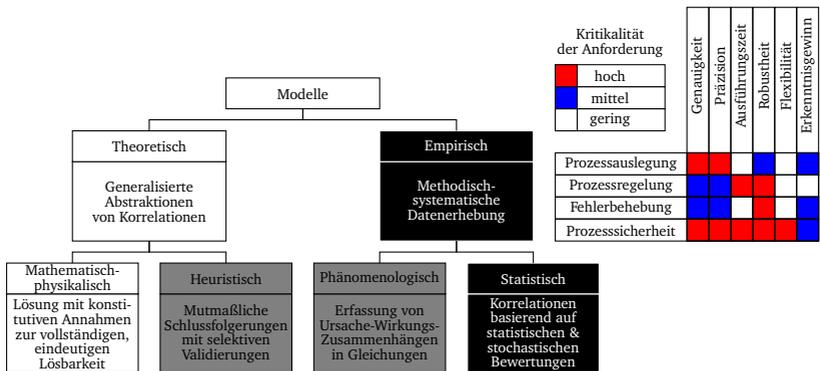


Abbildung 2.5.: Klassifikation von Modellen in White-, Gray- und Black-Box-Modelle in Anlehnung an [Vol19]

tische und phänomenologische Grey-Box-Modelle gemäß [BDD02], deren Ursprung in weißen bzw. schwarzen Modellen liegt. Heuristische Elemente werden in weiße Modelle integriert, um Defizite, die sich aus vernachlässigten, jedoch relevanten Phänomenen ergeben, zu kompensieren. Diese können in bestimmten Arbeitsbereichen validiert werden, ihre Gültigkeit kann jedoch nicht in allen möglichen Arbeitspunkten sichergestellt werden. Phänomenologische Grey-Box-Modelle erfassen aus Daten

---

identifizierte Ursache-Wirkungs-Zusammenhänge in Gleichungen. Dabei werden Korrelationen zwischen Ursachen und Wirkungen identifiziert, die nicht durch physikalische Gleichungen beschreibbar sind, jedoch reproduzierbar auftreten und somit offensichtlich in Verbindung zueinander stehen. [Vol19]

Über die Klassifikation hinaus definieren die Autoren Modellanforderungen und stellen Beziehungen zu unterschiedlichen Anwendungsfeldern her (siehe Abbildung 2.5 rechts). Die Kurzdefinitionen der Anforderungen nach [Vol19] lauten wie folgt:

- Genauigkeit: Übereinstimmung zwischen prädiziertem und wahren Wert (Auftreten systematischer Fehler)
- Präzision: Reproduzierbarkeit bzw. Streubreite von prädizierten Werten (Auftreten zufälliger bzw. stochastischer Fehler)
- Ausführungs- und Antwortzeit: Beanspruchung von Rechenkapazitäten bzw. Zeit zur Berechnung von Ausgangsgrößen
- Robustheit nach [Mia13]: Fähigkeit eines Modells, akkurate Resultate unter unterschiedlichen experimentellen Bedingungen zu liefern
- Flexibilität nach [Avg07]: Adaptionfähigkeit an neue Anwendungen, für die das Modell ursprünglich nicht entwickelt wurde
- Erkenntnisgewinn: Grad, zu dem neue Erkenntnisse über den Prozess aus Modellanalysen und -optimierungen hervorgehen

Abbildung 2.5 enthält einen Auszug der Zuordnung von Anforderungen an die in unterschiedlichen Anwendungsbereichen eingesetzten Modelle. Es wird ersichtlich, dass Modelle, die der Regelung von Umformprozessen dienen, besonders zeitkritisch sind und ihre Funktionalität unter heterogenen experimentellen Bedingungen unter Beweis stellen müssen. Weiterhin sind Mindestanforderungen an die Genauigkeit und Präzision der Modelle zu erfüllen, um eine möglichst genaue und reliable Einstellung von Bauteileigenschaften zu ermöglichen. Demgegenüber sind Anwendungen zur Auslegung von Prozessen oder zur Behebung von Fehlern zeitlich deutlich unkritischer, da diese nicht im laufenden Prozess zum Einsatz kommen und die Prozessaktzeiten bestimmen. Im Folgenden wird eine Auswahl in der Umformtechnik zur Prozessregelung eingesetzter Modelle präsentiert, wobei nach der

---

bereits beschriebenen Einteilung in White-, Grey- und Black-Box-Modelle unterteilt wird.

**White-Box-Modelle** White-Box-Modelle basieren zumeist auf komplexen, rechenintensiven Zusammenhängen zwischen Ein- und Ausgangsgrößen und stellen Anwender vor hohe Modellierungsaufwände. Die wohl einfachsten Modelle, die zur Regelung von Umformprozessen herangezogen werden, sind Kinematikmodelle, wodurch die Positions- und Geschwindigkeitsübersetzungen zwischen Maschinenantrieben und Werkzeugen berechnet werden. Dabei korreliert der Modellierungsaufwand mit der Anzahl an Freiheitsgraden von Umformmaschinen. Während das Übersetzungsverhalten von Maschinen mit einem Freiheitsgrad wie etwa konventionellen Kurbel- oder Kniehebelpressen (siehe dazu [Lan85]) relativ trivial zu berechnen ist, erfordern redundante Maschinen wie die 3DSP komplexe Modellbildungen, um Stößelposen mit drei Freiheitsgraden zu regeln [HPG19; Hop21].

Zur direkten Berechnung von Bauteileigenschaften entwickelte White-Box-Modelle basieren in den meisten Fällen auf Grundlagen der Plastizitätslehre und weisen daher starke Nichtlinearitäten auf. Von beherrschbarer Komplexität sind eindimensionale Berechnungen von Rückfederungen in Biegeprozessen [BC04; Li10; WKA93], die mitunter zur Steuerung von Biegewinkeln zum Einsatz kommen [ES99]. Multidirektionale, analytische Modelle zur Berechnung von Rückfederungen bei der Herstellung komplexerer Biegeteile existieren ebenfalls. Entsprechende Ansätze, diese mithilfe von optischer Messtechnik zu regeln, sind bislang noch nicht entwickelt. [MW21] Ansätze zur Berechnung von Faltenbildungen in Tiefziehteilen basieren ebenfalls auf analytischen Ansätzen [WKA95] und werden derzeit in ihrer Modellordnung reduziert, um sie durch kürzere Rechenzeiten für regelungstechnische Ansätze zu qualifizieren [CCK22]. Weitere White-Box-Modelle befassen sich mit der Vorhersage von Rissbildungen [Gur77; TN84] und Blechausdünnungen [SR75; MK67], dienen momentan jedoch nur der Auslegung von Prozessen und finden sich kaum in regelungstechnischen Ansätzen wieder. Ein interessanter Ansatz ist die Kopplung von FEM-Simulationen mit Regelungen. So zeigen Groche et al. am Beispiel eines störgrößenbeaufschlagten Tiefziehprozesses, dass unterschiedliche Prozessgrößen regelbar sind und eine simulative FEM-Abbildung der Regelkonzepte hohe Übereinstimmungen mit experimentellen Ergebnissen aufweist. [E1] Endelt nutzt geregelte FEM-Simulationen zur Findung optimaler Druckverläufe bei der

---

Innenhochdruckumformung von Rohren und stellt unter Beweis, dass in der Simulation ausgelegte Reglerverstärkungen in den realen Prozess transferiert werden können. [End22]

**Grey-Box-Modelle** Im Vergleich zu White-Box-Modellen werden Grey-Box-Modelle zeitlichen und genauigkeitsbezogenen Anforderungen eher gerecht, da einerseits Anpassungen an gemessene Datenpunkte vollzogen oder besonders rechenintensive, auf analytischen Ansätzen beruhende Modellteile durch datengetriebene Modelle substituiert werden können. Auf Maschinenebene zeigt Hoppe am Beispiel der 3DSP, dass die Modellierung des dynamischen Verhaltens des Antriebsstranges von datengetriebenen Modellen profitieren kann. Während Kräfte, die durch Trägheiten und Gravitation in das System einwirken, unter Kenntnis von Systemzuständen wie Antriebspositionen, -geschwindigkeiten und -beschleunigungen durch analytische Modelle abbildbar sind, werden Reibkräfte durch einen geschwindigkeitsproportionalen, an Messdaten gefitteten Term abgebildet. [Hop21] Die Modellierung tribologischer Effekte ist ein in der Umformtechnik auf großes Interesse stoßendes Forschungsgebiet, in dem Grey-Box-Modellierungen weit verbreitet sind. So werden in der Literatur eine Vielzahl an Modellen vorgestellt, die Reibkoeffizienten von den wichtigsten tribologischen Lasten wie etwa Kontaktnormalspannung, Relativgeschwindigkeit, Oberflächenvergrößerung und in der Umformzone wirkende Temperatur abhängig machen, wobei funktionale Zusammenhänge über logarithmische Regressionen [Gro18] oder NN [E19] ermittelt werden. Erhebliches Potenzial bieten diese Ansätze in Zukunft für FEM-Simulationen, da über solche Ansätze Reibkoeffizienten variabilisiert werden können und bei Kenntnis genannter Parameter für die einzelnen Knoten sowohl eine zeitliche als auch räumliche Auflösung des Reibverhaltens realisierbar ist. [E19]

Prozessregelungstechnische Anwendungen von Grey-Box-Modellen finden sich ebenfalls in der Literatur. Manabe et al. stellen in einem Tiefziehprozess unter Beweis, dass sie Materialeigenschaften von Bauteilen und Schmierzustände unter Kenntnis von Prozessparametern wie Hubhöhe und Kraft durch ein NN schätzen können. Geschätzte Werte werden anschließend in ein plastisches Deformationsmodell gespeist, das Verläufe der Niederhalterkräfte berechnet, die zu Falten oder Rissen führen. Die Autoren zeigen, dass mithilfe dieser Strategie die Niederhalterkräfte zielgerichtet eingestellt werden können, sodass genannten Fehlerbildern vorgebeugt wird. [MY98]

---

Am Beispiel eines Single Point Incremental Forming (SPIF)-Prozesses auf einer 3DSP gleichen Hesse et al. experimentell und simulativ ermittelte Gradientenfelder ab, die den Einfluss geometrischer Merkmale auf die axiale Steifigkeit von Bauteilen quantifizieren. Aufgrund der hohen Übereinstimmung beider Gradientenkennfelder rechtfertigen sie damit deren Einsatz für eine Hub-zu-Hub-Regelung und stellen unter Beweis, dass die axiale Bauteilsteifigkeit über eine Adaption des Werkzeugspitzenpfades manipulierbar ist. [HHG17] Groche et al. zeigen am Beispiel eines mehrstufigen Stanz-Biege-Prozesses, dass Biegewinkel mithilfe einer modellbasierten Regelung eingestellt werden können. Dazu werden funktionale Beziehungen zwischen Biegewinkel und den Parametern Hubhöhe, Blechdicke und Maximalkraft der vorgelagerten Stanzstufe aufgestellt, die auf ein nichtlineares Modell führen und eine Anwendung von Methoden der linearen Regelungstechnik verhindern. Daher werden nichtlineare Modellteile durch an Experimentaldaten gefittete Koeffizienten substituiert und das Modell linearisiert. Dies lässt eine modellbasierte, vorgesteuerte Regelung der Biegewinkel zu und führt sowohl in simulativen als auch experimentellen Untersuchungen zu vielversprechenden Ergebnissen. [Gro16] Eine ähnliche Vorgehensweise, die Nichtlinearitäten von White-Box-Modellen umgeht, wird von Wehr et al. [Weh18] in einem kontinuierlichen Blechumformprozess realisiert. Beim Kaltwalzen von Blechen wenden diese ein von Alexander [Ale72] entwickeltes analytisches Modell zur Abschätzung von Walzkräften an. Da das analytische Modell auf Differentialgleichungen beruht und ausschließlich durch numerische Berechnungsverfahren wie das Runge-Kutta-Verfahren gelöst werden kann, nutzen die Autoren Ergebnisse des Modells und eine gefittete Polynomfunktion, um einen Zusammenhang zwischen den vor und nach der Walzoperation vorliegenden Blechdicken und der Walzkraft herzustellen. Die entwickelte Funktion dient anschließend als Grundlage zur Anwendung einer modellprädiktiven Regelungsstrategie, die über Zustellungen der Walzspalte die Blechdicke regelt. [Weh18]

**Black-Box-Modelle** Forschungsfortschritte auf dem Gebiet des tiefen Lernens [LBH15], zunehmende Verfügbarkeiten von Daten und Rechenleistungen [Gao20] als auch kostenfreie Zugriffe auf leistungsfähige Programmbibliotheken [Aba16; Pas17; Har20] sind mitunter die wichtigsten Treiber der Popularisierung von Black-Box-Modellen in der Produktionstechnik. Besonders attraktiv sind Black-Box-Modelle aufgrund geringer Ausführungs- bzw. Antwortzeiten und der Tatsache, dass zur

---

Modellierung der Beziehungen zwischen Eingangs- und Ausgangsgrößen nur geringes Prozessverständnis aufgebracht werden muss. Gleichzeitig ist diese Tatsache einer der größten Kritikpunkte des Einsatzes von Black-Box-Modellen, da die Robustheit solcher Modelle insbesondere in Arbeitspunkten, in deren direkter Umgebung keine oder nur eine geringe Menge an Daten vorhanden sind, nicht sichergestellt werden kann. Nichtsdestotrotz werden Black-Box-Modelle in den letzten Jahren zunehmend in produktionstechnischen Anwendungen zur Zustandsüberwachung [Tet22] und Prozessregelung [Moz22] eingesetzt. Dabei unterscheiden sich die für die Modellbildung notwendigen Tätigkeiten erheblich von jenen, die zur Modellierung mithilfe von White-Box-Modellen erforderlich sind. Aufgrund der erst kürzlich erfolgten Popularisierung verfügen ingenieurtechnische Fachkräfte derzeit nur geringfügig über Kompetenzen bezüglich der Entwicklung von Black-Box-Modellen. Der Weg von unstrukturierten, heterogenen Datenformaten hin zu funktionsfähigen, datengetriebenen Modellen ist meist ein komplexer Prozess, bei dem unerfahrene Anwender eine strukturierte Vorgehensweise verinnerlichen sollten, bevor Modellierungsansätze erprobt werden. Aus diesem Grund haben sich Forscher in den 90-er Jahren mit der Erarbeitung von Prozessmodellen beschäftigt, die Anwendern als Leitfaden dienen sollen. „Knowledge Discovery in Databases“ [FPS96] oder „CRISP-DM“ [WH00] sind dabei die wichtigsten Vertreter solcher Prozessmodelle, lassen sich jedoch aufgrund der Annahme, dass Datensätze im ersten Prozessschritt bereits verfügbar sind, nur bedingt auf produktionstechnische Anwendungen übertragen. Dieses Defizit erkennen Huber et al. und entwickeln aus diesem Grund das „DMME“-Prozessmodell, das eine auf ingenieurtechnische Anwendungen abgestimmte Erweiterung des CRISP-DM Modells mit neun Prozessschritten darstellt. [Hub19] Mehrere Schritte des DMME-Prozessmodells adressieren stark anwendungsspezifische Fragestellungen, deren Beantwortung bei der Implementierung industrieller Anwendungen zweifellos sinnvoll ist, jedoch die Übersichtlichkeit bei der systematischen Beschreibung entwickelter Lösungen gefährdet. Aus diesem Grund stellen Molitor et al. [E10] und Kubik et al. [E6] das „Knowledge Discovery in Times Series for Engineering Applications (KDT-EA)“-Prozessmodell vor, das durch einen übersichtlichen Aufbau und fünf aufeinanderfolgende Prozessschritte gekennzeichnet ist. Abbildung 2.6 veranschaulicht das KDTEA-Prozessmodell, das in der vorliegenden Arbeit als Leitbild für die Entwicklung datengetriebener Modelle dient. Im Prozessschritt der Datenerfassung werden Sensoren anforderungsgerecht qualifiziert

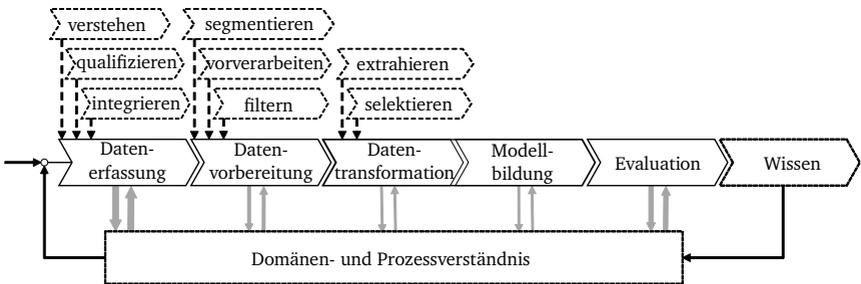


Abbildung 2.6.: KDT-EA-Prozessmodel in Anlehnung an [E10; E6]

und in Prozesse integriert. Hierbei sind Anforderungen bezüglich zeitlicher und räumlicher Auflösung, Bauraumrestriktionen sowie Auswirkungen auf den qualitäts- und wirtschaftlichkeitsgerechten Betrieb des Prozesses mitzudenken. Ergebnis des Prozessschrittes Datenerfassung ist das Vorliegen von unstrukturierten Rohdaten. Diese werden im Schritt der Datenvorbereitung vorverarbeitet, bei Bedarf relevante Datenbereiche segmentiert und gefiltert, um das Signal-Rausch-Verhältnis zu maximieren. Liegen die Daten nach den vorbereitenden Maßnahmen in strukturierter Form vor, erfolgt eine Reduzierung derer Dimensionalität. Dazu werden Kennwerte aus den Daten extrahiert und diese anschließend bezüglich ihrer Eignung, relevante Informationen für die Modellbildung bereitzustellen, bewertet. Dabei kommen Kennwertselektionsmethoden zum Einsatz, die in Filter-, Wrapper- und hybride Methoden unterteilt werden können. [KJ97] Während Filtermethoden keine Interaktion mit dem im Prozessschritt der Modellbildung genutzten Algorithmus erfordern, werden bei der Verwendung von Wrapper-Methoden Kennwertteilmengen iterativ in die Algorithmen gespeist und Kennwerte basierend auf Performanzen der Algorithmen eliminiert oder einbezogen. Hybride Methoden kombinieren beide genannten Ansätze und verfolgen das Ziel, die Vorteile recheneffizienter Filter-Algorithmen mit denen performanzoptimierender Wrapper-Methoden zu vereinen. [KJ97] Im Schritt der Modellbildung werden die in Kapitel 2.2.1 beschriebenen mathematischen Zusammenhänge aufgestellt, indem Muster in den Daten durch den Algorithmus identifiziert und in Modelle überführt werden. Dabei kann die Modellkomplexität durch die Wahl der Algorithmen und deren Topologien variiert werden, wobei einfachste Ansätze Korrelationen zwischen Eingangs- und Ausgangsgrößen

---

durch lineare oder polynomiale Regressionsfunktionen beschreiben. Universelle Approximatoren, die beliebige nichtlineare Korrelationen abbilden können, stellen NN dar, die durch Adaptionen ihrer Modellparameter vordefinierte Kostenfunktionen minimieren. Die Nutzung von NN stellt Anwender vor die Herausforderung, geeignete Hyperparameter zu wählen, die entscheidend für die Modellperformanz sein können. Als Hyperparameter werden jegliche Eigenschaften angesehen, die Anwender vor der Modellbildung wählen können und beziehen sich bei NN beispielsweise auf die Anzahl an Neuronen, versteckten Schichten, Wahl der Aktivierungs- oder Kostenfunktion. Ein besonderer Fall der Modellbildung sind tiefe Netze [LBH15], die die Prozessschritte der Datentransformation und Modellbildung vereinen. So können beispielsweise die aus dem Prozessschritt der Datenvorbereitung strukturierten Daten auf direktem Wege in faltende neuronale Netze (engl.: Convolutional Neural Network) (CNN) eingespeist werden, deren Faltungs- und Pooling-Schichten automatisiert relevante Kennwerte aus den Daten extrahieren.<sup>2</sup> Dies ermöglicht eine engere Interaktion kennwertextrahierender und -selektierender Techniken mit dem verwendeten Modell und ist besonders vorteilhaft bei dimensionsreichen Zeitreihen-[Ism19] oder Bilddatensätzen [KSH17].

Die Performanz der Algorithmen wird abschließend mittels geeigneter Metriken evaluiert. Bei überwachten Lernmethoden wird dabei zwischen Bewertungsmetriken klassifizierender und regressierender Algorithmen unterschieden, wobei klassifizierende Bewertungsmetriken meist Prozentualwerte von richtig bzw. falsch klassifizierten Stichproben darstellen und regressierende Metriken die Abweichungen zwischen realem und durch den Algorithmus prädiziertem Wert quantifizieren. Mithilfe der Metriken können Anwender Entscheidungen hinsichtlich der Einsatzfähigkeit des entwickelten Modells treffen und bei Bedarf ihr Domänen- und Prozessverständnis nutzen, um Änderungen in den vorgelagerten Schritten der Datenerfassung, -vorbereitung, -transformation und Modellbildung vorzunehmen.<sup>3</sup>

In der umformtechnischen Forschung finden überwiegend überwachte Lernalgorithmen Anwendung. [ES1] Anwendungsfälle am PtU der Technischen Universität Darmstadt adressieren Verschleißdetektionen basierend auf Kraft- [E4], Drehmoment- [E5], Beschleunigungs- [E3] und Bilddaten [S3; S2], wobei die Bilder über konven-

---

<sup>2</sup>Grundlagen überwachter Lernalgorithmen und im Speziellen von multiplen linearen Regressionen (MLR), NN und CNN sind Anhang A.8 zu entnehmen.

<sup>3</sup>Die wichtigsten Vertreter von Bewertungsmetriken regressierender Algorithmen sind in Anhang A.8.4 beschrieben.

---

tionelle, maschinelle [E8] oder tiefe Lernverfahren [E14; E15] verarbeitet werden können. Forschungsansätze aus der Informatik adressieren Steigerungen von Modellflexibilitäten über Domain Adaptation Techniken [WD18], die in bild- [S12] und zeitreihenbasierten [E7] Verschleißmodellen eine Übertragbarkeit von CNN auf unbekannte Bauteilgeometrien oder Halbzeuge sicherstellen. Eine räumliche Auflösung des Verschleißverhaltens kann durch die Anwendung vollfaltender NN sichergestellt werden [S5; S6], wobei eine hubweise Bildaufnahme von Stanzstempeln in schnelllaufenden Prozessen und deren Einspeisung in segmentierende Algorithmen eine hohe zeitliche und räumliche Auflösung unterschiedlicher Verschleißerscheinungen ermöglicht [E16]. Ebenfalls können Erkenntnisgewinne aus den genannten Anwendungen von CNN gewonnen werden, indem gradientenbasierte Explainable AI Techniken [Gun19] Datenbereiche kenntlich machen, die die Netze zur Berechnung der Ausgangsgröße verstärkt herangezogen haben. Anwendungen dazu finden sich in Modellen zur Verschleißdetektion [S1; S13] und Rissbildung [S4] von Bauteilen und zeigen deutlich, dass Bildbereiche, in denen jeweilige Mängel abgebildet werden, entscheidungsrelevant für die verwendeten Algorithmen sind. Kritikalitäten der Anwendungen von tiefen Lernalgorithmen ergeben sich, sofern lediglich unzureichende Datenmengen verfügbar sind. Konventionelle Data Augmentation Techniken als auch Generative Adversarial Networks konnten unter Beweis stellen, dass sich manipulierte bzw. synthetisierte Daten positiv auf Klassifikationsgenauigkeiten auswirken [S9] und eine verlässliche Detektion von diskreten Verschleißklassen in Stanzprozessen selbst bei niedriger Datenverfügbarkeit sicherstellen. [E13]

Neben zustandsüberwachenden Anwendungen sind in der umformtechnischen Literatur ebenfalls modellbasierte Prozesssteuerungen und -regelungen zu finden, die auf Black-Box-Modelle zurückgreifen. Die ersten Ansätze dazu wurden in Biegeprozessen demonstriert, in denen NN basierend auf Kennwerten aufgenommener Kraftsignale optimale Hubhöhen [FGR98] oder Niederhalterkräfte [VKC03] bestimmen können. Ziel dieser Anwendungen ist es, die durch Rückfederungseffekte induzierten Geometrieabweichungen zu eliminieren. Ähnliche Ansätze aus Biegeprozessen nutzen Kennwerte von Halb- und Werkzeug als Eingangsdaten für eine lineare Regression (LR) [Gro15] oder NN [IDD00] und zeigen auf, dass halbzeug- und werkzeugseitige Unsicherheit kompensierbar ist. Endelt und Danckert nutzen eine kaskadierte Regelungsstrategie zur Manipulation des Blecheinzugs in einer FEM-Tiefziehsimulation, bei der sowohl kurzzyklisch (ungleiche Schmierverhältnis-

---

se) als auch langzyklisch schwankende Prozessparameter (Werkzeugverschleiß und -temperatur) durch einen iterativ lernenden Algorithmus beherrscht werden. Dabei werden optimale Reglerverstärkungsfaktoren unter Minimierung einer Kostenfunktion erlernt, die zu niedrigen Abweichungen des Blecheinzugs (Regelgröße) und gleichzeitig geringen Sprüngen der Niederhalterkräfte (Stellgröße) führen. [ED10; End17] Auf iterativ lernenden Ansätzen beruhende Regelstrategien sind ebenfalls für simulative [Fio14] und experimentelle [Fio15] Geometrieregungen beim SPIF eingesetzt worden. Einen vielversprechenden Ansatz zur Regelung der Geometrie in einem SPIF-Prozess zeigen Störkle et al. auf, die bestärkende Lernverfahren (engl.: Reinforcement Learning) (RL) zur Geometrieoptimierung vorschlagen. Dabei sollen über 3D-Messtechnik Abweichungen zwischen Soll- und Ist-Geometrie erfasst und daraufhin Trajektorienparameter des Werkzeugpfades modifiziert werden. [Sto16] Die Veröffentlichung stellt eine experimentelle Implementierung des Ansatzes in Aussicht, welche nach bestem Wissen und Gewissen des Verfassers der vorliegenden Arbeit nicht realisiert wurde. Erste Anwendungen von RL zur Regelung von Umformprozessen werden von Dornheim et al. vorgestellt. Am Beispiel einer FEM-Tiefziehsimulation zeigen die Autoren, dass eine multikriterielle Optimierung des Prozesses unter Anwendung eines Q-Learning Algorithmus möglich ist. Dabei werden als Bauteileigenschaften Spannungsverteilungen, maximale Blechausdünnung und Materialnutzungsgrade zur Berechnung der Belohnungsfunktion herangezogen und zu diskreten Zeitschritten optimale Niederhalterkräfte abgeleitet, die die genannten Eigenschaften optimieren. Die Autoren vergleichen die Ergebnisse bei voller, partieller und nicht gegebener Beobachtbarkeit (Kenntnis über Reibkoeffizient), wobei die Bereitstellung von Informationen über relevante Prozesszustände die Performanz des Algorithmus erheblich steigert. [DLG20] In einer weiteren Veröffentlichung zeigen die Autoren, dass die Findung optimaler Prozessstellgrößen zur gezielten Einstellung von Werkstoffmikrostrukturen in ein Problem überführt werden kann, das durch RL lösbar ist. [Dor22] RL bieten somit das Potential, optimale Stellgrößen für unsicherheitsbehaftete Prozesse zu identifizieren, bei denen gezielte Bauteileigenschaften eingestellt werden sollen. Eine Erprobung der Algorithmen in realen Umgebungen ist jedoch mit einer Vielzahl an Herausforderungen verknüpft, die unter anderem mangelnde Datenverfügbarkeiten, partielle Beobachtbarkeiten und hochdimensionale Zustands- und Aktionsräume betreffen. [Dul20] Aus diesen Gründen sind Anwendungen von RL in produktionstechnischen Prozessen derzeit

---

weitestgehend simulativer Natur [Li23b], umformtechnische Anwendungen in realen Prozessen mit dem Ziel der Steigerung von Bauteilqualitäten sind Gegenstand von Forschungsbemühungen.

### **2.2.2. Flexibilität in der Umformtechnik**

Ein Ansatz zur Beherrschung von Unsicherheit ist die Steigerung von Freiheitsgraden in umformtechnischen Prozessen. Flexibilität spiegelt sich in der Befähigung von Produktionssystemen wider, Bauteile trotz variierender Anforderungen an Losgrößen, Formkomplexitäten und Bauteileigenschaften auf den zur Verfügung stehenden Anlagen fertigen zu können. Dies kann durch Erweiterungen von Systemfähigkeiten gelingen, indem Maschinen mit höherer Anzahl an Freiheitsgraden ausgerüstet, physikalische Parameter des Halbzeugs oder der Umgebung gezielt variiert und mehrere Prozesse zu Prozessketten zusammengeführt werden. [Yan18] Ein weiteres Instrument zur Sicherstellung von Flexibilität ist die Steigerung der Reaktionsfähigkeit von Produktionssystemen an identifizierte Zustände, was mit einer Flexibilisierung des System- und Maschinenbetriebes einhergeht. Darunter sind zumeist informationstechnische Automatisierungslösungen auf den System- und Maschinensteuerungen zu subsumieren, welche zustandsorientierte Systemadaptionen ermöglichen. [Yan18] Grundvoraussetzung dafür sind Einwirkungsmöglichkeiten in die Prozesse, deren Folgen bekannt sind und so gewählt werden können, dass vordefinierte Anforderungen an die Prozesse und Bauteile erfüllt werden. So wurde in den letzten Jahrzehnten beispielsweise die Entwicklung und industrielle Verbreitung von Servopressen maßgeblich vorangetrieben. [Osa11] Besonderheit dieser Pressen sind hochgenau regelbare Servomotorantriebe, mit denen Bewegungsprofile des Abtriebs frei programmiert [Kri21] und somit auf unterschiedliche Bauteilgeometrien angepasst werden können. Stattet man den Stößel von Servopressen durch kinematisch entkoppelte Druckpunkte aus, deren Ansteuerung durch separate Servomotoren realisiert wird, kann die Anzahl an Freiheitsgraden gesteigert werden. Groche et al. zeigen am Beispiel der bereits in Abbildung 2.4 vorgestellten 3DSP, dass die Integration zusätzlicher Freiheitsgrade in Pressen mehrdimensionale Stößel- und Werkzeugbewegungen ermöglicht, was Potenziale zur Manipulation geometrischer Bauteileigenschaften birgt. [Gro10] Dabei stellen die Autoren eine Klassifikation

---

des Flexibilitätsbegriffes nach Son und Park vor [SP87], nach der Flexibilität in produktionstechnischen Anwendungen in Bezug auf Ausrüstung, Produkt, Prozess und Nachfrage vorliegen kann. Während ausrüstungsbezogene Flexibilität Produktionssysteme befähigt, neue Produkte ohne oder mit geringen Nachrüstungsaufwänden in die Produktion zu integrieren, adressiert produktbezogene Flexibilität die Herstellung einer hohen Produktvielfalt. Prozessbezogene Flexibilität ermöglicht eine einfache Umstellung der Bauteilverarbeitung, welche beispielsweise durch eine niedrigschwellige Nachrüstung von technologischen Innovationen herbeizuführen ist, und nachfragebezogene Flexibilität lässt schnelle Reaktionen auf Schwankungen der Kundennachfrage zu. [SP87] Mit zunehmender Anzahl an in Produktionssysteme und Maschinen integrierte Freiheitsgrade steigt nach Groche et al. die ausrüstungs-, prozess- und produktbezogene Flexibilität, sinkt jedoch aufgrund zunehmender Komplexität und geringerer Produktivität die nachfragebezogene Flexibilität. [Gro10] Dieser Zusammenhang lässt sich anschaulich durch einen Vergleich konventioneller und inkrementeller Umformprozesse beschreiben. Konventionelle Umformprozesse mit einem Freiheitsgrad, wie etwa Biege-, Tiefzieh- oder Fließpressprozesse, sind aufgrund von hohen Umformgeschwindigkeiten und niedrigen Werkstück-Werkzeug-Kontaktzeiten hochproduktiv. Dabei wird die resultierende Bauteilgeometrie jedoch stark von den geometrischen Eigenschaften der Werkzeuge bestimmt, wodurch eine Adaption an sich ändernde Anforderungen bezüglich Bauteileigenschaften nur selten realisierbar ist. Die Geometrie von Bauteilen aus inkrementellen Umformprozessen, wozu das SPIF [Mar08] oder Vertreter von inkrementellen Massivumformprozessen wie etwa Taumelschmieden, Ringwalzen oder Rundkneten gehören [Gro07], wird stärker von den Bewegungsprofilen der Maschinen und Werkzeuge determiniert, bringt jedoch lange Werkstück-Werkzeug-Kontaktzeiten mit sich. Zudem führen hohe lokale Beanspruchungen von Halbzeug und Werkzeug sowie anspruchsvolle Steuer- und Regelkonzepte auf tendenziell niedrigere Umformgeschwindigkeiten [Gro07], wodurch die nachfragebezogene Flexibilität limitiert wird. Die vorliegende Substitutionalität zwischen den genannten Flexibilitätsarten stellt Produzenten bei ihrer Anlagenwirtschaft und der Planung von Prozessketten vor die Herausforderung, wirtschaftliche als auch technische Potenziale und Grenzen flexibilitätssteigernder Maßnahmen abzuschätzen und diese bei kostenintensiven Investitionsentscheidungen mitzudenken.

---

### 2.2.3. Regelung von Bauteileigenschaften

Eigenschaftsregelungen und -prädiktionen in umformtechnischen Prozessen gehen auf diverse Arbeiten unter Mitarbeit von Allwood zurück [All09; All16; Tek15; PAD14] und verfolgen das Ziel, Produkteigenschaften unter Nutzung adaptiver Komponenten und Regelgesetzen zielgerichtet zu beeinflussen. Abbildung 2.7 stellt ein generisches Blockschaltbild für Bauteilregelungen in der Metallumformung nach [All16] dar, dessen kaskadierter Aufbau aus einem Offline-Produktregler in der äußeren Kaskade und einem Online-Prozessregler in der inneren Kaskade besteht. Dabei realisiert der Produktregler eine Bauteil-zu-Bauteil bzw. Hub-zu-Hub-Regelung, bei der nach der Fertigung eines Bauteils die Bauteileigenschaften durch den Produktsensor gemessen und mithilfe des Produktreglers neue Führungsgrößen für den Prozessregler ermittelt werden. Der Prozessregler manipuliert den Prozess echtzeitlich gemäß den aus dem Produktregler erhaltenen Führungsgrößen und greift dabei auf Signale des Prozesssensors zurück. Wie in Kapitel 2.2.1 bereits am Beispiel unterschiedlicher umformtechnischer Anwendungen dargelegt, basieren sowohl Produkt- als auch Prozessregler auf Modellen unterschiedlicher Art und sind daher Gegenstand von Modellunsicherheit  $\delta_{M_0}$ . Die in Kapitel 2.1 beschriebene Messunsicherheit  $\delta_{M_e}$  spiegelt sich in den Messergebnissen der Prozess- und Produktsensoren wider. Aufgezeigte Unsicherheit aus Maschine  $\delta_M$ , Werkzeug  $\delta_W$ , Halbzeug  $\delta_H$  und Umwelt  $\delta_U$  (siehe Kapitel 2.1.1 - 2.1.4) wirkt auf den Prozess, wobei sich Teile der beiden letztgenannten Unsicherheitsquellen ebenfalls in Form von thermischen oder elastischen Relaxationen erst nach dem Prozess auf Bauteileigenschaften auswirken.

Die Bereitstellung von Flexibilität kann dabei als Voraussetzung zur Regelung von Bauteileigenschaften angesehen werden. Die für die Manipulation der Bauteileigenschaften vorgesehenen Aktoren sind das Instrument zur Bereitstellung von prozess-, produkt- oder ausrüstungsbezogener Flexibilität und können auf zwei Arten in die Prozesse eingebracht werden. Einerseits kann eine bauteilnahe Integration der Aktoren im Werkzeugraum erfolgen [Cao19; Ble23], sodass Unsicherheit im Übertragungsverhalten zwischen Aktor und Bauteil aufgrund der räumlichen Nähe minimiert wird. Andererseits ist die Nutzung von maschinenintegrierter Aktorik ein probates Mittel, die multiplen Freiheitsgrade flexibler Umformmaschinen für Bauteilregelungen zu nutzen. [E1]

Unterschiede hinsichtlich der Positionierung verwendeter Aktoren (maschinen-

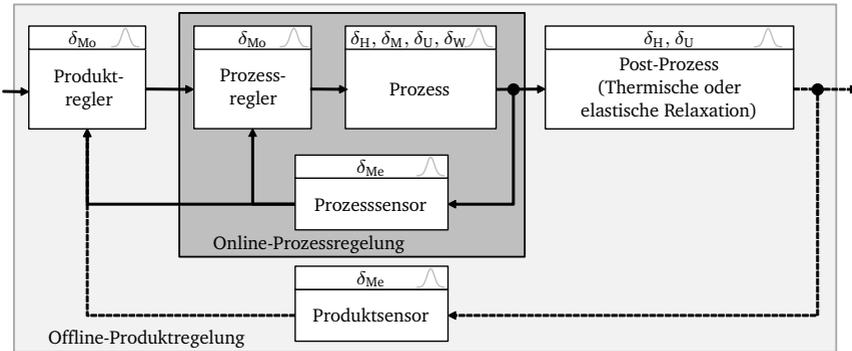


Abbildung 2.7.: Kaskadiertes Blockschaftbild zur Regelung von Bauteileigenschaften in der Metallumformung in Anlehnung an [All16] und Kennzeichnung auftretender Unsicherheitsquellen  $\delta_i$

vs. werkzeugintegriert), der Art der verwendeten Modelle (White-Box-Modell vs. Black-Box-Modell) und des verwendeten Reglers (Offline-Produktregler vs. Online-Prozessregler) können durch einen Vergleich zweier Publikationen ([DZH19] vs. [E1]) zur Regelung von Tiefziehprozessen diskutiert werden. Beide Veröffentlichungen nutzen den Umstand, dass der Kraftangriffspunkt (KAP) in Blechebene, der durch die Summe der zwischen Niederhalter und Bauteilflansch wirkenden Kräfte determiniert wird, stark mit resultierenden Fehlerbildern wie Falten- und Rissbildung korreliert. Eine qualitätsgerechte Produktion von rotationssymmetrischen Tiefziehbauteilen wird ermöglicht, wenn die auf das Blech wirkende Kraft möglichst im Mittelpunkt des Bauteils gehalten wird. Abbildung 2.8 stellt die in den Publikationen verwendeten Werkzeuge schematisch per Draufsicht dar und visualisiert vereinfachte Blockschaftbilder, aus denen die Unterschiede zwischen beiden Regelkonzepten ersichtlich werden. In der Offline-Regelung von Drossel et al. [DZH19] werden aktorisierte Aktivelemente (rot gekennzeichnet) zwischen Stößel und Niederhalter angebracht, deren Positionen  $d_i$  den zeitlichen Verlauf der über ein modulares Messsystem mit 24 Dehnungsmessstreifen sensierten Kräfte  $F(t)$  determinieren. Aus dem zeitlichen Verlauf der Kräfte wird nach dem Prozess der Mittelwert des KAP  $\bar{x}_{KP}$  in x- und y-Richtung der letzten 5 mm Hub berechnet, wobei der Index für das  $i$ -te Bauteil steht. Um einen funktionalen Zusammenhang zwischen dem Mittelwert des KAP  $\bar{x}_{KP}$  und den Positionen der Aktivelemente  $d_j$  herzustellen,

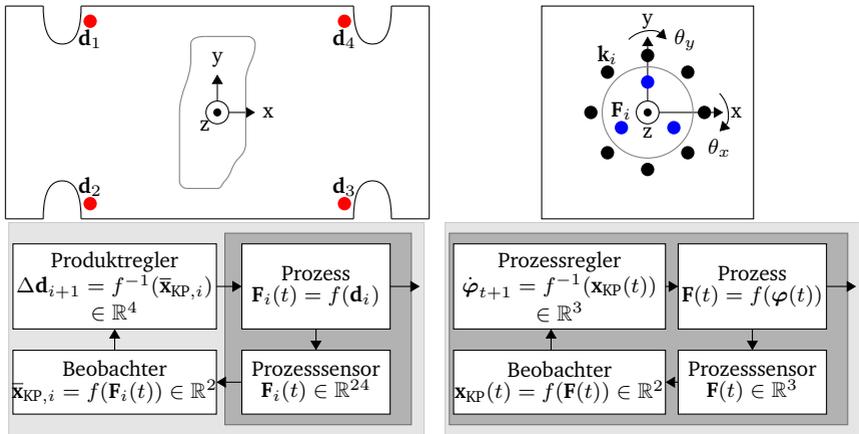


Abbildung 2.8.: Vergleich der Offline-Regelung nach [DZH19] (links) und Online-Regelung nach [E1] (rechts) mit schematischer Draufsicht auf die Werkzeuge (oben) und Blockschaltbild der Regelung (unten)

wird eine regressive Polynomfunktion entwickelt, deren linearisierte Inverse anschließend im Produktregler als Modell genutzt wird. So können über außermittige Abweichungen des KAP des  $i$ -ten Bauteils die Positionen der Aktivelemente  $\mathbf{d}_{i+1}$  des  $i + 1$ -ten Bauteils derart angepasst werden, dass mit einem zentraleren Verlauf des KAP im nächsten Hub zu rechnen ist. Nachteilig bei dieser Art der Offline-Regelung ist, dass während des Prozesses auftretende Abweichungen erst im nächsten Hub kompensiert werden können, die Entwicklung des datengetriebenen Modells die Durchführung von (zahlreichen) Vorversuchen erfordert und nach jedem Hub die Positionen der Aktivelemente adaptiert werden müssen, weshalb ein aktiver Eingriff in den Versuchsaufbau unabdingbar ist.

Groche et al. regeln dagegen den KAP echtzeitlich im Prozess. Dabei nutzen sie mit der 3DSP eine Maschine mit drei Stößelfreiheitsgraden, deren Kippwinkel  $\theta_x$  und  $\theta_y$  direkten Einfluss auf den KAP haben. Dies wird über eine konzentrische Anordnung der  $45^\circ$  zueinander versetzt angeordneten und im Tiefziehwerkzeug verbauten Federn mit Federsteifigkeiten  $k_i$  (siehe Abbildung 2.8, schwarz gekennzeichnet) realisiert, deren Stauchung bzw. Streckung die auf das Blech wirkende Niederhalterkraft beeinflusst. Verkippt der Stößel beispielsweise positiv um die  $y$ -Achse, werden die in Abbildung 2.8 rechts dargestellten Federn stärker gestaucht und der KAP

---

verlagert sich auf die entsprechende Seite. Dabei werden während des Prozesses drei im Werkzeug verbaute, ebenfalls konzentrisch angeordnete Kraftmessringe (siehe Abbildung 2.8, blau gekennzeichnet) genutzt, mithilfe derer über einen Prozessbeobachter der KAP  $x_{KP}(t)$  in Blechebene berechnet wird. Im Prozessregler wird eine Kombination eines kinematischen Pressen- und statischen Werkzeugmodells genutzt, um Geschwindigkeitsstellgrößen  $\dot{\varphi}$  für die servobetriebenen Maschinenantriebe zu berechnen. Das genutzte Modell wird dabei sowohl differenziert, invertiert und aufgrund von Nichtlinearitäten im entsprechenden Arbeitspunkt linearisiert. Die aufgezeigte Regelstrategie erlaubt es, auf vor dem Prozess unbekannte Störgrößen wie etwa Federermüdungen echtzeitlich zu reagieren, wodurch genannte Nachteile der vorgestellten Offline-Regelung umgangen werden. Ein tabellarischer Vergleich mit den wichtigsten Kenngrößen beider Regelstrategien ist in Tabelle 2.1 zu finden. In der umformtechnischen Forschung dominieren aktuell Offline-Regelungen, in denen basierend auf den Produkteigenschaften oder Prozessgrößenverläufen des vorgelagerten Bauteils modifizierte Stellgrößen für das nächste Bauteil abgeleitet werden. Beispiele dafür finden sich beim Biegen [Gro16; Gro15; Hav18], Tiefziehen [DZH19; End17; Hei18; BLC20], SPIF [Lu16; Lu17; Fio14; Fio15; HHG17; Thi21], Innenhochdruckumformen [End22] und Rohrbiegen [SGB21]. Ansätze zur Online-Regelung bestehen in einem wanddickengeregelten Drückwalzprozess [Ker22; Ker23] und dem vorab vorgestellten KAP-geregelten Tiefziehprozess [E1]. Simulative Ansätze, in denen rechenintensive Modelle zum Einsatz kommen können, da Prozesse nicht echtzeitlich ablaufen, realisieren Online-Regelungen am Beispiel eines härtegeregelten Ringwalzprozesses [Laf21]. Im DFG-Schwerpunktprogramm 2183 *Eigenschaftsgeregelte Umformprozesse* werden derzeit Konzepte und Strategien beforscht, die echtzeitliche Regelungen heterogener Bauteileigenschaften ermöglichen sollen. Dabei werden derzeit Fragen hinsichtlich des optimalen Zusammenspiels von Modellen und Sensoren in Form von Softsensoren [Klo21; Hom23], optimalen Sensorarten [Müh21] und deren lokaler Messgrößenaufnahme [RHB23] adressiert und kombiniert. Aus den Arbeiten gehen theoretische Ansätze zur Online-Regelung von Bauteileigenschaften hervor, die beispielsweise invers-differentielle, datengetriebene Modelle zur Regelung der Kragenhöhe und Bauteilhärte beim Stanzlochwalzen vorschlagen [E17].

	Regelung nach [DZH19]	Regelung nach [E1]
Aktoren	Abstandselemente an Positionen $\mathbf{d}_j$ zwischen Oberwerkzeug und Niederhalter	Exzentrische Servoantriebe $\varphi$ der 3DSP
Sensoren	Modulares Messsystem mit 24 Dehnungsmessstreifen zwischen Stößel und Oberwerkzeug	Drei Kraftmessringe im Oberwerkzeug
Freiheitsgrade Presse	1: Vertikale Translation	3: Vertikale Translation und Stößelkipfung $\theta_x$ und $\theta_y$ um zwei Achsen
Stellgröße	Umpositionierung der Abstandselemente $\Delta \mathbf{d} \in \mathbb{R}^4$	Geschwindigkeiten der Servoantriebe $\dot{\varphi} \in \mathbb{R}^3$
Messgröße	Zeitlicher Verlauf der Kräfte in modularem Messsystem $\mathbf{F}(t) \in \mathbb{R}^{24}$	Zeitlicher Verlauf der Kräfte in Oberwerkzeug $\mathbf{F}(t) \in \mathbb{R}^3$
Prozessbeobachter	Berechnung KAP in Blechebene $\mathbf{x}_{\text{KP}}(t) \in \mathbb{R}^2$ und Mittelwertbildung $\bar{\mathbf{x}}_{\text{KP}} \in \mathbb{R}^2$ für letzte 5 mm Hub	Berechnung KAP in Blechebene $\mathbf{x}_{\text{KP}}(t) \in \mathbb{R}^2$ über Beobachtermodell
Reglertyp Modellart	Offline-Regler Black-Box-Modell	Online-Regler White-Box-Modell
Modellbeschreibung	Polynomial gefittetes, inverses Regressionsmodell, linearisiert im Arbeitspunkt	Inverses, differentielles Modell der Pressenkinematik und Werkzeugstatik, linearisiert im Arbeitspunkt
Regleraufgabe Reglerzyklus	$\Delta \bar{\mathbf{x}}_{\text{KP},i} \rightarrow \Delta \mathbf{d}_{i+1}$ Hub-zu-Hub	$\mathbf{x}_{\text{KP}}(t) \rightarrow \dot{\varphi}_{t+1}$ 10 ms

Tabelle 2.1.: Vergleich von KAP-Regelungen in Tiefziehprozessen zwischen [DZH19] und [E1]

## 2.2.4. Selbstoptimierende Werkzeugmaschinen

Der Ansatz selbstoptimierender Werkzeugmaschinen stammt aus der spanenden Fertigung und wurde von Möhring et al. in einem Keynote-Paper diskutiert. [Möh20] Im Vergleich zu den im vorangegangenen Unterkapitel vorgestellten Bauteileigenschaftsregelkreisen wird im Ansatz selbstoptimierender Werkzeugmaschinen ein stärkerer Fokus auf das Zusammenwirken von Bauteilen und Maschinen gelegt. Über-

geordnetes Ziel selbstoptimierender Maschinen ist eine autonome Anpassung des eigenen Verhaltens unter Optimierung multipler Kriterien. Mögliche Optimierungskriterien adressieren Bauteilqualität, Produktivität, Produktionskosten, Energie- und Ressourceneffizienz. [Möh20] Abbildung 2.9 gibt einen Überblick über das Sys-

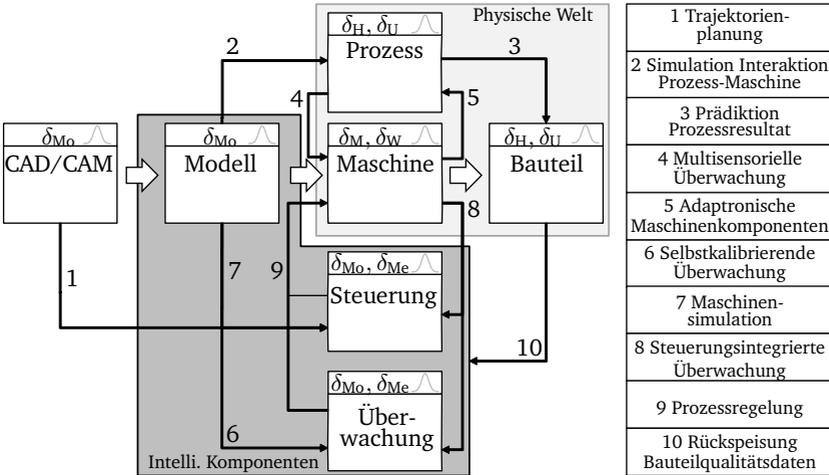


Abbildung 2.9.: Übersicht zu Bestandteilen selbstoptimierender Maschinen in Anlehnung an [Möh20] mit Unsicherheitsquellen  $\delta_i$

tem einer selbstoptimierenden Werkzeugmaschine, dazugehörige Bestandteile und bestandteilübergreifende Funktionen. Wie im Schaubild des vorangegangenen Unterkapitels sind einwirkende Unsicherheitsquellen  $\delta_i$  den Bestandteilen zugeordnet. Die Implementierung neuer Prozesse auf selbstoptimierenden Werkzeugmaschinen beginnt mit der Festlegung von Prozesskinematiken, Bewegungsverläufen der Maschine und Werkzeug und prozessbezogenen Zuständen. Moderne Computer Aided Design (CAD) und Computer Aided Manufacturing (CAM) Software steht Anwendern in der Regel zur Verfügung. Die Optimierung entsprechend ausgewählter Parameter erfolgt anhand von Prozess- und Maschinsimulationen, bevor modifizierte Parameter im realen Prozess erprobt werden. Dabei wird die Interaktion von Maschine und Prozess durch die Steuereinheit der Maschine sichergestellt und durch eine steuerintegrierte oder externe Überwachungseinheit überwacht. Resultat der Prozess-Maschinen-Interaktion ist ein Bauteil mit entsprechenden Bauteileigenschaften, dessen Qualitätsdaten nach dem Prozess oder gar echtzeitlich gemessen

---

und den intelligenten Komponenten des Systems (Modelle, Steuerung, Überwachungseinheit) rückgemeldet werden. Diese können daraufhin deren Parameter modifizieren, sodass eine qualitätsgerechte Produktion fortlaufend sichergestellt wird. [Möh20]

Auch wenn einzelne Bestandteile des Konzeptes selbstoptimierender Werkzeugmaschinen bereits seit Jahren Gegenstand intensiver Forschungsbemühungen sind und erprobte Ansätze existieren, die multisensorielle Überwachungssysteme, adaptive Prozessregelungen basierend auf Bauteilqualitätsdaten und Modelle bzw. Simulationen unter Berücksichtigung der Interaktion von Maschine und Prozess realisieren, werden die Potenziale selbstoptimierender Werkzeugmaschinen bislang nicht vollständig ausgeschöpft. Implementierungsbarrieren stellen derzeit mangelnde Datenzugänglichkeiten, Kompatibilitäten und Kommunikationsfähigkeiten zwischen Maschinensteuerungen, (Simulations-)Modellen und adaptronischen Komponenten dar [Möh20], die in Zukunft durch die Bereitstellung innovativer Automatisierungslösungen mit hohen Rechenkapazitäten und geeigneten Serverstrukturen [Krü17] als auch die fortschreitende Entwicklung digitaler Zwillinge [Tao18] behoben werden können.

## 2.3. Überführung von Qualitätsdaten in Antriebsgrößen

Im vorangegangenen Unterkapitel wurde dargelegt, dass Umformprozesse vom Einsatz flexibler Umformmaschinen profitieren können, indem zusätzliche Maschinenfreiheitsgrade zur Manipulation unsicherheitsbehafteter Umformprozesse und Bauteileigenschaften genutzt werden. Mit der Regelung von Bauteileigenschaften [All16] und selbstoptimierenden Werkzeugmaschinen [Möh20] werden in der akademischen Forschung zwei Konzepte vorgestellt, in denen die Rückspeisung von Qualitätsdaten in die Maschinensteuerung zentral für die Herbeiführung gewünschter Bauteileigenschaften ist. Dabei stellt sich die zentrale Fragestellung, wie aus gemessenen Qualitätsdaten der Bauteile optimale Antriebsverläufe von Werkzeugmaschinen identifiziert werden können. Abbildung 2.10 stellt ein schematisches Vorgehen zur Ermittlung von optimalen Antriebsverläufen dar. Während die Beziehungen von vorgegebenen Antriebsverläufen  $\mathbf{q}(t)$  und resultierenden Qualitätsdaten beobachtbar sind, da diese nach Prozessablauf gemessen werden können, ist eine

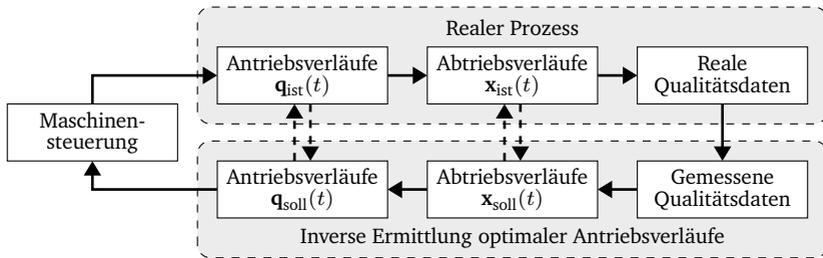


Abbildung 2.10.: Vorgehen zur inversen Ermittlung optimaler Antriebsverläufe aus gemessenen Qualitätsdaten

inverse Betrachtung der Wirkungszusammenhänge erheblich komplexer. Grund dafür sind in der Regel mangelnde Kenntnisse über Sensitivitäten und Nichtlinearitäten der Auswirkungen modifizierter Antriebsverläufe auf Bauteileigenschaften. Gleichzeitig ist sicherzustellen, dass Modifikationen von Antriebsverläufen jene Abtriebsverläufe erzeugen, die zu einer zielgerichteten Beeinflussung von Bauteileigenschaften führen. Demzufolge stellt die Manipulierbarkeit von Bauteileigenschaften eine Grundvoraussetzung für eigenschaftsgerichtete Prozesse dar. In der Fachliteratur werden Modelle genutzt, um Zusammenhänge zwischen Bauteileigenschaften und Antriebsverläufen offenzulegen, wobei Abtriebsverläufe  $\mathbf{x}(t)$  der Maschinen als Bindeglied zwischen Antrieben und Bauteileigenschaften dienen. Eine Übersetzung von Qualitätsdaten in Abtriebsverläufe bietet den Vorteil der entkoppelten Betrachtung der Werkzeug-Prozess-Interaktion, wodurch mögliche Nichtlinearitäten aus dem Übertragungsverhalten der Maschinenkinematik im ersten Schritt unberücksichtigt bleiben. Nach der Identifikation gewünschter Abtriebsverläufe erfolgt anschließend eine Transformation in Antriebskoordinaten  $\mathbf{q}(t)$ , die üblicherweise über inverse kinematische Maschinenmodelle erfolgt. In den folgenden beiden Unterkapiteln werden daher ausgewählte Methoden und Ansätze aus der Literatur vorgestellt, mithilfe derer aus Qualitätsdaten von Bauteilen Abtriebs- bzw. Antriebsverläufe ermittelbar sind.

---

### 2.3.1. Qualitätsdaten in Abtriebsgrößen

Die Ableitung von Abtriebsgrößen aus sensorisch erfassten Qualitätsdaten produzierter Bauteile birgt in umformtechnischen Anwendungen erhebliche Komplexität, da Effekte wie etwa thermische oder elastische Relaxation starke Nichtlinearitäten aufweisen, die bei der Modifizierung von Werkzeugpfaden berücksichtigt werden müssen. Anwendungen aus Biegeprozessen regeln die Rückfederung von Biegeteilen durch eine vertikale Zustellung des Stempels, wobei Hubhöhen über linearisierte White-Box-Modelle [Gro16] oder datengetriebene Black-Box-Modelle [Gro15; Hav18] ermittelbar sind.

Anspruchsvoller ist die Planung der Abtriebsverläufe bei inkrementellen Umformprozessen, da die Bauteilgeometrie vom zeitlichen Verlauf des mehrdimensionalen Werkzeugpfades und nicht länger von der eindimensionalen Stempelzustellung abhängt. Ein besonders häufig untersuchter inkrementeller Umformprozess ist das SPIF, bei dem die Werkzeugspitze das eingespannte Blech lokal kontaktiert und das Blech durch Abfahren eines dreidimensionalen Werkzeugpfades umformt. Der Prozess erlaubt die Fertigung beliebiger Geometrien, die lediglich von der Umformbarkeit des Halbzeuges und dem Arbeitsraum der Maschine begrenzt werden. Eine zentrale Herausforderung bei der Planung des Werkzeugpfades ist die Berücksichtigung von Rückfederungen, die nach Entnahme des Bauteils aus der Einspannvorrichtung auftreten [Jes05]. Neben Untersuchungen hinsichtlich grundsätzlicher Strategien zur Generierung von Werkzeugpfaden [Rau09; Lu13] sind in den vergangenen Jahren zahlreiche Publikationen veröffentlicht worden, die resultierende Bauteilgeometrien von SPIF-Bauteilen messen und Abweichungen zur Modifikation des Werkzeugpfades nutzen. Belchior et al. messen den im Prozess abgefahrenen Werkzeugpfad und kompensieren maschinenseitige Unsicherheit in Form von Steifigkeitseinflüssen durch eine aufwändige Steifigkeitsmodellierung des genutzten 6-Achs-Roboters. Maximale Geometrieabweichungen des Bauteils können durch die gewählte Kompensationsstrategie von 3,5 mm auf 1 mm reduziert werden. [Bel13] Lu et al. nutzen modellprädiktive Regelungsansätze, um den Werkzeugpfad basierend auf optischen 3D-Messdaten zu optimieren. Dazu scannen sie nach jedem inkrementellen Umformschritt die Bauteilgeometrie und nutzen ein Modell, das unter Einspeisung von Trajektorienparametern des Werkzeugpfades die resultierende Bauteilgeometrie prädiziert. Als Stellgrößen wählen sie einerseits die vertikale [Lu16] und in einer

---

darauf aufbauenden Publikation zusätzlich die horizontale Zustellung [Lu17], deren optimale Werte durch Formulierung und Optimierung einer modellbasierten Kostenfunktion gefunden werden.

Ansätze, die eine modellfreie<sup>4</sup> Regelung von Umformprozessen basierend auf RL realisieren, optimieren, wie bereits in Kapitel 2.2.1 beschrieben, die Niederhalterkraft in diskreten Zeitschritten beim Tiefziehen. [DLG20] In einem Freiformschmiedeprozess stellen Reinisch et al. unter Beweis, dass RL einen effektiven Ansatz darstellen, die Steuerparameter einzelner Stufen zu erlernen, die sowohl zu hohen Bauteilmaßhaltigkeiten als auch möglichst geringer Anzahl an durchzuführenden Prozessschritten führen. Als Aktionen wählt der genutzte Agent die in das Bauteil eingreifende Sattellänge (normalisiert auf die Ausgangshöhe des Bauteils) und die prozentuale Höhenreduktion in jedem Eingriff und wird nach Herstellung eines Bauteils für niedrige Geometrieabweichungen und hohe Ausnutzung der verfügbaren Presskraft belohnt. Die Autoren stellen unter Beweis, dass RL genannte Abtriebsgrößen in dem mehrstufigen Prozess erlernen können und damit das Potenzial bieten, optimale Prozessrouten unter Zuhilfenahme multikriterieller Belohnungsfunktionen zu identifizieren. [Rei21] Deng et al. vergleichen die Performanz von RL und konventionellen PI-Reglern zur Regelung der Blechdicke beim Blechbandwalzen. Als Aktionen bzw. Abtriebsgrößen werden dabei Kräfte und Verkippungen der Walzen definiert, über die Einfluss auf Blechdickengradienten in Längs- als auch Querrichtung genommen werden kann. Anhand simulativer Untersuchungen zeigen die Autoren, dass die Prozessfähigkeitsindizes  $C_p$  und  $C_{pk}$  durch den Einsatz RL signifikant gesteigert und Blechdickenschwankungen massiv reduziert werden. [Den22]

### 2.3.2. Abtriebsgrößen in Antriebsgrößen

Sind Abtriebsgrößen und deren zeitliche Verläufe bekannt, erfolgt zwangsläufig eine Transformation in Antriebskoordinaten. Bewegungen linear übersetzender Werkzeugmaschinen, zu denen ein Großteil der in der spanenden Fertigung eingesetzten Fräsmaschinen gehört, zeichnen sich durch lineare Positions- und Geschwindigkeitsübersetzungen aus. So sehen Kinematiken solcher Werkzeugmaschinen jeweils

---

<sup>4</sup>Unter modellfreiem Lernen werden entgegen der in Kapitel 2.2.1 vorgestellten Nomenklatur auf dem Forschungsgebiet des RL Algorithmen subsumiert, die ihre Vorschriften zu Aktionswahlen ausschließlich erlernen und dabei auf keine Modelle zurückgreifen, die physikalische Prozesszusammenhänge beschreiben.

einen Antrieb zur Manipulation eines Abtriebsfreiheitsgrades vor, wodurch Positions- und Geschwindigkeitstransformationen von Abtrieb auf Antrieb von begrenzter Komplexität sind. Nichtlinear-übersetzende Werkzeugmaschinen bedürfen einer modellbasierten Beschreibung, wobei Positionstransformationen von Abtriebsfreiheitsgraden in Antriebspositionen über Inverse Kinematik (IK)- oder entsprechende Geschwindigkeitstransformationen über inverse differentielle Kinematikmodelle realisierbar sind. Umfassende Forschungsbemühungen wurden mit der Entwicklung und rasanten Verbreitung von Industrierobotern betrieben, die das Ziel verfolgen, Posen der Endeffektoren von Manipulatoren hochgenau zu manipulieren. [Ver19] Abbildung 2.11 stellt die zwei wichtigsten Vertreter von Regelungsarten in der Robotik dar, die ebenfalls auf nichtlinear-übersetzende Werkzeugmaschinen anwendbar sind. Grundlegend für deren Anwendung ist die Verfügbarkeit kinematischer Modelle der Form

$$\mathbf{x} = \mathbf{f}_{\text{kin}}(\mathbf{q}), \quad (2.6)$$

die eine modellbasierte Beschreibung der Abtriebsgrößen  $\mathbf{x}$  bei Kenntnis der Antriebsgrößen  $\mathbf{q}$  zulassen. Um gewünschte Abtriebsverläufe  $\mathbf{x}_{\text{soll}}(t)$  herbeizuführen, werden diese bei einer Regelung im Gelenkraum über die IK-Transformation

$$\mathbf{q}_{\text{soll}}(t) = \mathbf{f}_{\text{kin}}^{-1}(\mathbf{x}_{\text{soll}}(t)) \quad (2.7)$$

in Soll-Größen für die Gelenke bzw. Antriebe transformiert. Anschließend wird der zeitliche Verlauf der Antriebe geregelt, wobei einwirkende Unsicherheit zwischen An- und Abtrieb in Form von Elastizitäten, Modellfehlern oder Lagerspiel unberücksichtigt bleibt. Im Gegensatz dazu werden die Abtriebsgrößen bei einer Regelung im Arbeitsraum direkt geregelt, weswegen eine dem Regelkreis vorgeschaltete inverse Transformation entfällt. Eine Kompensation der genannten, auf die kinematische Kette einwirkenden Unsicherheitsquellen wird durch eine Messung und Rückführung der Abtriebsgrößen realisiert. Dabei ist es nun Aufgabe des Reglers die inverse Transformation der Abtriebsgrößen in den Antriebsraum zu übernehmen. Wählt man als Stellgröße die Antriebspositionen, kann der Regler auf die IK-Funktion aus Gleichung 2.7 zurückgreifen. Üblicherweise werden als Stellgrößen Geschwindigkeiten der Antriebe gewählt, die bei servobetriebenen Werkzeugmaschinen direkt in den antriebsinternen Geschwindigkeitsregelkreis gespeist werden können. Dies

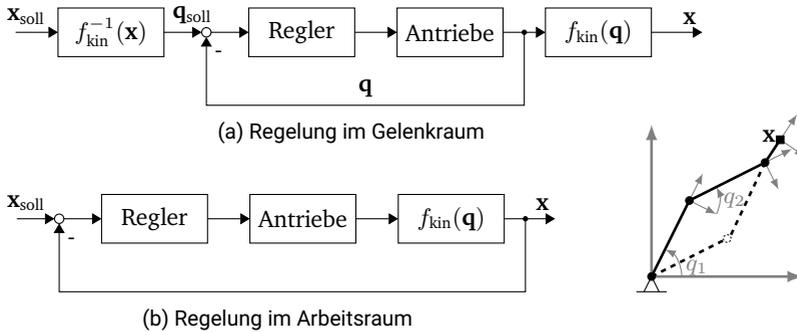


Abbildung 2.11.: Regelungsarten nichtlinear-übersetzender Werkzeugmaschinen

erfordert die Berechnung der differentiellen Kinematik

$$\dot{\mathbf{x}} = \frac{d\mathbf{f}_{\text{kin}}(\mathbf{q})}{dt} = \frac{d\mathbf{f}_{\text{kin}}(\mathbf{q})}{d\mathbf{q}} \cdot \dot{\mathbf{q}} = \mathbf{J}(\mathbf{q}) \cdot \dot{\mathbf{q}} \quad (2.8)$$

und eine anschließende Invertierung der hervorgehenden Jakobimatrix  $\mathbf{J}(\mathbf{q})$ . Bei Wahl eines P-Reglers führt dies auf die Geschwindigkeitsstellgrößen

$$\dot{\mathbf{q}}_{\text{soll}} = \mathbf{J}^{-1}(\mathbf{q}) \cdot \mathbf{K}_P \cdot (\mathbf{x}_{\text{soll}} - \mathbf{x}), \quad (2.9)$$

wobei  $\mathbf{K}_P$  eine proportionale Verstärkungsmatrix darstellt, deren Hauptdiagonalelemente  $\mathbf{K}_{P,ii}$  die Regelabweichungen des  $i$ -ten Abtriebfreiheitsgrades verstärken. Dabei können Gain Scheduling (GS)-Techniken die Werte der Verstärkungsmatrix an den linearisierten Arbeitspunkt nichtlinear-übersetzender Werkzeugmaschinen anpassen, wodurch die Performanz von Positionsregelungen erheblich gesteigert werden kann. [JA99]

Besondere Herausforderungen stellen singuläre Konfigurationen dar, in denen die Manipulierbarkeit mindestens eines Abtriebfreiheitsgrades verloren geht und das Manipulierbarkeitsmaß nach [Yos85]

$$m_{\text{Man}}(\mathbf{q}) = \sqrt{\det(\mathbf{J}(\mathbf{q}) \cdot \mathbf{J}^T(\mathbf{q}))} \quad (2.10)$$

Nullwerte annimmt. Das Auftreten kinematischer Singularitäten sei im Folgenden am Beispiel konventioneller Getriebearten mechanischer Pressen erläutert. Abbildung

2.12 stellt sowohl die typische Kinematik einer Kurbel- als auch Kniehebelpresse dar. Als Antriebsgröße wird der Antriebswinkel  $\varphi$  eingeführt, der die vertikale Position des Stoßeldruckpunktes  $x = f_{\text{kin}}(\varphi)$  bestimmt. Beim Kurbelantrieb liegen die Totpunkte, die bei umlaufender Rotation des Antriebswinkels durch eine Geschwindigkeitsumkehr des Stoßeldruckpunktes gekennzeichnet sind, bei  $\varphi_{\text{UT}}^{(\text{KU})} = 90^\circ$  und  $\varphi_{\text{OT}}^{(\text{KU})} = 270^\circ$ . Totpunkte der Kniehebelpresse liegen bei einer Streckung des Kniehe-

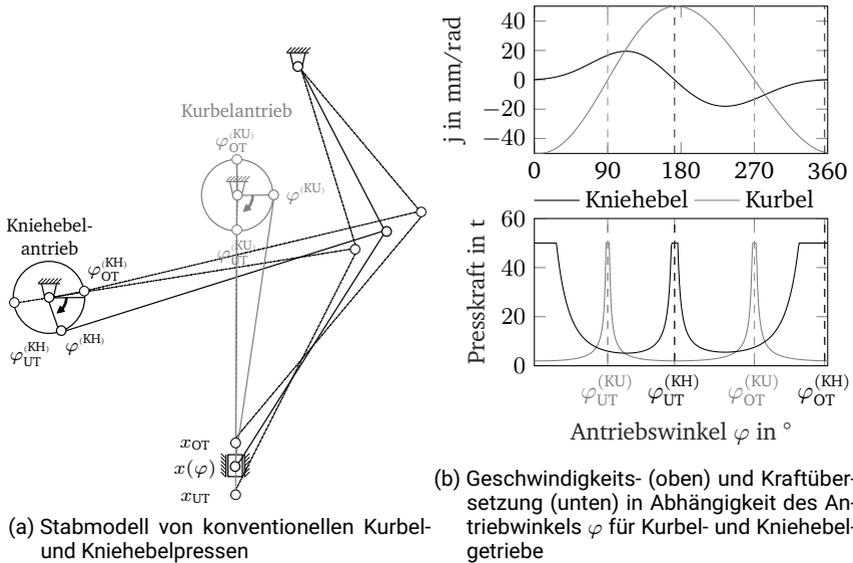


Abbildung 2.12.: Vergleich zwischen Kurbel- und Kniehebelkinematik bei mechanischen Pressen in Anlehnung an [Lan85]

bels (Stellungen in Abbildung 2.12(a) gestrichelt eingezeichnet) bei  $\varphi_{\text{OT}}^{(\text{KH})} \approx 172^\circ$  und  $\varphi_{\text{UT}}^{(\text{KH})} \approx 356^\circ$  vor. Abbildung 2.12(b) stellt die Verläufe der Geschwindigkeitsübersetzung  $j(\varphi)$  und verfügbare Presskraft am Stoßeldruckpunkt  $F(\varphi)$  für beide Getriebearten gegenüber. Dabei ist die Geschwindigkeitsübersetzung nach Gleichung 2.8 über  $\dot{x} = j(\varphi) \cdot \dot{\varphi}$  und die Presskraft über Prinzipien der kinetostatischen Dualität [Chi91] durch

$$F(\varphi) = j^{-1}(\varphi) \cdot M_\varphi \quad (2.11)$$

berechenbar, wobei  $M_\varphi$  das am Antrieb verfügbare Nenndrehmoment respektive für kurze Zeiträume Spitzendrehmoment darstellt. Theoretisch können durch die Invertierung der in den Totpunkten singulären Geschwindigkeitsübersetzung unendlich hohe Kräfte übertragen werden, was jedoch aufgrund Versagensrisiken mechanischer Getriebeglieder nicht realisierbar ist. Die Substitutionalität von Geschwindigkeitsübersetzung  $j(\varphi)$  und verfügbarer Presskraft  $F(\varphi)$  zeigt klar den Zielkonflikt auf, dem nichtlinear-übersetzende Pressen bei einer Regelung der Stoßeldruckpunkte oder Stoßelpose im Arbeitsraum unterlegen sind. Einerseits ist eine hohe Manipulierbarkeit und damit die Möglichkeit, auftretende Regelabweichungen durch möglichst kurze Antriebsstellwege zu eliminieren, wünschenswert, andererseits ist das Aufbringen hoher Kräfte und damit die Durchführung von kraftintensiven Prozessen bei vertretbarer Energieeinspeisung ausschließlich in unmittelbarer Nähe zu den Totpunkten möglich. Erste Ansätze zur Regelung von Servopressen im Arbeitsraum sperren die Totpunkte [HPG19], wodurch die übertragbaren Presskräfte erheblich eingeschränkt werden. Aus diesem Grund beschäftigen sich darauf aufbauende Untersuchungen mit der Nutzung singularitätsrobuster Jakobimatrizen im Reglerübertragungsverhalten. Anstatt der inversen Jakobimatrix nutzt Hoppe [Hop21] eine gedämpfte inverse Jakobimatrix (engl.: damped least-squares (DLS))

$$\mathbf{J}^+(\mathbf{q}) = \frac{\mathbf{J}^T(\mathbf{q})}{\mathbf{J}^T(\mathbf{q}) \cdot \mathbf{J}(\mathbf{q}) + \lambda^2 \cdot \mathbf{I}}, \quad (2.12)$$

nach [NH86] im Reglerübertragungsverhalten zur Ableitung von Geschwindigkeitsstellgrößen für die Antriebe einer 3DSP. Diese strebt in singulären Konfigurationen im Gegensatz zur inversen Jakobimatrix nicht gegen unendlich, sondern wird durch den Dämpfungsfaktor  $\lambda$  regularisiert. Für die in Abbildung 2.12 dargestellten Kinematiken ergibt sich analog dazu die DLS-Inverse  $j(\varphi)^\dagger = j(\varphi) \cdot (j^2(\varphi) + \lambda)^{-1}$ , für die bei  $\lambda > 0$  in Totpunktstellungen  $\lim_{j(\varphi) \rightarrow 0} j^+(\varphi) = 0$  gilt. Eine Substitution der inversen Jakobimatrix mit der DLS-Inversen in Gleichung 2.9 umgeht somit das Problem, dass der Regler in singulären Konfigurationen unendlich hohe Stellgrößen ausgibt. Die Nutzung der DLS-Inversen birgt wiederum das Problem, dass die ausgegebenen Stellgrößen in singulären Konfigurationen Nullwerte annehmen und die vorgestellten Pressen somit in den Totpunkten zum Stillstand kommen, was durch eine Vorsteuerung der Antriebe kompensierbar ist. [Hop21]

Weitere Herausforderungen entstehen bei der Regelung redundanter Werkzeugma-

schinen im Arbeitsraum. Unter redundanten Manipulatoren werden überaktuierte Maschinen mit Antrieben  $\mathbf{q} \in \mathbb{R}^n$  und Abtriebfreiheitsgraden  $\mathbf{x} \in \mathbb{R}^m$  verstanden, wobei  $m < n$  gilt. Redundanzen äußern sich in einer Unbestimmtheit der IK nach Gleichung 2.7, da keine eindeutige Lösung vorliegt und multiple Antriebsstellungen auf die gleiche Abtriebsstellung führen. [Sic90] Auch eine Ableitung von Geschwindigkeitsstellgrößen nach Gleichung 2.9 ist nicht möglich, da die Jakobimatrix  $\mathbf{J}(\mathbf{q}) \in \mathbb{R}^{m \times n}$  nicht-quadratisch und damit eine direkte Invertierung nicht möglich ist. Ein Ansatz zur Lösung dieses Problems liegt in der Nutzung der Moore-Penrose-Pseudoinversen

$$\mathbf{J}^\dagger(\mathbf{q}) = \frac{\mathbf{J}^T(\mathbf{q})}{\mathbf{J}^T(\mathbf{q}) \cdot \mathbf{J}(\mathbf{q})} \quad (2.13)$$

nach [Whi69], deren Vorteil die Bereitstellung minimaler genormter Antriebsgeschwindigkeiten ist. Wird davon ausgegangen, dass die in Abbildung 2.12(a) dargestellte Kniehebelkinematik überaktuiert ist und demnach der als Festlager eingezeichnete Rotationspunkt des Kniehebels translatorische Freiheitsgrade besitzt, ist eine Bereitstellung minimaler Antriebsgeschwindigkeiten jedoch nicht zweckmäßig, um den beschriebenen Zielkonflikt zwischen höchstmöglicher Manipulierbarkeit und Kraftübertragung zu lösen. Vielmehr bedarf es einer Verstellung des Rotationspunktes in Abhängigkeit der zum jeweiligen Zeitpunkt bereitzustellenden Presskraft am Stoßeldruckpunkt. Dies gelingt, indem die überaktuierten Freiheitsgrade von der eigentlichen Positionsregelaufgabe entkoppelt und zusätzliche Regelgrößen oder Nebenbedingungen in die Regelung aufgenommen werden, was bei redundanten Manipulatoren zur Kollisionsvermeidung [MK85], Minimierung mechanischer Lasten [Lie77] oder Maximierung der Energieeffizienz [VK84] genutzt werden kann. Hoppe nutzt die redundante Maschinentopologie der 3DSP mit  $\mathbf{q} \in \mathbb{R}^5$  und  $\mathbf{x} \in \mathbb{R}^3$  zur zusätzlichen Regelung der beiden Totpunkte, wobei die Regelaufgaben der exzentrischen Servoantriebe und jene der Spindelantriebe entkoppelt werden. Dabei werden die Totpunkte so eingestellt, dass diese sich äquidistant um die vertikale Position des Stoßels anordnen, wodurch gemäß Abbildung 2.12(b) die Manipulierbarkeit maximiert, jedoch die verfügbare Presskraft minimiert wird. [Hop21]

Von einer modellbasierten Beschreibung weiterer kinematischer und kinetischer Maschinenzustände oder deren direkter Messung können Regelungen ebenfalls profitieren. In [ES2] und [E2] werden analytische Funktionen des Rucks im Antriebsstrang

von Werkzeugmaschinen durch dreifache Differenzierung der Vorwärtskinematik aus Gleichung 2.6 berechnet, die auf

$$\ddot{\mathbf{x}} = \frac{\partial^2 \mathbf{J}(\mathbf{q})}{\partial \mathbf{q}^2} \otimes \dot{\mathbf{q}}^3 + 3 \frac{\partial \mathbf{J}(\mathbf{q})}{\partial \mathbf{q}} \otimes \dot{\mathbf{q}} \cdot \ddot{\mathbf{q}} + \mathbf{J}(\mathbf{q}) \cdot \ddot{\mathbf{q}} \quad (2.14)$$

führen. Eine modellbasierte Berechnung der für gewünschte Bewegungen notwendigen Antriebsdrehmomente kann über inverse dynamische Modelle der Form

$$\mathbf{M}_q = \mathbf{M}(\mathbf{q}) \cdot \ddot{\mathbf{q}} + \mathbf{c}(\mathbf{q}, \dot{\mathbf{q}}) + \mathbf{g}(\mathbf{q}) + \mathbf{r}(\mathbf{q}, \dot{\mathbf{q}}) + \mathbf{F}_p(\mathbf{q}) \quad (2.15)$$

erfolgen [Hop21], wobei  $\mathbf{M}(\mathbf{q})$  die Massenmatrix,  $\mathbf{c}(\mathbf{q}, \dot{\mathbf{q}})$  auftretende Zentrifugal- und Corioliskräfte,  $\mathbf{g}(\mathbf{q})$  Gewichtskräfte,  $\mathbf{r}(\mathbf{q}, \dot{\mathbf{q}})$  Reibkräfte und  $\mathbf{F}_p(\mathbf{q})$  die den Antriebsdrehmomenten gegenwirkenden Abtriebskräfte in generalisierten Koordinaten darstellen. Modellbasierte Beschreibungen genannter Größen bieten die Möglichkeit, Antriebsverläufe redundanter Werkzeugmaschinen durch Formulierung und approximative Lösung von Kostenfunktionen zu optimieren, was beispielsweise durch Ansätze aus der nichtlinearen, modellprädiktiven Regelung (engl.: Model Predictive Control) (MPC) [Sch21] gelingen kann. Anwendungen von MPC auf Werkzeugmaschinen sind in der Literatur selten zu finden. Stephens et al. zeigen am Beispiel einer 5-Achs-Fräsmaschine, dass die Antriebspositionsgenauigkeit durch die Implementierung einer MPC im Vergleich zu einem konventionellen PID-Regler erheblich gesteigert werden kann. [SMG12] Nicolis et al. demonstrieren an einem 7-Achs-Roboter, dass MPC bei redundanten Kinematiken dazu beitragen können, neben der eigentlichen Regelaufgabe zusätzliche Nebenbedingungen in die Regelung mit aufzunehmen und realisieren eine Impedanzregelung bei minimierten Gelenkgeschwindigkeiten und festgelegten Gelenkorientierungen. [NAR20] Yang et al. nutzen eine 5-Achs-Werkzeugmaschine als Demonstrationsobjekt, um die Potenziale von MPC zur Reduktion von Positionsabweichungen der Werkzeugspitze aufzuzeigen. Unter Aufstellung einer Kostenfunktion, die sowohl Antriebs- und Abtriebsabweichungen als auch die Höhe der Stellgrößen berücksichtigt, zeigen die Autoren, dass Abweichungen der Abtriebspositionen massiv reduziert werden können. [YZD17] Ein modellfreies Lernen zur Ableitung optimaler Stellgrößen, bei dem die Ausgangsgrößen vorgestellter Modelle zur Berechnung von Bestandteilen für Belohnungsfunktionen herangezogen werden, wird durch eine Anwendung von RL [Li23b] ermöglicht. So können Rucke, Antriebsdrehmomente, Positionsabweichungen und

---

weitere modellbasiert berechenbare Größen herangezogen werden, um die Güte gewählter Stellgrößen mittels einer Belohnungsfunktion zu quantifizieren. Dies ermöglicht das Lernen einer optimalen Entscheidungsstrategie (engl.: Policy), die nach modellbasierter Optimierung von der Simulationsumgebung in die reale Welt transferiert werden kann. Eine Applikation in der realen Umgebung bietet anschließend die Möglichkeit, die Effekte von Modellfehlern oder modellbasiert nicht abbildbaren Phänomenen auf die Strategie zu beseitigen und somit die optimale, zustandsabhängige Entscheidungsstrategie für die jeweilige Werkzeugmaschine zu finden. Anwendung finden solche Ansätze in der Literatur vor allem auf mehrachsigen, teilweise redundanten Industrierobotern. Xie et al. zeigen unter Nutzung unterschiedlicher Actor-Critic (AC)-Algorithmen, dass optimale Trajektorien von Robotern erlernt werden können, die sowohl die Posengenauigkeit optimieren als auch Kollisionen zu raumfesten Hindernissen verhindern. Als Belohnungsbestandteile werden Positions-, Orientierungsabweichungen und Distanzen zu Hindernissen herangezogen und als Aktionen die jeweiligen Antriebsdrehmomente gewählt. [Xie19] Shen et al. [She22] sowie Hua et al. [Hua21] lassen ebenfalls Bewegungsbahnen des Endeffektors unter Nutzung von RL-Algorithmen erlernen, die Kollisionen mit Hindernissen vermeiden. Ähnliche Anwendungen, bei denen Regelgesetze ohne eine Modellierung der Roboterkinematik auskommen, stellen Kumar et al. [Kum21] vor. Perrusquía et al. wenden zur Positionsregelung eines redundanten Manipulators einen Multi-Agenten-RL-Algorithmus an und zeigen, dass dieser Positionen erheblich schneller anfahren kann als klassische PID-Regler oder auf überwachten Lernmethoden basierende Algorithmen. [PYL21] Li et al. präsentieren eine auf RL-Algorithmen beruhende Methode, mithilfe derer Werkzeugspitzenpfade redundanter Manipulatoren im Hinblick auf Kollisionsvermeidung und Prozessdauer optimiert werden. Beim inversen Mapping der Abtriebs- auf Antriebskoordinaten wird die Redundanz des Manipulators genutzt, um neben der Positionsgenauigkeit ebenfalls die Energieeffizienz zu optimieren [LLD21], wodurch Anforderungen nach möglichst energieeffizienten Betriebsmöglichkeiten von Werkzeugmaschinen [Den20] erfüllt werden können. Eine interessante Anwendung stellen Maldonado-Ramirez et al. in einem Schweißprozess mit einem Industrieroboter vor, der mittels optischer Messtechnik die auf dem Bauteil eingezeichnete Schweißnaht observiert und mittels eines CNN, das als Policy dient, Positionsstellgrößen im Arbeitsraum ableitet. Es konnte nachgewiesen werden, dass durchschnittliche Positions- und Orientierungs-

---

abweichungen 0,85 mm bzw. 1,05° betragen, was ausreichende Genauigkeiten für Schweißprozesse darstellt. [MRL21]

## 2.4. Zwischenfazit

Zahlreiche Unsicherheitseinflüsse wirken sich auf Eigenschaften umformtechnisch hergestellter Bauteile aus und resultieren in schwankenden Bauteilqualitäten. Ansätze zur Beherrschung jener Unsicherheit gehen aus der Flexibilisierung von Umformmaschinen hervor, deren zusätzliche Freiheitsgrade eine simultane Regelung multipler Bauteileigenschaften ermöglichen. Viele Bauteileigenschaften sind jedoch während der Prozesse nicht mess- oder beobachtbar und stellen sich erst nach der Durchführung des Prozesses ein. Aus diesem Grund werden in der produktionstechnischen Literatur kaskadierte Eigenschaftsregelkreise [All16] oder dem Prozess nachgelagerte Eigenschaftsmessungen [Möh20] vorgeschlagen, mithilfe derer das Maschinenverhalten für nachfolgende Prozesse adaptiert werden kann. Offen bleibt bei den vorgeschlagenen Methodiken jedoch, inwiefern die zwangsläufig anzuwendenden Modelle durch Daten angereichert werden sollen und welche Komplexitäten und Adaptivitäten die Modelle aufweisen müssen.

Mit der Entwicklung redundanter Mehrpunkt-Servopressen stehen mittlerweile Werkzeugmaschinen bereit, deren multiplen Abtriebsfreiheitsgrade eine Mehrgrößenregelung erlauben und deren Redundanz gleichzeitig Optimierungen der modellgestützten Transformation von Abtriebs- auf Antriebsverläufe zulässt. Überschüssige Antriebsfreiheitsgrade werden momentan genutzt, um die Totpunkte solcher Maschinen zu regeln, wobei diese so eingestellt werden, dass die Manipulierbarkeit der Stoßelpose maximiert wird. [Hop21] Dabei entsteht ein Zielkonflikt zwischen maximaler Geschwindigkeitsübersetzung und bereitgestellter Presskraft, der bei der Planung von Antriebsverläufen bislang unberücksichtigt bleibt.

---

## 3. Zielsetzung und Vorgehensweise

---

### 3.1. Zielsetzung

Zentrales Ziel der vorliegenden Dissertation ist die Erlangung von wissenschaftlichen Erkenntnissen zur kaskadierten Regelung von Bauteileigenschaften auf redundanten Mehrpunkt-Servopressen. Schwerpunkt der Arbeit ist das Aufzeigen von Potenzialen der Anwendung von KI-Algorithmen zur Performanzsteigerung bestehender Eigenschafts-, Prozess- und Maschinenregelungen. Aus dem Stand der Technik wird ersichtlich, dass grundlegende Methoden zur Regelung der Stößelpose bereits bestehen, jedoch die Potenziale datengetriebener Modelle zur Regelung von Bauteileigenschaften nicht vollständig bekannt sind. So gilt es aufzuzeigen, dass durch eine Kombination von Online-Prozessregler und Offline-Eigenschaftsregler sowohl im Prozess messbare Prozessgrößen als auch sich erst nach der Prozessführung einstellende Bauteileigenschaften manipulierbar bzw. regelbar sind.

Wesentlich für die Durchführung der Forschungsarbeiten ist die Entwicklung und Nutzung von Modellen mit weißen und insbesondere schwarzen Anteilen. Bislang kommen Modelle mit hohem weißem Anteil zur Regelung von redundanten Mehrpunkt-Servopressen im Arbeitsraum zum Einsatz, die funktionale Zusammenhänge zwischen Posenabweichungen des Stößels und Sollgeschwindigkeiten der Antriebe bereitstellen. Dies ermöglicht zwar eine Regelung der Stößelpose, jedoch noch keine Adaption von Führungsgrößen zur Manipulation von Bauteileigenschaften. Eine auf analytischen White-Box-Modellen beruhende a priori Berechnung von Bauteileigenschaften bei bekanntem Prozessgrößenverlauf erscheint angesichts einwirkender Unsicherheit aus Halbzeug, Werkzeug, Maschine und Umwelt impraktikabel, weshalb ein KI-gestützter Ansatz verfolgt wird. So wird um den bestehenden Online-Prozessregler ein Offline-Produktregler etabliert, der unter Einspeisung von

Daten vorangegangener Produktionsverläufe optimale Führungsgrößen für den Online-Prozessregler ableitet. Ein optimaler Zeitverlauf der Abtriebsgrößen lässt jedoch noch keine deterministische Berechnung der Antriebsverläufe zu, da es sich bei den in dieser Arbeit herangezogenen Versuchsständen um überaktuierte Maschinen handelt. Daher wird untersucht, welche Ansätze sich zur simulationsgestützten Antriebspfadoptimierung eignen und welche Optimierungskriterien es dabei zu berücksichtigen gilt.

Abbildung 3.1 gibt einen Überblick über ein schematisches Blockschaltbild, das

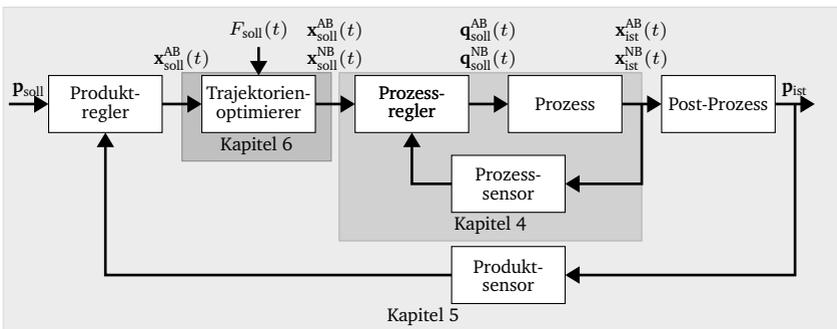


Abbildung 3.1.: Schematisches Blockschaltbild zur Regelung redundanter Mehrpunkt-Servopressen in Anlehnung an [All16], das der Ableitung von Zielsetzung und Forschungsfragen dient

die Eigenschaftsregelung auf redundanten Mehrpunkt-Servopressen adressiert und angelehnt an den bereits vorgestellten Eigenschaftsregelkreis nach Allwood [All16] ist. Als Eingangsgröße der äußeren Kaskade dienen Soll-Bauteileigenschaften  $p_{soll}$ . Aufgabe des Produktreglers ist es, Kenntnisse über gemessene Bauteileigenschaften  $p_{ist}$  vergangener Produktionsdurchläufe zu nutzen, um zeitliche Soll-Verläufe der Abtriebsgrößen  $x_{soll}^{AB}(t)$  zu bestimmen, die Abweichungen zwischen Soll- und Ist-Bauteileigenschaften  $\Delta p$  möglichst minimieren. Die aus dem Produktregler ausgehenden Abtriebsverläufe werden anschließend einem Trajektorienoptimierer zugeführt, der unter Berücksichtigung des zu erwartenden Kraftverlaufes am Abtrieb  $F_{soll}(t)$  zusätzliche Nebenbedingungen  $x_{soll}^{NB}(t)$  formuliert, die die Realisierbarkeit des Prozesses ermöglichen. Dies dient im Besonderen der Lösung des in Kapitel 2.3.2 geschilderten Zielkonfliktes zwischen Manipulierbarkeit und verfügbarer Presskraft

---

bei der Regelung von nichtlinear-übersetzenden Pressen. Sind die zeitlichen Verläufe der Abtriebsgrößen  $\mathbf{x}_{\text{soll}}^{\text{AB}}(t)$  und der Nebenbedingungen  $\mathbf{x}_{\text{soll}}^{\text{NB}}(t)$  bekannt, werden diese dem Prozessregler als Führungsgrößen bereitgestellt, der die Maschinenregelung realisiert und die im Arbeitsraum vorgegebenen Soll-Vorgaben  $\mathbf{x}_{\text{soll}}(t)$  in Stellgrößen für die Maschinenantriebe  $\mathbf{q}_{\text{soll}}(t)$  umwandelt. Dabei wird die Regelaufgabe auf die Antriebe aufgeteilt, wobei die Antriebe  $\mathbf{q}^{\text{AB}}$  zur Manipulation der durch den Produktregler spezifizierten Abtriebsverläufe  $\mathbf{x}_{\text{soll}}^{\text{AB}}(t)$  zuständig sind. Die durch die redundante Maschinentopologie überschüssigen Antriebsfreiheitsgrade  $\mathbf{q}^{\text{NB}}$  übernehmen die Manipulation der durch den Trajektorienoptimierer identifizierten Nebenbedingungen  $\mathbf{x}_{\text{soll}}^{\text{NB}}(t)$ . Aus dem schematischen Blockschaltbild lassen sich damit drei zentrale Fragestellungen ableiten, die im Folgenden näher spezifiziert werden.

1. *Wie kann die Performanz bestehender Positionsregelungen bei hoher Nichtlinearität der Strecke und Unsicherheit gesteigert werden?*

Um höchstmögliche Übereinstimmungen zwischen den Soll-  $\mathbf{x}_{\text{soll}}^{\text{AB}}(t)$  und Ist-Abtriebsgrößen  $\mathbf{x}_{\text{ist}}^{\text{AB}}(t)$  sicherzustellen, stellen Adaptionen der Verstärkungsfaktoren an linearisierte Arbeitspunkte ein vielversprechendes Mittel dar. Bisherig entworfene Positionsregelungen von Mehrpunkt-Servopressen im Arbeitsraum verstärken Regelabweichungen mit konstanten Faktoren [Hop21; HPG19] und tragen damit dem nichtlinearen Übersetzungsverhalten der Presse unzureichend Rechnung. GS-Techniken lassen eine optimale Auslegung der Verstärkungsfaktoren unter Anwendung linearer Regelungstechnik zu, wodurch Stabilitätsnachweise erbracht und Regelabweichungen dynamisch eliminiert werden können. Daher gilt es nachzuweisen, dass eine optimierte Positionsregelung von Mehrpunkt-Servopressen im Arbeitsraum positive Effekte auf Maßhaltigkeiten produzierter Bauteile hat.

2. *Welche KI-gestützten Modelle eignen sich zur Übersetzung von identifizierten Eigenschaftsabweichungen  $\Delta \mathbf{p}$  in Abtriebsverläufe  $\mathbf{x}_{\text{soll}}^{\text{AB}}(t)$ ?*

Die übergeordnete Zielgröße eines umformtechnischen Produktionsprozesses ist eine anforderungsgerechte Fertigung von Bauteilen und damit das Einhalten spezifizierter Toleranzen. Ausprägungen relevanter Bauteileigenschaften werden somit entweder ein- oder zweiseitig von Toleranzgrenzen beschränkt und führen bei Überschreitung zu Ausschuss. Treten Abweichungen

---

zwischen nach dem Prozess gemessenen und vor dem Prozess spezifizierten Bauteileigenschaften auf, können Führungsgrößen der Maschinenregelung für das nächste zu fertigende Bauteil angepasst werden, um Abweichungen zu reduzieren oder zu eliminieren. Meist sind die Zusammenhänge zwischen generierten Bauteileigenschaften und Verläufen der Abtriebsgrößen hochkomplex und nichtlinear, sodass sich diese nicht oder nur stark begrenzt durch analytische White-Box-Modelle beschreiben lassen. Aus diesem Grund wird am Beispiel dreier Umformprozesse untersucht, wie Eigenschaftsabweichungen  $\Delta p$  mithilfe von KI-gestützten Modellen entgegengewirkt werden kann (Kapitel 5). Dabei sind insbesondere der Einsatz und die Performanzen von überwachten und bestärkenden Lernansätzen im Produktregler Schwerpunkt der Untersuchungen.

3. *Wie können Nebenbedingungen redundanter Maschinentopologien in die Maschinenregelung integriert werden und welche Optimierungskriterien sollten Berücksichtigung finden?*

Die Überaktuierung redundanter Mehrpunkt-Servopressen erlaubt, wie anhand von Abbildung 3.1 beschrieben, eine Berücksichtigung von Nebenbedingungen in der Maschinenregelung. Der Zielkonflikt zwischen maximaler Manipulierbarkeit der Stößelpose und Bereitstellung höchstmöglicher Presskräfte findet bei der Planung von Antriebspfaden bislang keine Berücksichtigung. Daher gilt es Ansätze zu untersuchen, die der Identifikation optimaler Antriebsrajektorien unter Kenntnis der aufzubringenden Prozesskraftverläufe  $F_{\text{soll}}(t)$  dienen. Darüber hinaus stellt sich die Frage, welche grundsätzlichen Optimierungsansätze Anwendung finden und in welchem Maße weiße bzw. schwarze Modellierungsanteile in die Optimierungsansätze eingehen können.

## 3.2. Vorgehensweise

Die Beantwortung vorangegangener Forschungsfragen stützt sich auf simulative und experimentelle Untersuchungen am Beispiel der 3DSP. In Kapitel 4 werden mit dem Prototypen und der Forschungsversion der 3DSP zwei Versuchsstände sowie deren Regelkonzepte vorgestellt. Ein Transfer der bereits in [Hop21] vorgestellten Positionsregelung vom 1t-Prototyp auf die 160t-Forschungsversion der 3DSP wird

---

vorgenommen. Weiterhin werden die Positionsregelung mit Hilfe von GS-Techniken optimiert und daraus hervorgehende Genauigkeitssteigerungen am Beispiel eines inkrementellen Lochwalzprozesses demonstriert (Forschungsfrage 1).

In Kapitel 5 werden KI-gestützte Modellierungsansätze für den in Abbildung 3.1 dargestellten Produktregler vorgestellt. Am Beispiel von eindimensionalen Regelungen in Biegeprozessen (Kapitel 5.1 & 5.2) und einer mehrdimensionalen Regelung in einem SPIF-Prozess (Kapitel 5.3) werden unterschiedliche KI-Algorithmen zur Vorhersage optimaler Abtriebsverläufe & -größen vorgestellt, die das Ziel verfolgen, die Auswirkungen elastischer Relaxationen auf die geometrische Bauteilmaßhaltigkeit zu kompensieren. Insbesondere ein Vergleich der Vor- und Nachteile überwachter und bestärkender Lernalgorithmen ist Gegenstand der Kapitel. Dabei werden Konzepte zur Inline-Erfassung geregelter Prozessgrößen durch den Prozesssensor (siehe Abbildung 3.1) als auch Offline-Messungen finaler Produkteigenschaften durch den Produktsensor präsentiert (Forschungsfrage 2).

Abschließend dient Kapitel 6 dem Vergleich zweier Konzepte zur simulationsgestützten Findung optimaler Trajektorien unter Kenntnis von Soll-Abtriebsgrößen  $\mathbf{x}_{\text{soll}}^{\text{AB}}(t)$  und Prozesskraftverläufen  $F_{\text{soll}}(t)$ . Es werden zwei Ansätze miteinander verglichen, die sich im Grad der genutzten weißen und schwarzen Modellanteile elementar voneinander unterscheiden. Einerseits findet MPC Anwendung, die unter Optimierung einer manuell parametrisierten, multikriteriellen Kostenfunktion optimale Stellgrößen für die Maschinenantriebe ermittelt. Dies geht mit erhöhtem Modellierungsaufwand einher. Im Gegensatz dazu findet modellfreies RL Anwendung, bei dem der Algorithmus über keinerlei Kenntnisse über das Systemverhalten verfügt. Das Kapitel schließt mit einem Vergleich beider Ansätze und dient der Beantwortung von Forschungsfrage 3.

---

## 4. Versuchsstände und deren Regelung

---

Im Rahmen der vorliegenden Arbeit dienen der Prototyp und die Forschungsversion der 3DSP als Demonstrationsobjekte. Bei beiden Maschinen handelt es sich um redundante und demnach überaktuierte Servopressen mit drei Stößelfreiheitsgraden und fünf voneinander entkoppelten Antrieben. Im Folgenden werden beide Pressen und deren modellbasierte Regelungskonzepte vorgestellt. Weiterhin erfolgt eine Optimierung der bestehenden Positionsregelung mitsamt simulativer und experimenteller Erprobung.

### 4.1. Beschreibung der Versuchsstände

Mit dem Ziel der Flexibilisierung umformtechnischer Prozesse wurden am PtU ein Prototyp [Sch10] und darauffolgend im Rahmen der zwölfjährigen Laufzeit des Sonderforschungsbereiches 805 *Beherrschung von Unsicherheit in lasttragenden Systemen des Maschinenbaus* die Forschungsversion [Hop21] der 3DSP entwickelt und aufgebaut. Beide Pressen verfügen über einen parallelkinematischen Aufbau, bei dem exzentrische Servomotoren voneinander entkoppelt die Positionen von drei Stößel-druckpunkten manipulieren. Die Übersetzung der Antriebs- in Abtriebsbewegungen erfolgt über drei Kniehebelgetriebe, die um einen Rotationspunkt  $\mathbf{B}_0$  schwingen. Abbildung 4.1 veranschaulicht die Topologien beider Pressen und visualisiert die Kinematiken der dreifach in den Maschinen verbauten, parallelkinematischen Getriebeketten als Stabmodell. Zusätzlich eingezeichnet sind die Antriebe, die in die Exzenterantriebe  $\varphi_i$  mit  $i \in [1, 2, 3]$  und Spindeltriebe einteilbar sind. Die Spindeltriebe treiben die koaxial übereinander verbauten Spindelsterne  $\mathbf{q}_{\text{sp}} = \begin{bmatrix} z_{\text{spo}} & z_{\text{spu}} \end{bmatrix}$  an, welche mit den drei um  $120^\circ$  versetzt angeordneten Getriebeketten verbunden

sind. Die Stellung der Spindelsterne legt in erster Linie die Position des Rotationspunktes  $B_0$  fest, aus welchem sich der obere Totpunkt (OT) und der untere Totpunkt (UT) der Stößeldruckpunkte bzw. Stößellager ergeben. Während beim Prototypen

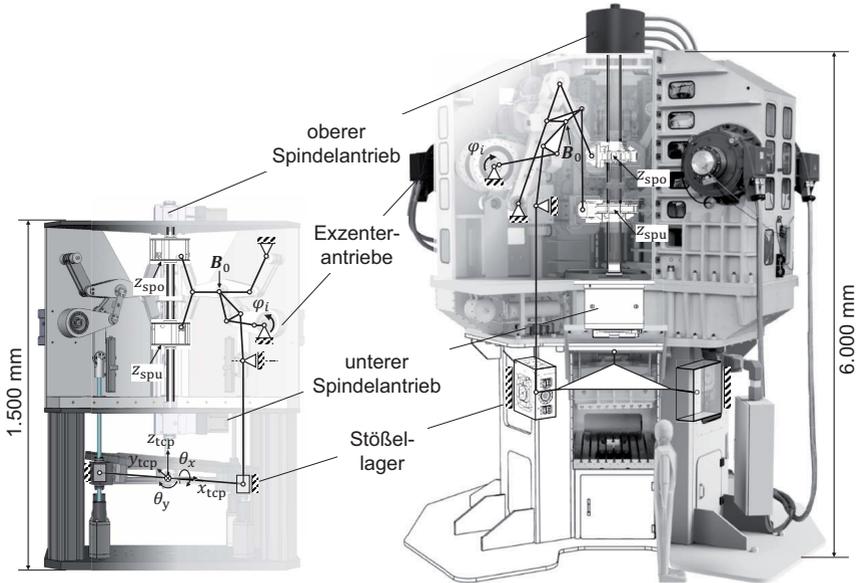


Abbildung 4.1.: Maschinentopologien von 3DSP - Prototyp mit 1t Presskraft (links) und Forschungsversion mit 160t Presskraft (rechts) [Pel21c]

fünf Servomotoren mit Schneckengetriebe verbaut sind, aus deren Kombinationen sich jeweils ein maximales Drehmoment von 15 Nm ergibt, sind in der Forschungsversion insgesamt acht Torquemotoren verbaut. Sechs der Torquemotoren stellen dabei exzentrische Servomotoren dar, wobei jeweils zwei Motoren mechanisch als auch elektronisch nach dem Master-Slave-Konzept gekoppelt sind und somit als eine Antriebseinheit angesehen werden. Eine exzentrische Antriebseinheit kann ein Nenn Drehmoment von 7000 Nm aufbringen, die Spindeltriebe der Forschungsversion verfügen über jeweils 5200 Nm Nenn Drehmoment. Bei phasengleichem Betrieb der drei exzentrischen Antriebseinheiten kommt es zu keiner Stößelkipfung und Hubhöhen zwischen 25 mm und 100 mm (Forschungsversion) bzw. 12 mm und 41 mm (Prototyp) sind realisierbar. Drehen die exzentrischen Antriebseinheiten

Parameter	Prototyp	Forschungsversion	Skalierungsfaktor
Stößeldurchmesser	691 mm	2.220 mm	3,2
Hubhöhe	12-41 mm	25-100 mm	2,44
max. $\theta_x$	4,52°	3,43°	0,76
max. $\theta_y$	3,91°	2,97°	0,76
Spindelhub	50 mm	200 mm	4
max. $M_\varphi$	15 Nm	7.000 Nm	466
max. $F_z$	10 kN	1.600 kN	160

Tabelle 4.1.: Kennwerte der 3DSP nach [Hop21]

phasenversetzt und die Winkelmaße  $\varphi_i$  unterscheiden sich demzufolge voneinander, resultiert dies in unterschiedlichen vertikalen Höhen der Stößellager und es kommt zu Stößelkippen  $[\theta_x \ \theta_y]$  um die raumfesten x- und y-Achsen. Anforderungen an hohe Beanspruchungen der Getriebebauteile bei gleichzeitig hoher Positionsgenauigkeit werden durch spielfreie, kombinierte Wälz-Gleitlager erfüllt, die für die Forschungsversion der 3DSP entwickelt und integriert wurden [SKG19; GSG20]. Einen Überblick über charakteristische Kennwerte beider Pressen bietet Tabelle 4.1. Während die exzentrischen Antriebseinheiten in jedem Arbeitspunkt vollständige

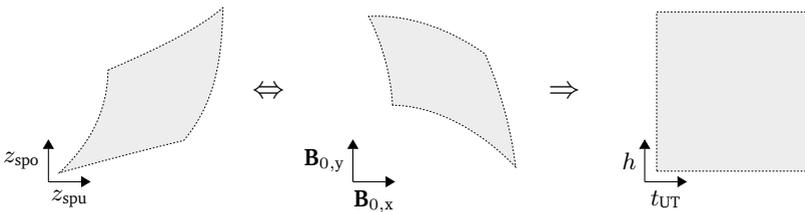
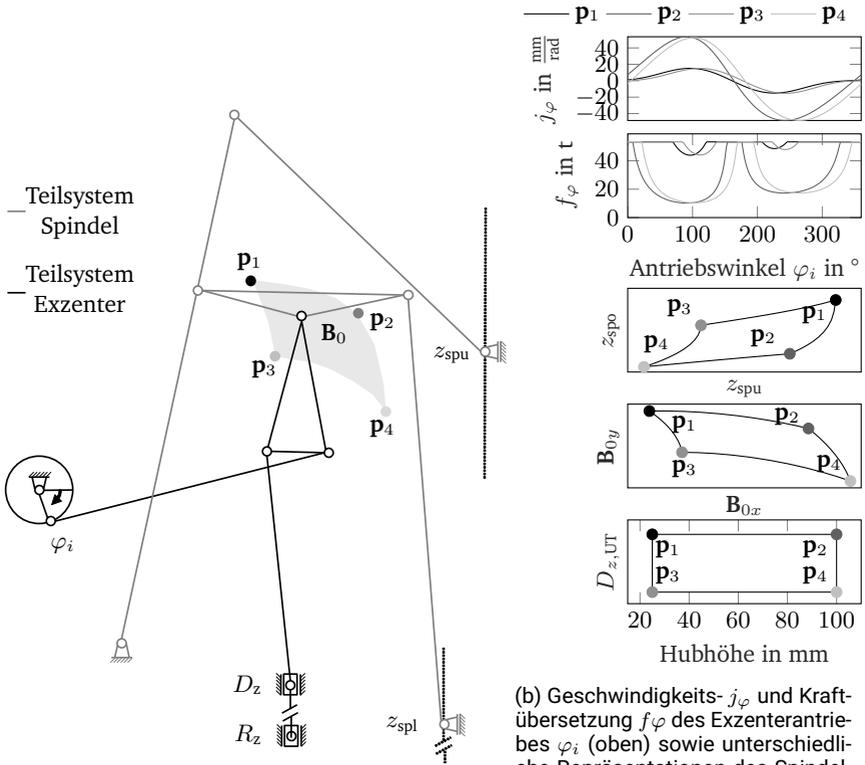


Abbildung 4.2.: Prozessfenster der Spindelantriebe der Forschungsversion und dazugehörige kinematische Transformationen in  $\mathbf{B}_0$ - und Totpunktkoordinaten

Rotationen vollziehen können, ist das Betriebsfenster der Spindelantriebe aufgrund von Kollisionsgefahr von Getriebebauteilen restriktiert. Abbildung 4.2 zeigt schematisch das Betriebsfenster der Spindelantriebe für die Forschungsversion, das über Vorwärtskinematikmodelle in x- und y-Koordinaten des Rotationspunktes  $\mathbf{B}_0$  oder in ein rechteckiges Betriebsfenster bestehend aus UT  $t_{UT}$  und Hubhöhe  $h$  transformierbar ist. Die gleichen Betriebsfenster sind ebenfalls in Abbildung 4.3b) erfasst,

wobei die begrenzenden Punkte  $\mathbf{p}_i$  mit  $i \in [1, \dots, 4]$  eingezeichnet sind.

In Abbildung 4.3a)<sup>1</sup> ist das Betriebsfenster des Rotationspunktes  $\mathbf{B}_0$  in grau hin-



(a) Stabmodell der Forschungsversion der 3DSP

(b) Geschwindigkeits-  $j_\varphi$  und Kraftübersetzung  $f_\varphi$  des Exzenterantriebes  $\varphi_i$  (oben) sowie unterschiedliche Repräsentationen des Spindel-Betriebsfensters

Abbildung 4.3.: Kinematik und Kraftübersetzung der Forschungsversion der 3D-Servo-Presse

terlegt. Je weiter der Rotationspunkt  $\mathbf{B}_0$  auf der linken Seite des eingezeichneten Betriebsfenster platziert wird, desto geringer wird die durch eine Rotation der exzentrischen Antriebseinheit realisierbare Hubhöhe (siehe 4.3b)  $\mathbf{p}_1$  &  $\mathbf{p}_3$ ). Eine Platzierung an der rechten Grenze des Betriebsfensters führt auf Hubhöhen von bis zu 100 mm (siehe 4.3b)  $\mathbf{p}_2$  &  $\mathbf{p}_4$ ). Die Spindelstellungen und die daraus hervorge-

<sup>1</sup>Abbildung A.1 bietet analoge Informationen für den Prototypen der 3DSP.

---

hende Stellung des Rotationspunktes  $\mathbf{B}_0$  sind damit von fundamentaler Bedeutung für die Kennwerte eines Hubes. Analog zu den in Abbildung 2.12 hergeleiteten Geschwindigkeits- und Kraftübersetzungen von Kurbel- und Kniehebelkinematiken für mechanische Pressen bieten die zwei oberen Plots in 4.3b) Einblicke in die Geschwindigkeits- und Kraftübersetzungen  $j_\varphi$  und  $f_\varphi$  für die jeweiligen Grenzpunkte des Betriebsfenster  $\mathbf{p}_i$ . Es wird ersichtlich, dass die in Kapitel 2.3.2 geschilderte Problematik der Substitutionalität zwischen Kraft- und Geschwindigkeitsübersetzung auch für die Kniehebelkinematik der 3DSP gilt, wobei die stufenlose Einstellung der Spindelstellungen eine Manipulation von Kraft- und Geschwindigkeitsübersetzung während des Prozesses ermöglicht. Ein Betrieb der Presse bei niedrigen Hubhöhen (siehe Punkte  $\mathbf{p}_1$  &  $\mathbf{p}_3$ ) führt zu geringen Geschwindigkeitsübersetzungen, jedoch weicht die aufbringbare Kraft bei Abruf des Nenndrehmomentes von 7000 Nm an der exzentrischen Antriebseinheit zwischen den Totpunkten nur geringfügig von den mechanisch realisierbaren  $160 \text{ t}/3 = 53.33 \text{ t}$  ab. Demgegenüber führen hohe Hubhöhen (siehe Punkte  $\mathbf{p}_2$  &  $\mathbf{p}_4$ ) zu hohen Geschwindigkeitsübersetzungen von bis zu 54 mm/rad, wobei die am Stoßeldruckpunkt abrufbare Kraft zwischen den Totpunkten auf bis zu 100 kN abfällt.

## 4.2. Validierung der Positionsregelung

Um eine möglichst genaue Führung der Stoßelpose zu gewährleisten, ist eine modellbasierte Regelung der Stoßelpose erforderlich. Ansätze zur Regelung der 3DSP wurden von Hoppe et al. [HPG19] vorgestellt und am Prototypen der Presse experimentell validiert. Dabei wird das Anfahren kinematischer Singularitäten vermieden, da dies mit dem implementierten Regelgesetz aufgrund von kinematischen Singularitäten zu Instabilitäten führt. Deshalb stellen Hoppe [Hop21] und Hoppe et al. [E2] gegen Singularitäten robuste Regelgesetze auf und prüfen deren Eignung anhand experimenteller Untersuchungen am Prototypen der 3DSP [Hop21] und für die Forschungsversion in simulativer Umgebung [E2]. Da eine experimentelle Erprobung des vorgestellten Regelgesetzes auf der Forschungsversion bislang nicht erfolgte, wird diese im Folgenden vorgestellt.

Dazu wird die Funktionsweise der Positionsregelung anhand des Blockschaltbildes aus Abbildung 4.4 erläutert. Da es sich bei der 3DSP um ein redundantes System

mit fünf Antriebs- und lediglich drei Abtriebsfreiheitsgraden handelt, erfolgt eine Entkopplung der Regelungsaufgaben für Spindel- und Exzenterantriebe. Zentrales Ziel der Positionsregelung der 3DSP ist eine möglichst genaue Manipulation der dreidimensionalen Stoßelpose  $\mathbf{x}_{st} = [\theta_x \quad \theta_y \quad z_{st}]^T$ . Bei Pressen stellen darüber hinaus die Lage der Totpunkte  $\mathbf{t} = [t_{OT} \quad t_{UT}]^T$  zwei wichtige Kenngrößen für die Ausführung eines Hubes dar, weshalb diese neben der Stoßelpose als weitere Regelgrößen herangezogen werden. Eine Entkopplung der Regelungsaufgaben erfolgt nun durch Zuordnung von Antriebsfreiheitsgraden zu entsprechenden Regelgrößen. Da die Exzenterantriebe  $\mathbf{q}_\varphi = [\varphi_1 \quad \varphi_2 \quad \varphi_3]^T$  Drehzahlen von bis zu 200 U/min bereitstellen und durch ein phasenversetztes Verfahren die einzigen Antriebe darstellen, die eine Verkipfung des Stoßels hervorrufen können, werden diese zur Manipulation der Stoßelpose verwendet. Dagegen erfordert das Verstellen der Totpunkte im laufenden Betrieb nur geringfügige Dynamiken, weshalb den Spindelantrieben  $\mathbf{q}_{sp} = [z_{spo} \quad z_{spu}]^T$  jene Regelaufgabe zugesprochen wird. Die Antriebe werden gemäß des Blockschaltbildes aus Abbildung 4.4 unter Nutzung

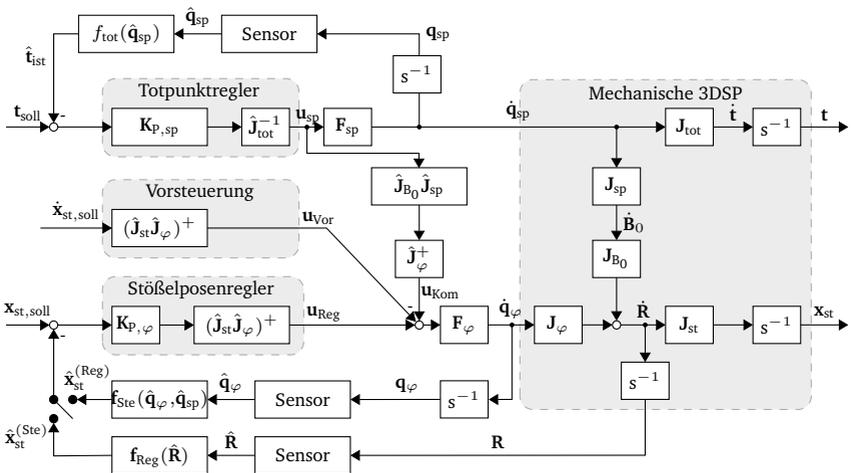


Abbildung 4.4.: Blockschaltbild der 3DSP Positionsregelung in Anlehnung an [Hop21] und [E12]

differenzieller, IK-Modelle geregelt. Die auf Starrkörpermodellen beruhenden

Jakobimatrizen  $\hat{\mathbf{J}}$  quantifizieren Geschwindigkeitsübersetzungen von Antrieben auf Regelgrößen, sodass über  $\dot{\mathbf{t}} = \hat{\mathbf{J}}_{\text{tot}} \cdot \dot{\mathbf{q}}_{\text{sp}}$  und  $\dot{\mathbf{x}}_{\text{st}} = \hat{\mathbf{J}}_{\text{st}} \cdot \hat{\mathbf{J}}_{\varphi} \cdot \dot{\mathbf{q}}_{\varphi}$  Transformationen der Antriebsgeschwindigkeiten in Geschwindigkeiten der Regelgrößen berechenbar sind, wobei  $\hat{\mathbf{J}}_{\text{st}} \in \mathbb{R}^{3 \times 3}$  und  $\hat{\mathbf{J}}_{\varphi} \in \mathbb{R}^{3 \times 3}$  die Jakobimatrizen der Teilsysteme Stößel bzw. Kniehebel darstellen und  $\hat{\mathbf{J}}_{\text{tot}} \in \mathbb{R}^{2 \times 2}$  die Übersetzung der Spindelantriebsgeschwindigkeiten auf die Geschwindigkeiten der Stößellager quantifiziert.<sup>2</sup> Da die Jakobimatrizen im Allgemeinen von den Antriebsstellungen abhängen und damit stark nichtlineares Verhalten aufweisen, ist es in Robotikanwendungen üblich, deren Inverse in das Reglerübertragungsverhalten zu integrieren, um nichtlineare Geschwindigkeitsübersetzungen in der Strecke zu kompensieren. Dies erfordert eine Invertierbarkeit der genutzten Jakobimatrizen in allen Arbeitspunkten, welche jedoch für die Jakobimatrix des Teilsystems Kniehebel  $\hat{\mathbf{J}}_{\varphi}$  nicht gegeben ist. In Totpunktstellungen, in denen die Position des jeweiligen Stößellagers Extremwerte erreicht, treten kinematische Singularitäten auf [HPG19; Hop21], weswegen Elemente der inversen Jakobimatrix unendlich hohe Werte annehmen und in singulären Konfigurationen Unstetigkeiten aufweisen. Um dies zu verhindern, werden inverse Jakobimatrizen mit Singularitäten unter Nutzung von Techniken der robusten Regelung regularisiert. Ein Ansatz ist die Nutzung von gedämpften DLS-Inversen [Wam86], die durch Einführung eines Regularisierungsfaktors  $\lambda_{\text{DLS}}$  Unstetigkeiten vorbeugen und sich gemäß

$$\mathbf{J}^+ = \frac{\mathbf{J}^T}{\mathbf{J}^T \mathbf{J} + \lambda_{\text{DLS}}^2 \mathbf{I}} \quad (4.1)$$

ergeben.

Sowohl der Regler der Totpunkte als auch der Stößelposenregler (siehe Abbildung 4.4) berechnen die jeweilige Regelabweichung durch einen Soll-Ist-Abgleich der Totpunkte  $\mathbf{e}_{\text{t}} = \mathbf{t}_{\text{soll}} - \hat{\mathbf{t}}_{\text{ist}}$  bzw. der Stößelpose  $\mathbf{e}_{\text{st}} = \mathbf{x}_{\text{st,soll}} - \hat{\mathbf{x}}_{\text{st,ist}}$ . Bei der Regelung der Totpunkte werden antriebsinterne Sensoren zur Messung der Spindelantriebspositionen genutzt und in einen Totpunktbeobachter  $\hat{\mathbf{t}}_{\text{ist}} = f_{\text{tot}}(\hat{\mathbf{q}}_{\text{sp}})$  gespeist, der die aktuelle Totpunktlage basierend auf einem Vorwärtskinematikmodell berechnet. Eine analoge Regelung für die Stößelpose basiert auf gemessenen Positionen aller Antriebe, wodurch die geschätzte Stößelpose  $\hat{\mathbf{x}}_{\text{st}}^{(\text{Ste})} = \mathbf{f}_{\text{ste}}(\hat{\mathbf{q}})$  berechnet wird. Auf Messungen der Antriebsvariablen basierende Regelungsansätze werden als Rege-

<sup>2</sup>Im Rahmen des vorliegenden Kapitels der Arbeit werden basierend auf Modellen geschätzte oder sensorisch aufgenommene Größen mit  $(\hat{\cdot})$  gekennzeichnet, die unsicherheitsbehaftet sind.

lungen im Gelenkraum bezeichnet. Diese bergen inhärent den Nachteil, dass die den Antrieben der Maschine in der kinematischen Kette nachgelagerte Unsicherheit nicht kompensiert werden kann. Aus diesem Grund wird die Regelung, die ausschließlich die Antriebspositionen misst und auf keine Sensoren innerhalb der Getriebekinematik zurückgreift, nachfolgend als Steuerung bezeichnet. Demgegenüber stehen Regelungen im Arbeitsraum, bei denen Sensoren in unmittelbarer Nähe zum Endeffektor dessen Pose berechnen. Ein solcher Regeltyp greift bei der Positionsregelung der 3DSP auf lineare Positionsgeber (*Balluff BTL5*, Auflösung 5  $\mu\text{m}$ ) zurück, die an allen drei Stößellagern befestigt sind. Die gemessenen Positionen der Stößellager  $\hat{\mathbf{R}}$  werden anschließend in ein Vorwärtskinematikmodell des Teilsystems Stößel  $\hat{\mathbf{x}}_{\text{st}}^{(\text{Reg})} = \mathbf{f}_{\text{Reg}}(\hat{\mathbf{R}})$  gespeist, das als Beobachter dient und die geregelte Stößelpose schätzt. Eine Regelung im Arbeitsraum hat dabei den Vorteil, dass auftretende Unsicherheit in den Teilsystemen Spindel- und Kniehebelkinematik, die durch Lagerspiel verbauter Wälz-Gleitlager [SKG19], Getriebeelastizität [GHS17] oder Fertigungstoleranzen unweigerlich auftreten, durch die Sensoren erfasst und damit kompensiert werden kann. Aus diesem Grund wird die Regelung basierend auf gemessenen Stößellagerpositionen im Folgenden als Regelung, die Regelung basierend auf gemessenen Antriebspositionen als Steuerung bezeichnet.<sup>3</sup> Die auftretenden Regelabweichungen  $\mathbf{e}_t$  und  $\mathbf{e}_{\text{st}}$  werden über proportionale Verstärkungsmatrizen  $\mathbf{K}_{\text{P,sp}} \in \mathbb{R}^{2 \times 2}$  bzw.  $\mathbf{K}_{\text{P},\varphi} \in \mathbb{R}^{3 \times 3}$  und eine Multiplikation mit inversen (gedämpften) Jakobimatrizen in die Geschwindigkeitsstellgrößen

$$\mathbf{u}_{\text{sp}} = \hat{\mathbf{J}}_{\text{sp}}^{-1} \cdot \mathbf{K}_{\text{P,sp}} \cdot \underbrace{(\mathbf{t}_{\text{soll}} - \hat{\mathbf{t}}_{\text{ist}}(\hat{\mathbf{q}}_{\text{sp}}))}_{\mathbf{e}_t}, \quad (4.2)$$

und

$$\mathbf{u}_{\text{Reg}} = (\hat{\mathbf{J}}_{\text{st}} \hat{\mathbf{J}}_{\varphi})^+ \cdot \mathbf{K}_{\text{P},\varphi} \cdot \underbrace{(\mathbf{x}_{\text{st,soll}} - \hat{\mathbf{x}}_{\text{st}}(\hat{\mathbf{q}}))}_{\mathbf{e}_{\text{st}}} \quad (4.3)$$

<sup>3</sup>Es sei angemerkt, dass es sich gemäß des Blockschaltbildes aus Abbildung 4.4 bei beiden eingezeichneten Regelvarianten (Berechnung der Stößelpose basierend auf Stößellagerpositionen oder basierend auf Antriebsgrößen) um Regelungen im Arbeitsraum handelt, da die gemessenen Größen über Vorwärtskinematik-Modelle in Abtriebsgrößen umgerechnet werden und sich die Regelabweichungen aus Soll- und Ist-Werten der geschätzten Stößelpose ergeben. Eine mit der Fachliteratur kompatible Bezeichnung der Regelgesetze würde auf die Begriffe der indirekten und direkten Regelung führen (siehe dazu auch [E12]). Die unterschiedlichen Varianten werden zur Berechnung der Ist-Stößelpose jedoch im Folgenden als Steuerung (Messung Antriebspositionen) und Regelung (Messung Stößellager) bezeichnet.

transformiert. Um die Dynamik der Stößelregelung zu erhöhen, ist eine Vorsteuerung implementiert, die aus der vorgegebenen Trajektorie der Stößelpose einen Geschwindigkeitsverlauf  $\dot{\mathbf{x}}_{\text{st,soll}}$  numerisch differenziert und gemäß

$$\mathbf{u}_{\text{Vor}} = (\hat{\mathbf{J}}_{\text{st}} \hat{\mathbf{J}}_{\varphi})^+ \cdot \dot{\mathbf{x}}_{\text{st,soll}} \quad (4.4)$$

einen vorgesteuerten Anteil der Gesamtstellgröße bereitstellt. Da Geschwindigkeiten der Spindelantriebe ebenfalls Einfluss auf die Geschwindigkeiten der Stößellager nehmen, bedarf es einer zusätzlichen Kompensation. Dazu werden die Spindelgeschwindigkeiten über

$$\mathbf{u}_{\text{Kom}} = \hat{\mathbf{J}}_{\varphi}^+ \cdot \hat{\mathbf{J}}_{B_0} \cdot \hat{\mathbf{J}}_{\text{sp}} \cdot \dot{\mathbf{q}}_{\text{sp}}, \quad (4.5)$$

in Geschwindigkeiten der Exzenterantriebe transformiert, wobei  $\hat{\mathbf{J}}_{B_0} \in \mathbb{R}^{3 \times 2}$  die Geschwindigkeitsübersetzung des Gelenkes  $B_0$  auf die drei Stößellager  $\mathbf{R}$  beschreibt. Dieser Einfluss muss von der Gesamtstellgröße subtrahiert werden, sodass sich  $\mathbf{u}_{\varphi}$  zu

$$\mathbf{u}_{\varphi} = \mathbf{u}_{\text{Reg}} + \mathbf{u}_{\text{Vor}} - \mathbf{u}_{\text{Kom}} \quad (4.6)$$

ergibt. Das Übertragungsverhalten aller Antriebe wird, wie in [HPG19] für den Prototypen der Presse demonstriert, als PT1-Übertragungsfunktion mit experimentell ermittelter Zeitkonstante angenommen.<sup>4</sup>

Um die Funktionalität der Regelung für die Forschungsversion der Presse zu validieren, werden Stauchexperimente durchgeführt. Abbildung 4.5b) zeigt das genutzte Stauchwerkzeug, das aus Ober- und Unterteil besteht. Im Oberteil ist im direkten Kraftfluss eine Kraftmessdose (*HBM C6B*) verbaut, die die im Prozess angelegte Stauchkraft misst. Die aus reinem Kupfer (*CW021A*) gefertigte Probe ist in einer kreisrunden, 30 mm hohen Matrize eingespannt, welche eine radiale Ausdehnung der Probe im unteren Bereich verhindert. Daher führt die Durchführung von Stauchversuchen auf die pilzförmige Bauteilgeometrie aus Abbildung 4.5b). Um die Güte der Regelung bewerten zu können, wird das Stauchwerkzeug an unterschiedlichen Stellen  $\mathbf{b}_i$  bezüglich des Stößelmittelpunktes befestigt. Abbildung 4.5a) zeigt den Stößel der 3DSP aus der Draufsicht, wobei die untersuchten Positionierungen des Werkzeugs  $\mathbf{b}_i$  eingezeichnet sind. Außermittigte Werkzeugpositionierungen führen zu außermittigten Kräfteinwirkungen auf den Stößel, sodass die Parallelkinematiken

<sup>4</sup>Die Vorgehensweise zur Ermittlung der Zeitkonstanten ist Anhang A.2 zu entnehmen.

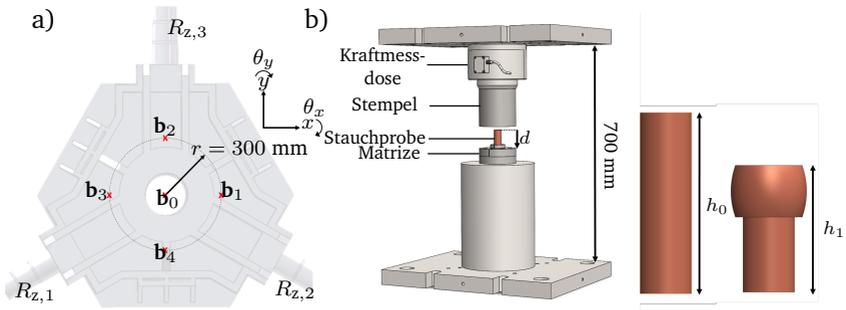


Abbildung 4.5.: a) Draufsicht des Stößels mit eingezeichneten Positionierungen des Stauchwerkzeugs  $\mathbf{b}_i$  und b) CAD-Darstellung des Werkzeugs und Kupferproben im unverformten und umgeformten Zustand in Anlehnung an [E12]

des Teilsystems Kniehebel unterschiedlich stark belastet werden. Durch resultierende Momente um die horizontalen Mittelachsen des Stößels kommt es bei Pressen zu Stößelkippungen [SS94; CCL13], die durch eine Regelung im Arbeitsraum detektiert und kompensiert werden sollten. Ebenfalls sollte die Regelung im Arbeitsraum in Pressen auftretende Elastizitäten [AW05] kompensieren und somit zu höheren Stauchtiefen führen.

Abbildung 4.6 gibt einen Überblick über mehrere Messgrößen für Stauchversuche an unterschiedlichen Positionierungen  $\mathbf{b}_i$  relativ zum Stößelmittelpunkt. In 4.6a) sind Drehmomente aller drei Antriebe  $M_{\varphi_i}$  als auch die im Oberwerkzeug gemessene Kraft für geregelte Stauchversuche aufgetragen. In der Abbildung sind die Zeiträume, in denen betragsmäßig hohe Druckgradienten vorliegen, wie der lineare Kraftanstieg im linear-elastischen Bereich bei etwa 5 Sekunden und der Kraftabfall im Rückhub nach etwa 16 Sekunden, transparent grau hinterlegt, um zeitliche Abgleiche zwischen Kraft-, Momenten- und Kippwinkelverläufen zu ermöglichen. Aus Abbildung 4.6a) wird deutlich, dass die Verläufe der Antriebsdrehmomente stark von der Positionierung des Werkzeugs abhängen. Dies lässt sich begründen mit unterschiedlichen Hebelverhältnissen zwischen den entsprechenden Stößellagern und dem Druckpunkt des Werkzeugs am Stößel  $\mathbf{b}_i$ . Während das Hebelverhältnis für die mittige Positionierung  $\mathbf{b}_0$  für alle Antriebe exakt gleich ist und demnach die Antriebe über den gesamten Stauchvorgang ähnlich hohe Drehmomente aufbringen müssen, gehen außermittige Werkzeugpositionierungen mit zusätzlichen

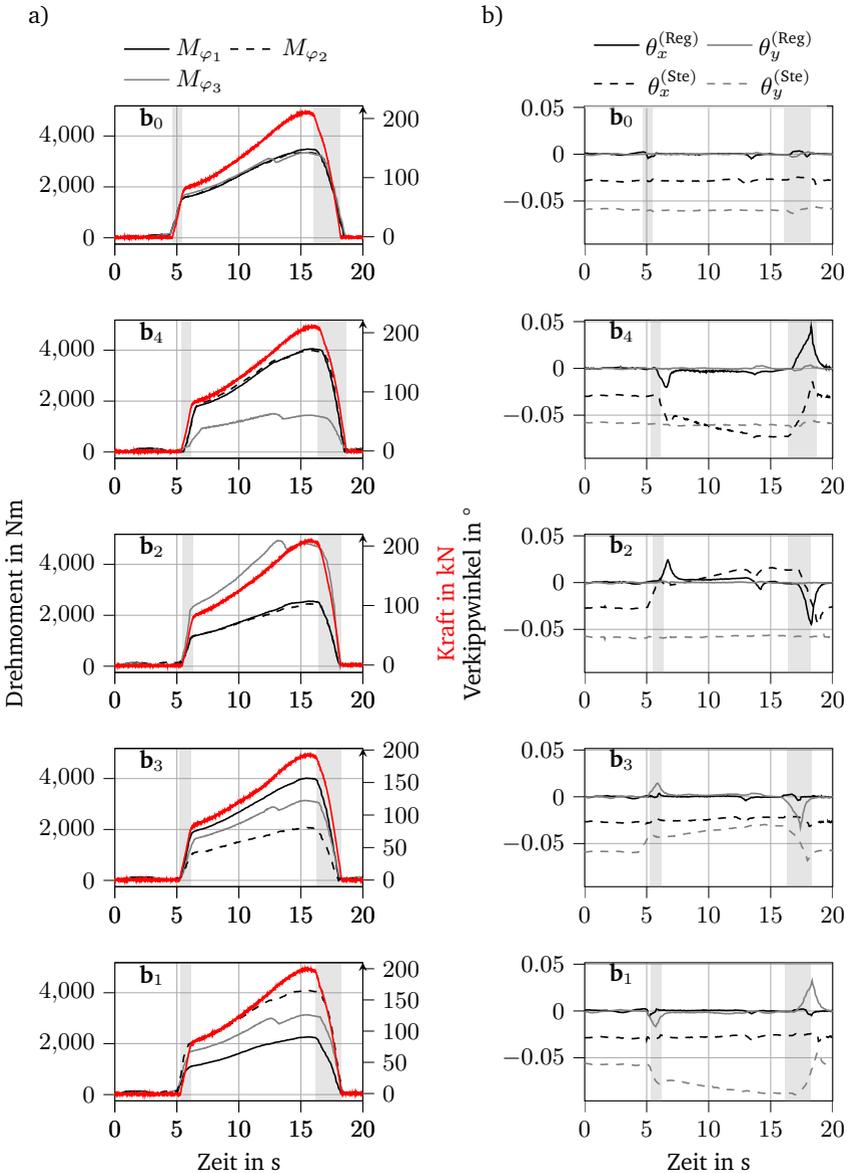


Abbildung 4.6.: a) Drehmomenten- und Kraftverläufe von Stauchversuchen für unterschiedliche Positionierungen  $b_i$  am Stößel und b) zugehörige Verkippwinkel gesteuerter und geregelter Versuche

---

Be- oder Entlastungen einzelner Motoren einher. Eine vordere Positionierung des Werkzeugs  $\mathbf{b}_4$  führt zu kürzeren Hebeln des ersten und zweiten Motors, wodurch diese Drehmomente von bis zu 3800 Nm aufbringen müssen. Demgegenüber führt der deutlich längere Hebel des dritten Motors auf ein reduziertes Drehmoment von 1500 Nm. Einen Extremfall stellt die Werkzeugpositionierung  $\mathbf{b}_2$  dar, da die Hebellänge für den dritten Motor unter allen Versuchen am geringsten ist. Daher weist  $M_{\varphi_3}$  für diesen Fall mit etwa 5000 Nm das höchste Drehmoment auf. Die Drehmomentenverläufe für die Positionen  $\mathbf{b}_1$  und  $\mathbf{b}_3$  zeigen substitutionale Verläufe des ersten und zweiten Antriebs auf, da die Hebelverhältnisse sich für die beiden Positionierungen umkehren.

Abbildung 4.6b) zeigt die entsprechenden Verkippungen um beide raumfesten Stößelachsen für geregelte und gesteuerte Versuche, die jeweils basierend auf den Messsignalen der Lineargebern an den Stößellagern durch den Stößelbeobachter  $\mathbf{x}_{st} = f_{\text{Reg}}(\hat{\mathbf{R}})$  aus Abbildung 4.4 berechnet werden. Zu erkennen ist, dass die durch Steuersignale hervorgerufenen Verkippungen initial um  $\theta_x^{(\text{Ste})} \approx 0.03^\circ$  und  $\theta_y^{(\text{Ste})} \approx 0.06^\circ$  verkippt sind, obwohl die Steuerung als Führungsgrößen  $\theta_{x,\text{soll}}^{(\text{Ste})} = 0.00^\circ$  und  $\theta_{y,\text{soll}}^{(\text{Ste})} = 0.00^\circ$  erhält. Dies lässt sich auf Abweichungen zwischen dem zur Berechnung der Ist-Werte herangezogenen, unsicherheitsbehafteten Starrkörpermodell der Presse und der realen Pressenkinematik zurückführen. Gleichzeitig ist ersichtlich, dass der Stauchprozess sich sichtbar auf die Verkippung des Stößels auswirkt. Bei mittlerer Positionierung der Probe treten nur geringfügig prozessinduzierte Verkippungen auf, da durch den zentralen Angriffspunkt der Prozesskraft keine Momente um die Mittelachsen des Stößels generiert werden. Bei außermittiger Positionierung des Werkzeugs werden die Effekte einer außermittigen Krafteinwirkung und insbesondere die Funktionalität der Regelung klar ersichtlich. Die vordere Platzierung  $\mathbf{b}_4$  bewirkt ein negatives Drehmoment um die x-Achse des Stößels (siehe Abbildung 4.5a)) und führt bei Krafteinwirkung im linear-elastischen Bereich zu negativen Stößelkippen um die x-Achse. Während die Steuerung die kraftinduzierte Verkippung nicht vollständig kompensiert und der Betrag des Verkippwinkels mit zunehmender Krafteinwirkung anwächst, kann die Regelung die Verkippung leicht zeitverzögert kompensieren. Mit zunehmender Kraft entsteht dabei keine zunehmende Regelabweichung. Erst bei Entlastung kommt es zu einer positiven Verkippung um die x-Achse, welche erneut nach kurzer Zeitverzögerung ausgeregelt wird. Ähnliche Verläufe für die Steuerung und Regelung, jedoch um unterschiedliche

Regeltyp	$\bar{d}$ in mm	$\bar{h}_1$ in mm	$\sigma(d)$ in mm	$\sigma(h_1)$ in mm
Steuerung	22.74	48.85	0.04	0.2
Regelung	23.96	47.52	0.01	0.22

Tabelle 4.2.: Stauchtiefen  $d$  und finale Probenhöhen  $h_1$  für gesteuerte und geregelte Stauchversuche

Kippachsen bzw. mit divergierenden Kipprichtungen, sind für die außermittigen Werkzeugpositionierungen  $\mathbf{b}_1$ ,  $\mathbf{b}_2$  und  $\mathbf{b}_3$  zu beobachten.

In Tabelle 4.2 sind die Mittelwerte ( $\bar{\cdot}$ ) und Standardabweichungen  $\sigma(\cdot)$  der Stauchtiefen  $d$  und dazugehörige Probenhöhen  $h_1$  für die jeweils 15 durchgeführten gesteuerten bzw. geregelten Versuche festgehalten. Wie erwartet führt die Regelung zu höheren Stauchtiefen  $d^{(\text{Reg})}$  und nähert sich der gewünschten Stauchtiefe von 24 mm mit einer durchschnittlichen Tiefe von 23.96 mm und dazugehöriger Standardabweichung von 0.01 mm mit hoher Genauigkeit an. Dagegen führen gesteuerte Versuche auf eine durchschnittliche Stauchtiefe von lediglich 22.74 mm, was in Einfederungen im Teilsystem Kniehebel und der Eliminierung von Lagerspiel begründet liegt. Gleichzeitig streut die Wiederholgenauigkeit der Stauchtiefe stärker als bei der Regelung, was sich in der erhöhten Standardabweichung von 0.04 mm widerspiegelt. Die unterschiedlichen Stauchtiefen wirken sich ebenfalls auf die per digitalem Messschieber vermessenen Probenhöhen aus. Die durchschnittliche Höhe der geregelten Proben beträgt 47.52 mm, wohingegen die Steuerung zu Proben mit einer durchschnittlichen Höhe von 48.85 mm führt. Die höhere Wiederholgenauigkeit im Hinblick auf die genauere Positionierung des Stößels spiegelt sich jedoch nicht in geringeren Streuungen der Höhen von geregelten Proben wider, was an den ähnlichen Standardabweichungen der jeweiligen Probenhöhen erkannt werden kann und möglicherweise in schwankenden Halbzeugeigenschaften begründet liegt.<sup>5</sup>

<sup>5</sup>Einblicke in die gemessenen Positionen der Stößellager sowie Geschwindigkeitsstellgrößen und realen Geschwindigkeiten der Antriebe für außermittige Stauchversuche sind Anhang A.3 zu entnehmen.

---

### 4.3. Optimierung der Positionsregelung mittels Gain-Scheduling

Die in [Hop21] vorgestellte und im Blockschaltbild aus Abbildung 4.4 dargestellte Positionsregelung der 3DSP nutzt Positionen und Orientierungen des Stößels als Führungsgrößen für den geschlossenen Regelkreis. Das Vorgehen erlaubt zwar eine gezielte Manipulation der zu regelnden Stößelfreiheitsgrade, führt jedoch Nachteile im Hinblick auf Recheneffizienz und systematische Auslegung der Verstärkungsfaktoren mit sich. Einerseits besteht erhöhter Modellierungs- und Rechenaufwand, der sich aus der Berechnung von differentieller IK zwischen Stößelpose und Antriebspositionen ergibt, andererseits ist die zur Regelung herangezogene DLS-Inverse der kombinierten Jakobimatrix der Teilsysteme Exzenter- und Stößelkinematik für die meisten Antriebsstellungen vollbesetzt. Einträge auf der Nebendiagonalen der Jakobimatrix  $(\hat{\mathbf{J}}_{\text{st}}\hat{\mathbf{J}}_{\varphi})_{ij}^+$  führen dazu, dass ein Antrieb mehrere Stößelfreiheitsgrade manipuliert und somit die Geschwindigkeiten der geregelten Freiheitsgrade eine Superposition unterschiedlicher Antriebsgeschwindigkeiten darstellen. Somit beziehen sich die Einträge der Diagonalmatrix mit den Verstärkungsfaktoren auf Regelabweichungen einzelner Stößelfreiheitsgrade, deren Priorität hinsichtlich dynamischer Eliminierung der Regelabweichung über eine manuelle Wahl der dazugehörigen Verstärkungsfaktoren  $\mathbf{K}_{i,i,p}$  festgelegt werden kann. [Hop21] Wünschenswert im Hinblick auf eine systematische Auslegung der Verstärkungsfaktoren ist es daher, Interdependenzen zwischen Antriebsgeschwindigkeiten und geregelten Freiheitsgraden zu minimieren und somit eine möglichst dünnbesetzte Jakobimatrix zur Regelung heranzuziehen.

Ein vielversprechender Ansatz dazu ist eine vorgeschaltete Transformation der Stößelfreiheitsgrade in Koordinaten der Stößellager  $\mathbf{R}_i$  über ein IK-Modell des Teilsystems Stößel. Dies birgt den Vorteil, dass kinematische Größen des Stößellagers  $\mathbf{R}_i$  ausschließlich von den Spindelantrieben  $\mathbf{q}_{\text{sp}}$  und dem entsprechenden Exzenterantrieb  $\varphi_i$  abhängig sind, was eine systematische Auslegung des Verstärkungsfaktors  $\mathbf{K}_{i,i,p}$  erheblich erleichtert und die Möglichkeit schafft, diesen unter Zuhilfenahme von Stabilitätskriterien zu variabilisieren, sodass  $\mathbf{K}_{i,i,p} = f(\mathbf{q}_{\text{sp}}, \varphi_i)$  gilt. In den folgenden Unterkapiteln wird die Herleitung analytischer Gleichungen zur Variabilisierung der Verstärkungsfaktoren mittels GS vorgestellt als auch simulativ erprobt. Eine experimentelle Validierung erfolgt am Beispiel eines Lochwalzprozesses [Kno20], bei dem neben Positionsregelgenauigkeiten ebenfalls die Effekte auf geometrische

---

Bauteileigenschaften untersucht werden.

### 4.3.1. Analytische Herleitung variabler Verstärkungsfaktoren

Die Realisierbarkeit des Ansatzes erfordert eine Invertierbarkeit der Vorwärtskinematik des Teilsystems Stößel. Unter der Annahme, dass sich der Stößelmittelpunkt bei Verkippen in der horizontalen Ebene nicht verschiebt, lassen sich die Stößelkoordinaten leicht in Stößellagerkoordinaten transformieren. Diese Annahme ist jedoch nicht gerechtfertigt, da nicht der Flächenschwerpunkt des durch die Stößellager aufgespannten Dreiecks sondern der erste Fermat-Punkt den Stößelmittelpunkt beschreibt (siehe [Hop21]). Nachteilig bei der vorwärtskinematischen Berechnung unter Nutzung des ersten Fermat-Punktes ist jedoch die nicht gegebene Invertierbarkeit, sodass unter Kenntnis der Stößelpose  $[\theta_x \ \theta_y \ z_{st}]^T$  nicht in Positionen der Stößellager  $\mathbf{R} = [R_{z,1} \ R_{z,2} \ R_{z,3}]^T$  umgerechnet werden kann. Dieses Problem wird umgangen, indem die vorgegebenen Kippwinkel  $\theta_x$  und  $\theta_y$  zur trigonometrischen Berechnung der horizontalen Verschiebung des Stößelmittelpunktes in x- und y-Richtung genutzt werden, sodass  $[x_{st} \ y_{st} \ z_{st}]^T$  vorliegt. Unter Kenntnis der bekannten Verkippenwinkel wird anschließend eine dreidimensionale Ebenengleichung definiert, deren Schnittpunkte mit den Hochachsen der linear geführten Stößelanlenkstangen die Positionen der Stößellager  $\mathbf{R}_i$  liefern. Die angewandte Ebenengleichung liefert jedoch keine exakte, analytische Lösung der IK. Berechnete Positionen der Stößellager führen bei erneuter Einspeisung in das Vorwärtskinematikmodell zu Abweichungen in der z-Koordinate des Stößelmittelpunktes. Entstehende Residuen sind für alle realisierbaren Kombinationen aus Nick- und Rollwinkel in Abbildung 4.7a) dargestellt. So führen insbesondere hohe Nickwinkel zu betragsmäßigen Abweichungen von bis zu knapp zwei Millimetern, die in Anbetracht von hohen Anforderungen an die Genauigkeit der Stößelführung einer Kompensation bedürfen.

Als geeignetes Instrument zur Kompensation dieser Abweichungen wird ein einschichtiges NN mit 100 Neuronen und Tangens hyperbolicus Aktivierungsfunktionen angesehen, das unter Kenntnis der beiden Kippwinkel die entsprechende Abweichung der z-Koordinate des Stößelmittelpunktes prädiziert. Mithilfe dieser Prädiktion werden anschließend die Positionswerte aller Stößellager korrigiert, was

a) unkompensierte Residualverteilung    b) kompenzierte Residualverteilung

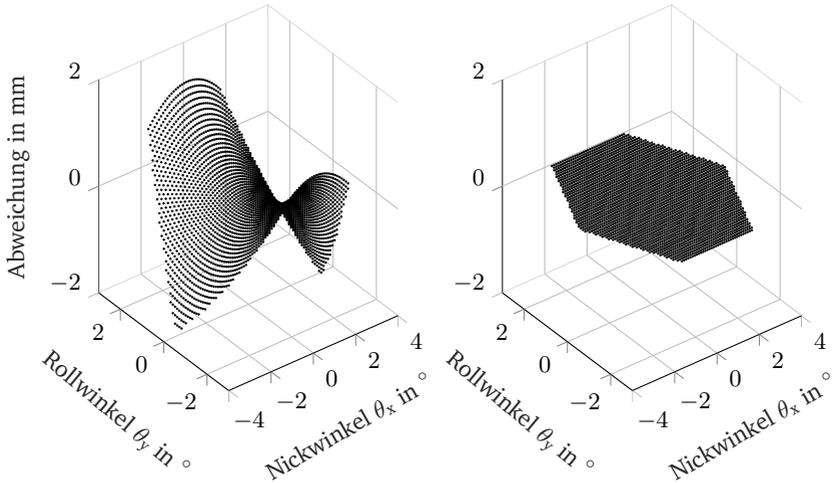


Abbildung 4.7.: Residualverteilung der angenäherten IK des Teilsystems Stößel a) ohne Kompensation und b) mit Kompensation eines zweischichtigen NN

auf die Residualverteilung in Abbildung 4.7b) und eine maximale Abweichung von einem Mikrometer führt. Die Güte der Kompensation führt somit auf betragsmäßig maximale Abweichungen, die geringer als die Sensorauflösung ausfallen, womit eine ausreichend genaue Annäherung der IK des Teilsystems Stößel vorliegt.

Sind die erforderlichen Positionen der Stößellager zur Herbeiführung beliebiger Stößelposen bekannt, kann eine Regelung im Stößellageraum erfolgen, sodass eine vollständig voneinander entkoppelte Transformation von Regelabweichungen in Stellgrößen für die drei Exzentertriebe ermöglicht wird. Abbildung 4.8 stellt einen Regelansatz vor, bei dem das approximierte IK-Modell des Stößels zur Umwandlung der Führungsgrößen in den Stößellageraum genutzt wird. Auf eine Abbildung der Totpunktregelung mit entsprechender Kompensation und Vorsteuerung wird verzichtet, da diese sich analog zum Blockschaltbild in Abbildung 4.8 ergeben. Unmittelbar werden die Vorteile einer solchen Regelung ersichtlich. Einerseits kann auf einen Stößelbeobachter in der Rückführung des Regelkreises verzichtet werden, andererseits handelt es sich bei der DLS-Inversen Jakobimatrix  $\hat{J}_\varphi^+$  um eine Diagonalmatrix,

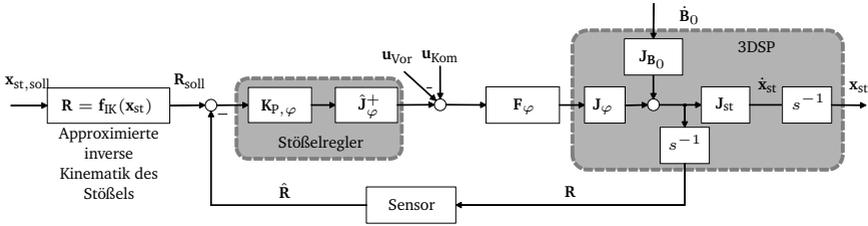


Abbildung 4.8.: Blockschaltbild der optimierten Positionsregelung der 3D Servo Presse im Stoßellagerraum

deren Diagonaleinträge  $\hat{J}_{\varphi,ii}^+$  die gedämpfte Geschwindigkeitsübersetzung zwischen Exzenterantrieb  $\varphi_i$  und Stoßellager  $R_i$  quantifizieren. Nebeneinträge außerhalb der Hauptdiagonalen  $\hat{J}_{\varphi,ij|i \neq j}^+$  beinhalten dabei stets Nullwerte, da kein Geschwindigkeitseinfluss zwischen dem  $i$ -ten Exzenterantrieb und dem  $j$ -ten Stoßellager für  $i \neq j$  besteht. Diese Eigenschaft wird im Folgenden genutzt, um die Positionsregelung des  $i$ -ten Stoßellagers anhand von linearen Stabilitätskriterien in beliebigen Arbeitspunkten auszulegen.

Im ersten Schritt muss dazu die Übertragungsfunktion des geschlossenen Regelkreises aufgestellt werden. Diese ergibt sich mit dem Blockschaltbild aus Abbildung 4.8 zu

$$\mathbf{F}_i(s) = \frac{\mathbf{R}_{i,ist}(s)}{\mathbf{R}_{i,soll}(s)} = \frac{\mathbf{F}_{i,R} \cdot \mathbf{F}_{i,\varphi}(s) \cdot \mathbf{J}_{ii,\varphi} \cdot s^{-1}}{1 + \mathbf{F}_{i,R} \cdot \mathbf{F}_{i,\varphi}(s) \cdot \mathbf{J}_{ii,\varphi} \cdot s^{-1}}, \quad (4.7)$$

wobei  $\mathbf{F}_{i,R} = \mathbf{K}_{ii,P,\varphi} \cdot \hat{\mathbf{J}}_{ii,\varphi}^+$  die Übertragungsfunktion des im Arbeitspunkt linearisierten P-Reglers und  $\mathbf{F}_{i,\varphi}(s) = \frac{1}{\tau_i \cdot s + 1}$  die Übertragungsfunktion der Antriebe sind, deren Verhalten nach [HPG19] als zeitverzögertes Glied erster Ordnung angenommen werden kann und durch die Zeitkonstante  $\tau_i$  charakterisiert wird. Ein Einsetzen beider Gleichungen in Formel 4.7 und eine Umstellung der Formel in die Übertragungsfunktion eines klassischen PT2-Gliedes führen auf

$$\mathbf{F}_i(s) = \frac{\mathbf{R}_{i,ist}(s)}{\mathbf{R}_{i,soll}(s)} = \frac{\mathbf{K}_{ii,P,\varphi} \cdot \hat{\mathbf{J}}_{ii,\varphi}^+ \cdot \mathbf{J}_{ii,\varphi}}{\tau_i \cdot s^2 + s + \mathbf{K}_{ii,P,\varphi} \cdot \hat{\mathbf{J}}_{ii,\varphi}^+ \cdot \mathbf{J}_{ii,\varphi}}. \quad (4.8)$$

Eine Stabilitätsanalyse und eine Prüfung des Regelverhaltens auf Schwingungsfähigkeit erfolgt durch Nullsetzen des charakteristischen Nennerpolynoms

$$\mathcal{N}(\mathbf{F}_i(s)) = \tau_i \cdot s^2 + s + \mathbf{K}_{ii,P,\varphi} \cdot \hat{\mathbf{J}}_{ii,\varphi}^+ \cdot \mathbf{J}_{ii,\varphi} \stackrel{!}{=} 0, \quad (4.9)$$

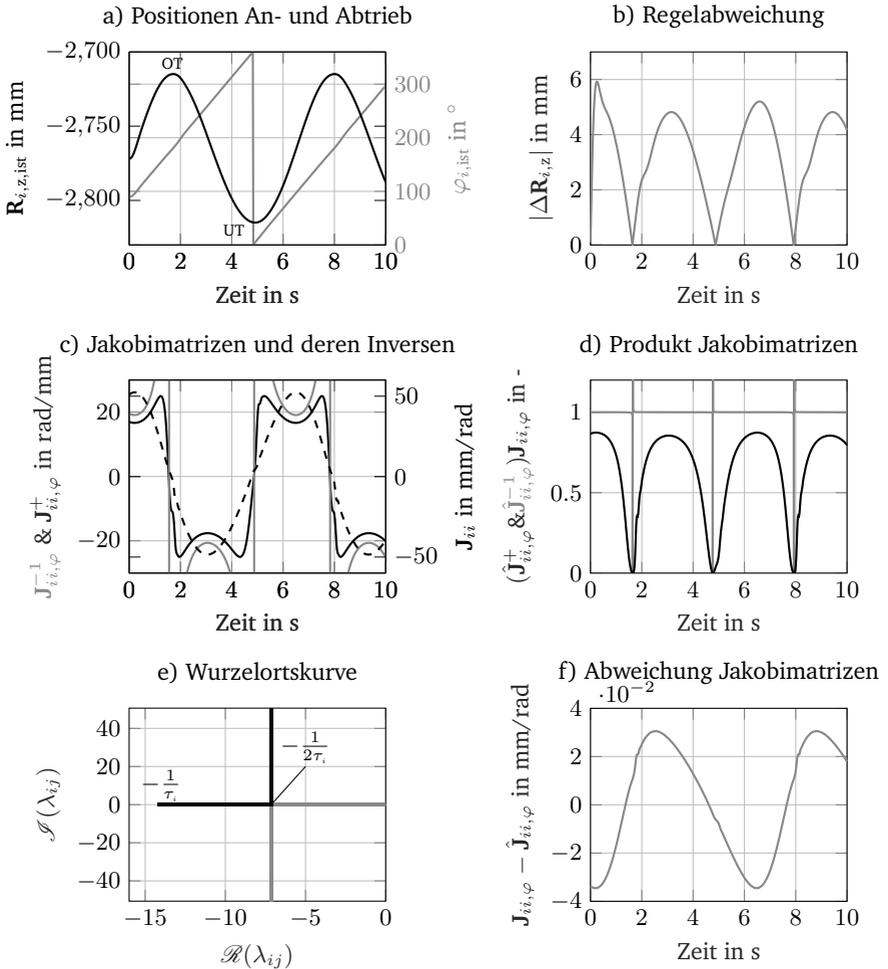


Abbildung 4.9.: Simulatives Verhalten der Stoßellagerregelung für konstant gewählten Verstärkungsfaktor  $K_{ii,P,\varphi} = 10$

wodurch die beiden Pole  $\lambda_{ij}$  der Übertragungsfunktion berechnet werden. Diese ergeben sich zu

$$\lambda_{ij} = -\frac{1}{2\tau_i} \pm \sqrt{\frac{1}{4\tau_i^2} - \frac{\mathbf{K}_{ii,P,\varphi} \cdot \hat{\mathbf{J}}_{ii,\varphi}^+ \cdot \mathbf{J}_{ii,\varphi}}{\tau_i}} \quad (4.10)$$

und geben Aufschlüsse über die Stabilität und Schwingungsfähigkeit des Regelkreises.

### 4.3.2. Erprobung der Regelung in simulativer Umgebung

Zur Ermittlung von Reglereigenschaften wird der Regelkreis in der Simulationsumgebung Matlab/Simulink untersucht. Um Unsicherheit im Streckenverhalten nachzubilden, wird die in der Strecke genutzte Jakobimatrix  $\mathbf{J}_\varphi$  basierend auf einem Starrkörpermodell berechnet, dessen Modellparameter, wie etwa Längen der Getriebebauteile oder Winkelstellungen zueinander, von den Fertigungsangaben leicht abweichen, jedoch noch innerhalb derer Toleranzen liegen. Somit ergeben sich, wie in Abbildung 4.9f) zu sehen, geringfügige Abweichungen zwischen der im Regler genutzten Jakobimatrix  $\hat{\mathbf{J}}_{ii,\varphi}$  und jener in der Strecke  $\mathbf{J}_{ii,\varphi}$ . Als Führungsgrößen für die Regelung wird eine oszillierende Position des Stößellagers vorgegeben, bei dem OT und UT nach etwa 1.5 bzw. 4.8 s erreicht werden sollen (siehe Abbildung 4.9a). Im Idealfall führt dies auf eine konstante Exzentergeschwindigkeit von 1 rad/s. Bei Anwendung der Regelung kommt es nach 4.9 b) jedoch zu Regelabweichungen, die nach Durchlaufen der Totpunkte Extremwerte von knapp 6 mm annehmen. Dies lässt sich auf eine fehlende Manipulierbarkeit der Stößellagergeschwindigkeiten und dem Auftreten von Grenzstabilitäten in Singularitäten zurückführen. Zieht man Formel 4.10 heran und analysiert die Lage der beiden Pole in den singularären Konfigurationen, ergibt sich

$$\lim_{\mathbf{J}_{ii,\varphi} \rightarrow 0} \begin{bmatrix} \lambda_{i1} \\ \lambda_{i2} \end{bmatrix} = \lim_{\mathbf{J}_{ii,\varphi} \rightarrow 0} -\frac{1}{2\tau_i} \pm \sqrt{\underbrace{\frac{1}{4\tau_i^2} - \frac{\mathbf{K}_{ii,P,\varphi} \cdot \hat{\mathbf{J}}_{ii,\varphi} \cdot \mathbf{J}_{ii,\varphi}}{(\hat{\mathbf{J}}_{ii,\varphi}^2 + \lambda_{\text{DLS}}^2) \cdot \tau_i}}_{w_i}} = \begin{bmatrix} 0 \\ -\frac{1}{\tau_i} \end{bmatrix}. \quad (4.11)$$

Die in Formel 4.11 durchgeführte Grenzwertbetrachtung erklärt ebenfalls, warum die Nutzung einer unregularisierten Jakobimatrix unter Nichtberücksichtigung des

Dämpfungs-faktors  $\lambda_{\text{DLS}}$  zu Instabilitäten in den Totpunkten (siehe [HPG19]) führt. Abbildung 4.9d) zeigt die Verläufe der Produkte von geschätzter inverser Jakobimatrix  $\hat{\mathbf{J}}_{ii,\varphi}^{-1} \cdot \mathbf{J}_{ii,\varphi}$  und geschätzter DLS-Jakobimatrix  $\hat{\mathbf{J}}_{ii,\varphi}^+ \cdot \mathbf{J}_{ii,\varphi}$  mit der in der Strecke modellierten Jakobimatrix. Ersichtlich wird, dass das Produkt aus invertierter und regulärer Jakobimatrix in den Singularitäten theoretisch unendlich hohe Werte annimmt. Dies liegt an den eingebrachten Imperfektionen in der Jakobimatrix der Strecke, die dazu führen, dass die Totpunkte von geschätzter und in der Strecke genutzter Jakobimatrix nicht zusammenfallen, wodurch es in singulären Konfigurationen der geschätzten Jakobimatrix zu einer Division durch Nullwerte kommt.

Eine Grenzwertbetrachtung  $\lim_{\hat{\mathbf{J}}_{ii,\varphi} \rightarrow 0} \begin{bmatrix} \lambda_{i1} & \lambda_{i2} \end{bmatrix}^T$  wie in Formel 4.11 für die unregularisierte Jakobimatrix führt demnach auf Pollagen von

$$\lim_{\hat{\mathbf{J}}_{ii,\varphi} \rightarrow 0} -\frac{1}{2\tau_i} \pm \sqrt{\frac{1}{4\tau_i^2} - \frac{\mathbf{K}_{ii,\text{P},\varphi} \cdot \mathbf{J}_{ii,\varphi}}{\hat{\mathbf{J}}_{ii,\varphi} \cdot \tau_i}} = \begin{cases} \begin{bmatrix} \infty \\ -\infty \end{bmatrix}, & \text{wenn } \mathbf{J}_{ii,\varphi} > 0 \\ -\frac{1}{2\tau_i} + j \begin{bmatrix} \infty \\ -\infty \end{bmatrix}, & \text{wenn } \mathbf{J}_{ii,\varphi} < 0 \end{cases} \quad (4.12)$$

und regt starke Schwingungen in der Maschine an [ES2]. Dieses Problem wird durch die DLS-Inverse der Jakobimatrix umgangen, da das Produkt  $\hat{\mathbf{J}}_{ii,\varphi}^+ \cdot \mathbf{J}_{ii,\varphi}$  in der Nähe der Totpunkte gedämpft wird und somit der Einfluss des Stößelreglers auf die Stellgrößen der Antriebe stark begrenzt wird. Mithilfe der Grenzwertbetrachtung lässt sich ebenfalls der Verlauf der Wurzelortskurve in Abbildung 4.9e) erklären. Während in Totpunktbereichen für den Wurzelterm  $w_i$  aus Formel 4.11 zwangsläufig  $\lim_{\hat{\mathbf{J}}_{ii,\varphi} \rightarrow 0} \sqrt{w_i} = -\frac{1}{2\tau_i}$  gilt und damit die Realteile der Pole  $\mathcal{R}(\lambda_{ij})$  gegen  $\begin{bmatrix} 0 & -\frac{1}{\tau_i} \end{bmatrix}^T$  streben, kann der Verstärkungsfaktor  $\mathbf{K}_{ii,\text{P},\varphi}$  zwischen den Totpunkten so gewählt werden, dass die Pole aufeinander zulaufen und an der Grenze zu schwingungsfähigem Verhalten platziert werden, sodass  $\mathcal{R}(\lambda_{ij}) = \begin{bmatrix} -\frac{1}{2\tau_i} & -\frac{1}{2\tau_i} \end{bmatrix}^T$  gilt. Eine zu hohe Wahl des Verstärkungsfaktors führt auf negative Werte für den Ausdruck unter der Wurzel  $w_i < 0$ , sodass die Pole mit Realteilen von  $\mathcal{R}(\lambda_{ij}) = \begin{bmatrix} -\frac{1}{2\tau_i} & -\frac{1}{2\tau_i} \end{bmatrix}^T$  einen Imaginärteil erhalten und konjugiert komplex auseinander gehen. Die simulativen Untersuchungen der Stößel-lagerregelung und das Aufstellen der analytischen Funktion zur Visualisierung der Wurzelortskurve führen auf die zentralen Erkenntnisse, dass die Einführung einer regularisierten DLS-Inverse in das Regelgesetz Instabilitäten vorbeugt und diese in grenzstabile Zustände in Totpunktregionen umwandelt.

Gleichzeitig erlaubt eine geschickte Auslegung des Verstärkungsfaktors  $\mathbf{K}_{ii,\text{P},\varphi}$  eine

Polplatzierung in der linken Halbebene der Wurzelortskurve und kann über weite Wertebereiche der Jakobimatrizen die Lage der Pole derart manipulieren, dass höchstmögliche Stabilitätsreserven sichergestellt werden und gleichzeitig schwingungsfähiges Verhalten vermieden wird.

Anhand von Formel 4.11 ist zu erkennen, dass der Verstärkungsfaktor der Regelung so adaptiert werden kann, dass die Pole mit möglichst hoher Stabilitätsreserve an der Grenze zur Schwingungsfähigkeit platziert werden können. Dies geht mit einer Dynamiksteigerung der Regelung einher und wird erreicht, indem  $w_i \stackrel{!}{=} 0$  gesetzt wird. Diese Bedingung führt nach Umstellung von  $w_i$  nach  $\mathbf{K}_{ii,P,\varphi}$ <sup>6</sup> zu

$$\mathbf{K}_{ii,P,\varphi|w_i \stackrel{!}{=} 0} = \frac{(\hat{\mathbf{J}}_{ii,\varphi}^2 + \lambda_{\text{DLS}}^2)}{4\tau_i \cdot \hat{\mathbf{J}}_{ii,\varphi}^2} \quad (4.13)$$

und begegnet der gleichen Problematik wie die Polstellen aus der Grenzwertbetrachtung in Formel 4.12. Eine Annäherung der Antriebsstellungen an singuläre Konfigurationen führt wiederum auf  $\lim_{\hat{\mathbf{J}}_{ii,\varphi} \rightarrow 0} \mathbf{K}_{ii,P,\varphi|w_i \stackrel{!}{=} 0} = \infty$ , woraus sich die Notwendigkeit einer zusätzlichen Regularisierung des Verstärkungsfaktors ergibt. An dieser Stelle wird eine Fallunterscheidung eingeführt, bei der der Verstärkungsfaktor bei ausreichender Manipulierbarkeit des Stoßellagers ( $|\hat{\mathbf{J}}_{ii,\varphi}| \geq \hat{J}_{\text{Grenz},\varphi}$ ) aus Nullsetzen des Wurzelterms  $w_i$  für ein nichtrobustes Regelgesetz und bei mangelhafter Manipulierbarkeit ( $|\hat{\mathbf{J}}_{ii,\varphi}| < \hat{J}_{\text{Grenz},\varphi}$ ) aus der regularisierten Berechnungsvariante aus Formel 4.13 abgeleitet wird. Dies führt letztendlich auf

$$\mathbf{K}_{ii,P,\varphi|w_i \stackrel{!}{=} 0} = \begin{cases} \frac{1}{4\tau_i} \left( 1 + \frac{\lambda_{\text{DLS}}^2}{\hat{\mathbf{J}}_{ii,\varphi}^2} \right) & \text{wenn } |\hat{\mathbf{J}}_{ii,\varphi}| \geq \hat{J}_{\text{Grenz},\varphi} \\ \frac{\hat{\mathbf{J}}_{ii,\varphi}^2 \cdot (\hat{\mathbf{J}}_{ii,\varphi}^2 + \lambda_{\text{DLS}}^2)}{4\tau_i \cdot (\hat{\mathbf{J}}_{ii,\varphi}^4 + 2 \cdot \hat{\mathbf{J}}_{ii,\varphi}^2 \cdot \lambda_{\text{Kp}}^2 + \lambda_{\text{Kp}}^4)} & \text{wenn } |\hat{\mathbf{J}}_{ii,\varphi}| < \hat{J}_{\text{Grenz},\varphi} \end{cases}, \quad (4.14)$$

wobei  $\lambda_{\text{Kp}}$  den für die Dämpfung des Verstärkungsfaktors vorgesehenen Regularisierungsfaktor darstellt.

Abbildung 4.10 stellt unterschiedliche Größen der simulativen Untersuchungen mit dem adaptiven Verstärkungsfaktor dar. In 4.10a) ist die Führungs- und Regelgröße der Regelung eines Stoßellagers dargestellt. Die Regelgröße folgt der Führungsgröße mit hoher Genauigkeit, maximale Regelabweichungen (siehe 4.10b) von knapp 4

<sup>6</sup>Zwar wird in Formel 4.11 die Jakobimatrix der Strecke  $\mathbf{J}_{ii,\varphi}$  genutzt, diese steht zur Auslegung der Regelübertragungsfunktion jedoch nicht zur Verfügung. Aus diesem Grund wird diese durch die geschätzte Jakobimatrix  $\hat{\mathbf{J}}_{ii,\varphi}$  ersetzt.

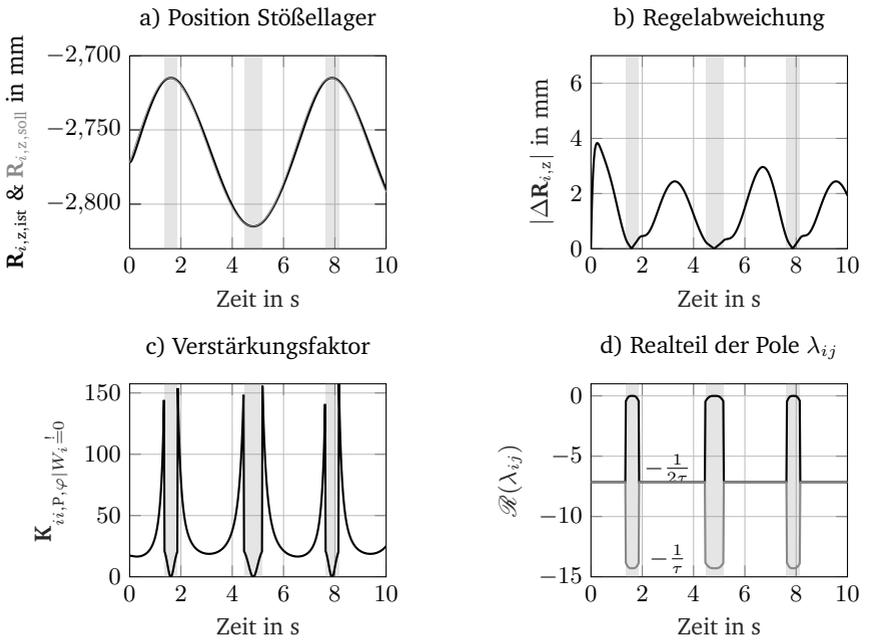


Abbildung 4.10.: Simulatives Verhalten der Stößellagerregelung für den adaptiven Verstärkungsfaktor  $K_{ii,P,\varphi|W_i \neq 0}$  gemäß Formel 4.14

---

mm sind zu verzeichnen, womit deutliche Verbesserungen im Vergleich zu den Simulationen mit konstantem Verstärkungsfaktor (siehe 4.9b) erzielt werden. Abbildung 4.10c) zeigt den Zeitverlauf des Verstärkungsfaktors  $K_{ii,P,\varphi|w_i \stackrel{!}{=} 0}$  auf. Die grau eingefärbten Bereiche stellen jene Zeitintervalle dar, in denen der regularisierte Verstärkungsfaktor aufgrund einer Unterschreitung der Manipulierbarkeit zur Regelung genutzt wird. Dabei ist zu sehen, dass in weiten Teilen der Regelung der adaptive, auf nichtrobustem Regelgesetz ausgelegte Verstärkungsfaktor zum Einsatz kommt, der mit Annäherung an grau eingefärbte Bereiche und damit mit abnehmender Manipulierbarkeit gegen unendlich strebt. Wird die Manipulierbarkeitsgrenze unterschritten, wird der Verstärkungsfaktor stark gedämpft und nimmt in Singularitäten Nullwerte an. Dass der adaptive Verstärkungsfaktor zum gewünschten Verhalten führt, ist Abbildung 4.10d) zu entnehmen. Die Pollagen liegen stets an der Grenze zum Überschwingen bei  $-(2\tau_i)^{-1}$  und führen keine Imaginärteile mit sich. Eine Trennung der Realteile erfolgt ausschließlich unter Nutzung des regularisierten Verstärkungsfaktors.<sup>7</sup>

### 4.3.3. Experimentelle Validierung im Lochwalzprozess

Nachdem in simulativer Umgebung die Überlegenheit einer entkoppelten Stößel-lagerregelung mit adaptiven Verstärkungsfaktoren demonstriert werden konnte, erfolgt eine experimentelle Validierung des Regelgesetzes. Dazu wird das in der Simulation entworfene Regelgesetz mitsamt des entworfenen NN mithilfe der *Simulink PLC Coder* Toolbox [Mat22] in IEC 61131-3 normkonformen Steuerungscode kompiliert, der anschließend auf die speicherprogrammierbare Steuerung (SPS) der 3DSP aufgespielt wird. Neben regelungstechnischen Performanzkriterien von Regelgesetzen sind für die Bewertung produktionstechnischer Prozesse die Geometrien resultierender Bauteile eine wichtige Kenngröße, die Aufschlüsse über die Regelgüte liefern. Aus diesem Grund werden am Beispiel eines Lochwalzprozesses Proben mit unterschiedlichen Regelgesetzen gefertigt und anschließend deren Geometrie miteinander verglichen.

---

<sup>7</sup>Ein simulativer Vergleich zwischen der in Kapitel 4.2 vorgestellten Positionsregelung mit konstanten Verstärkungsfaktoren und der im vorliegenden Kapitel vorgestellten, adaptiven Regelung ist in Anhang A.4 abgebildet.

Der Prozess wird wie in Abbildung 4.11 dargestellt auf der Forschungsversion der

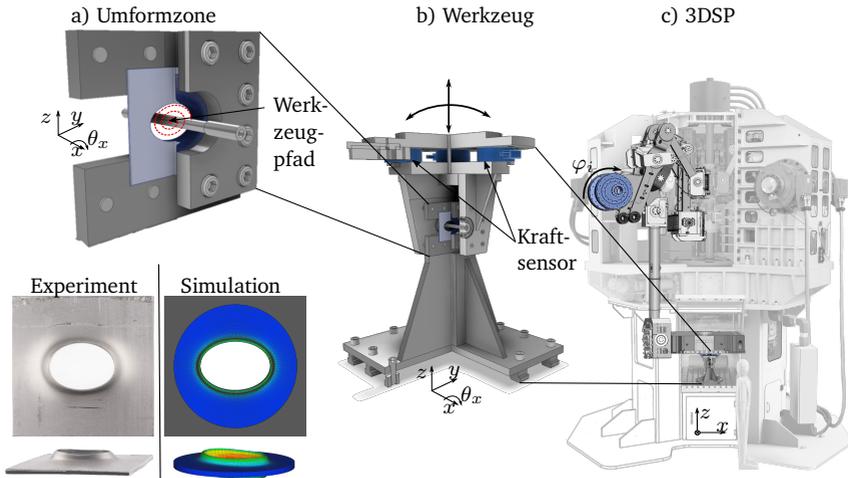


Abbildung 4.11.: Versuchsaufbau bestehend aus a) Umformzone mit eingespanntem Blech, b) Lochwalzwerkzeug und c) Forschungsversion der 3DSP mit integriertem Lochwalzwerkzeug

3DSP durchgeführt und greift auf ein speziell für die Presse konstruiertes Lochwalzwerkzeug zurück. Ziel der Anwendung ist das Abfahren eines vorgegebenen Werkzeugpfades mit der Walze des Werkzeugs. Der Werkzeugpfad ist schematisch in Abbildung 4.11a) als rot gestrichelte Linie angedeutet. Durch eine Überlagerung einer vertikalen Bewegung in z-Richtung und einer Verkipfung  $\theta_x$  erfolgt eine Aufweitung des Loches, das vor dem Prozess einen Durchmesser von 14,1 mm aufweist. Durch die flexible Parametrisierung des Werkzeugpfades ist es möglich, sowohl kreisrunde als auch Freiformgeometrien wie etwa elliptische Löcher in das Blech einzubringen, wodurch die Regelgüte untersuchter Regelgesetze bei multiplen Geometrien untersucht werden kann.

Abbildung 4.12 zeigt die parametrisierten Geometrien der lochgewalzten Bauteile und ein dazugehöriges Vorgehen zur Bestimmung des Pfades des Walzenmittelpunktes. Die finalen Lochgeometrien werden dabei über die Radien der kleinen und großen Ellipsenhalbachse  $r_a$  und  $r_b$  parametrisiert, sodass die y- und z-Koordinaten

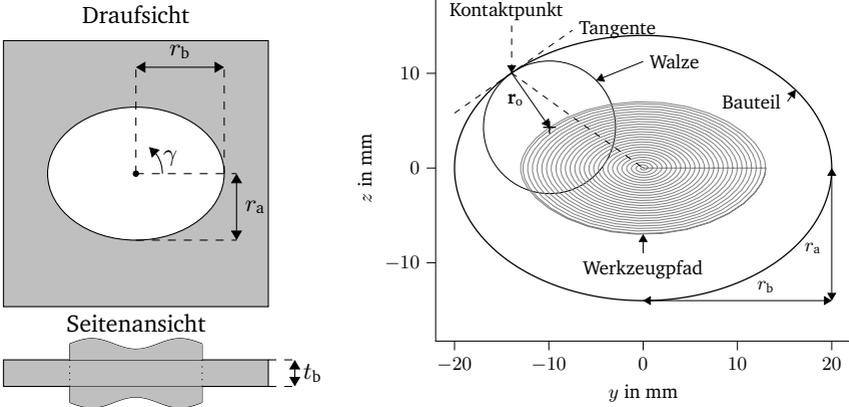


Abbildung 4.12.: Darstellung der Geometrie elliptisch lochgewalzter Bauteile (links) und Vorgehen zur Planung des Pfades des Walzenmittelpunktes (rechts)

der gewünschten Lochgeometrie über

$$\begin{bmatrix} y \\ z \end{bmatrix} = \begin{bmatrix} r_b \cdot \cos(\gamma) \\ r_a \cdot \sin(\gamma) \end{bmatrix} \quad (4.15)$$

berechenbar sind. Um die einzelnen Punkte des Walzenpfades zu berechnen, werden die Tangenten der Kontaktpunkte zwischen Walze und Blech berechnet, deren orthogonale Einheitsvektoren  $\mathbf{r}_o$

$$\mathbf{r}_o = \begin{bmatrix} y_o \\ z_o \end{bmatrix} = \frac{1}{\sqrt{(\cos(\gamma) \cdot r_b)^2 + (\sin(\gamma) \cdot r_a)^2}} \begin{bmatrix} \cos(\gamma) \cdot r_b \\ \sin(\gamma) \cdot r_a \end{bmatrix} \quad (4.16)$$

mit dem Walzendurchmesser multipliziert werden können und, wie in Abbildung 4.12 veranschaulicht, auf die mit einem schwarzen Kreuz markierte Lage des Walzenmittelpunktes führen. Der Walzenpfad ergibt sich durch eine iterative Berechnung des Kontaktpunktes bei umlaufenden Winkel  $\gamma$  und einem radialen Vorschub von 0.5 mm pro Umdrehung bezüglich der großen Ellipsenhalbachse  $r_b$ . Die Geschwindigkeit wird zu  $2 \text{ s/U}$  gewählt und lediglich zu Prozessbeginn aufgrund eines hohen Verhältnisses von Tangential- zu Radialgeschwindigkeit gedrosselt. Unter Kenntnis der Koordinaten des berechneten Walzenpfades können die entsprechenden Stößel-

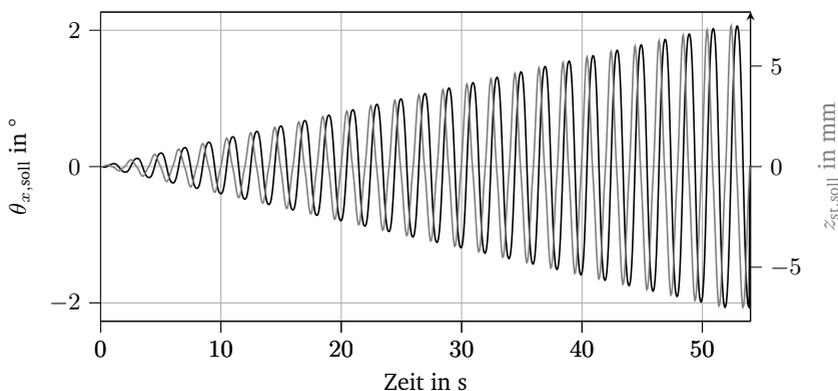


Abbildung 4.13.: Führungsgrößen des Positionsregelkreises der 3DSP zur Herstellung elliptischer Lochwalzproben mit  $r_a = 14$  mm und  $r_b = 20$  mm

posen über ein inverses Starrkörpermodell des Oberwerkzeugs berechnet werden, was für  $r_a = 14$  mm und  $r_b = 20$  mm auf die in Abbildung 4.13 visualisierten Führungsgrößen für den Positionsregelkreis der Maschine führt. Die Führungsgröße  $\theta_{y,soll}$  ist über die gesamte Prozessdauer auf 0 gesetzt, da der Prozess keine Verkipfung um die y-Achse des Stößels erfordert. In den Experimenten finden Blechproben aus dem Werkstoff DC04 mit einer Blechdicke von  $t_b = 3$  mm Verwendung.

Im Folgenden werden die Ergebnisse von drei Regelgesetzen miteinander verglichen, wobei für jedes Regelgesetz jeweils eine Probe mit großen Halbachsenradien von  $r_b \in [14 \ 16 \ 18 \ 20]$  mm und einem gleichbleibendem kleinen Halbachsenradius von  $r_a = 14$  mm gefertigt werden. Die Regelgesetze werden nach Tabelle 4.3 im Folgenden als *Robust*, *Ungedämpft* und *Adaptiv* bezeichnet, wobei *Robust* und *Ungedämpft* Regelgesetze darstellen, die die Stößelpose mit konstanten Verstärkungsfaktoren und einer gedämpften (*Robust*,  $\lambda_{DLS} > 0$ ) bzw. ungedämpften (*Ungedämpft*,  $\lambda_{DLS} = 0$ ) inversen Jakobimatrix nach Formel 4.1 regeln. Das Regelgesetz *Adaptiv* greift auf das Prinzip des GS zurück. Dieses regelt die einzelnen Stößellager durch inverse Transformation der Stößelpose in Stößellagerpositionen und passt die proportionalen Verstärkungsfaktoren gemäß Formel 4.14 an die linearisierten Arbeitspunkte an. Nach der Versuchsdurchführung werden alle Proben durch einen optischen 3D-Laser-Scanner der Firma *Hexagon AB (Absolute Arm 8525-7)* vermes-

Bezeichnung	Verstärkung $\mathbf{K}_{i,P,\varphi}$	Dämpfung	Kapitel
Robust	$\begin{bmatrix} k_{P,\theta_x} & k_{P,\theta_y} & k_{P,z} \\ 2 & 2 & 2 \end{bmatrix} =$	$\lambda_{DLS} = 0,03$	4.2
Ungedämpft	$\begin{bmatrix} k_{P,\theta_x} & k_{P,\theta_y} & k_{P,z} \\ 2 & 2 & 2 \end{bmatrix} =$	$\lambda_{DLS} = 0$	4.2
Adaptiv	Gemäß Formel 4.14	$\lambda_{DLS} = 0,03; \hat{j}_{Grenz,\varphi} = 7,5 \text{ mm/s}; \lambda_{Kp} = 0.03$	4.3

Tabelle 4.3.: Übersicht über Parameter der drei verglichenen Regelgesetze

sen.<sup>8</sup> Die aufgenommenen 3D-Punktewolken werden als *stl*-Datei abgespeichert und anschließend in der Programmiersprache *Python* mithilfe der *trimesh*-Bibliothek eingelesen und in das *Numpy*-Datenformat transformiert. Das weitere Vorgehen ist in Abbildung 4.14 visualisiert. Die in Abbildung 4.14b) gezeigte Draufsicht dient als Grundlage für die Anwendung eines Fitting-Ansatzes, bei dem eine ellipsenähnliche Funktion der Form

$$\mathbf{a}_1 \cdot z^2 + \mathbf{a}_2 \cdot zy + \mathbf{a}_3 \cdot y^2 + \mathbf{a}_4 \cdot z + \mathbf{a}_5 \cdot y = 1 \quad (4.17)$$

an die innere Lochkontur des Bauteils gefittet wird, wobei die Parameter  $\mathbf{a}_i$  nach dem Prinzip der kleinsten Fehlerquadrate an die Datenpunkte angepasst werden. Dies führt auf die in Abbildung 4.14(d) rot dargestellte Ellipse. Gleichzeitig wird der Radiusverlauf über den umlaufenden Winkel  $\gamma$  durch eine Polynomfunktion gefittet, was auf die rote Kurve in Abbildung 4.14e) führt.

Tabelle 4.4 gibt Aufschluss über die mittleren und maximalen betragsmäßigen Regelabweichungen der im Lochwalzprozess geregelten Stößelfreiheitsgrade für die untersuchten Regelgesetze. Es ist ersichtlich, dass eine Adaption der Verstärkungsfaktoren für alle erfassten Performanzkriterien auf die niedrigsten Regelabweichungen führt. Die Regelabweichungen zwischen robuster und ungedämpfter Positionsregelung sind für die vertikale Translation des Stößels ( $z_{st}$ ) vergleichbar, jedoch sind signifikant höhere Regelabweichungen des Verkippfreiheitsgrades  $\theta_x$  unter Verwendung der robusten Regelung zu verzeichnen. Dies lässt sich durch den Umstand erklären, dass Verkippungen zwangsläufig mit einer Annäherung mindestens eines Stößellagers an die Totpunkte der Maschine einhergehen. Infolge niedrigerer

<sup>8</sup>Nähere Informationen über das Messgerät sind dem Anhang A.6 zu entnehmen.

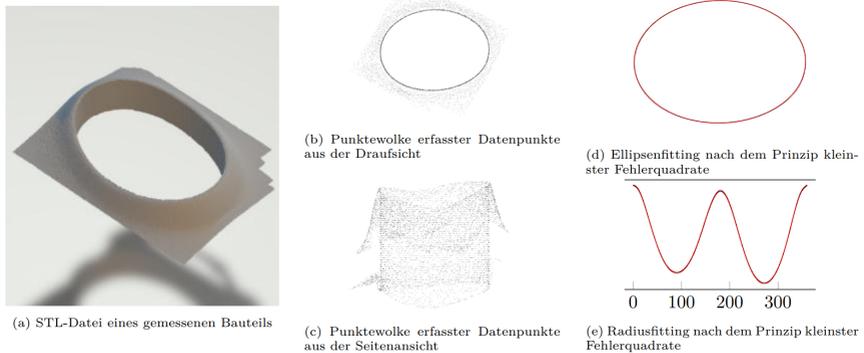


Abbildung 4.14.: Visualisierung des Vorgehens zur Auswertung erfasster, optischer Messdaten

Bezeichnung	$ \overline{\Delta z_{st}} $	$\max( \Delta z_{st} )$	$ \overline{\Delta \theta_x} $	$\max( \Delta \theta_x )$
<i>Robust</i>	1.49 mm	4.68 mm	0.48 °	1.85 °
<i>Ungedämpft</i>	1.46 mm	4.56 mm	0.34 °	1.46 °
<i>Adaptiv</i>	0.92 mm	2.96 mm	0.23 °	1.17 °

Tabelle 4.4.: Mittlere ( $|\overline{\cdot}|$ ) und maximale Regelabweichungen  $\max(|\cdot|)$  der im Lochwalzprozess geregelten Stößelfreiheitsgrade für unterschiedliche Regelgesetze [E9]

Manipulierbarkeit werden die Differenzen zwischen inverser und DLS-gedämpfter Jakobimatrix größer (siehe Abbildung 4.9c), sodass die durch die Regelgesetze ausgegebenen Geschwindigkeitsstellgrößen stärker voneinander abweichen. Die adaptive Regelung kompensiert diesen Effekt durch Anpassung des Verstärkungsfaktors an den linearisierten Arbeitspunkt und führt demnach trotz Nutzung einer DLS-Inversen auf die geringsten Abweichungen hinsichtlich der Stößelkipung  $\theta_x$ .

Die aus Tabelle 4.4 hervorgehenden Regelabweichungen spiegeln sich ebenfalls in den Geometrien produzierter Lochwalzbauteile wider. Abbildung 4.15 stellt für vier unterschiedliche Exzentrizitäten mit elliptischen Halbachsenlängen  $r_b \in [14 \ 16 \ 18 \ 20]$  mm die aus den optischen Messdaten gefitteten Ellipsen und entsprechende Soll-Geometrien dar. Es ist deutlich zu erkennen, dass die adaptive Regelung zu den größten Ausweitungen des Lochbildes und damit zu den geringsten

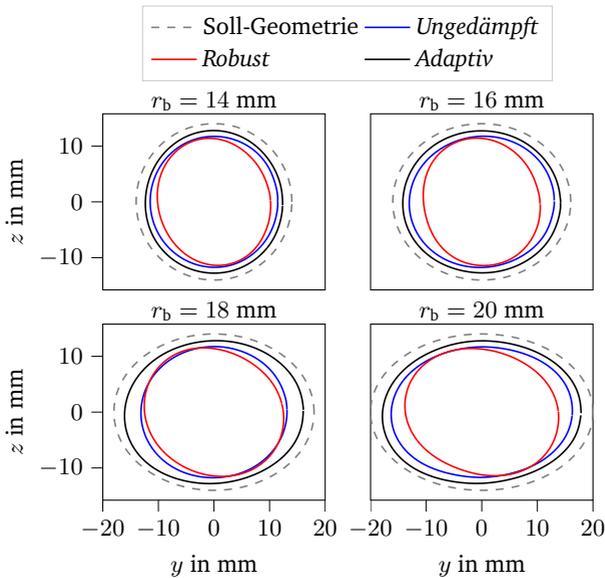


Abbildung 4.15.: Vergleich resultierender Geometrien lochgewalzter Bauteile bei Anwendung unterschiedlicher Regelgesetze [E9]

Abweichungen zwischen Soll- und Ist-Geometrie führt. Gleichzeitig spiegeln sich die Abweichungen zwischen robuster und ungedämpfter Regelstrategie bezüglich Verkipparabweichungen in unterschiedlich stark abweichenden y-Koordinaten der Bauteile wider, wohingegen sich Abweichungen bezüglich der z-Achse auf ähnlichem Niveau bewegen. Die resultierenden Geometrien stehen daher im Einklang mit den in Tabelle 4.4 dargelegten Regelabweichungen und stellen unter Beweis, dass die Auslegung des Regelgesetzes elementar für die resultierenden Bauteilgeometrien ist.<sup>9</sup>

Trotz der Nutzung von adaptiven Verstärkungsfaktoren verbleiben Abweichungen zwischen Ist- und Soll-Geometrie, die einer Kompensation bedürfen. Dazu wird ein datengetriebener Ansatz gewählt, bei dem Korrelationen zwischen Ist- und Soll-Werten  $r_i^{(ist)}$  und  $r_i^{(soll)}$  der elliptischen Halbachsen genutzt werden, um die Soll-Werte anzupassen.

<sup>9</sup>Ein Vergleich der realen Bauteile ist Abbildung A.8 in Anhang A.7 zu entnehmen.

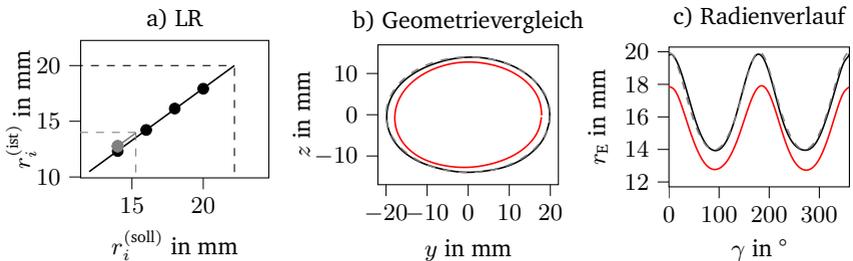


Abbildung 4.16.: Ansatz zur Werkzeugpfadkorrektur mittels linearer Regression zwischen Ist- und Soll-Werten elliptischer Halbachsenradien (a) und Vergleich resultierender Lochgeometrien (b) sowie Radienverläufe (c) zwischen korrigiertem (schwarz) und unkorrigiertem Bauteil (rot)

Abbildung 4.16a) visualisiert den Ansatz, bei dem die Ist- und Soll-Werte der langen Halbachsen  $r_b$  mittels LR korreliert werden und ein linearer Zusammenhang identifizierbar ist. Die Regressionsgleichung wird anschließend genutzt, um die Soll-Werte bei der Planung des Werkzeugpfades anzupassen, wobei für die Kompensation der kurzen elliptischen Halbachse (siehe graue Punkte in Abbildung 4.16) die gleiche Steigung angenommen wird. Die Soll-Werte bei der Planung des Werkzeugpfades für ein Bauteil mit den Ist-Abmaßen  $r_a^{(ist)} = 14$  mm und  $r_b^{(ist)} = 20$  mm lauten  $r_a^{(soll)} = 15.3$  mm und  $r_b^{(soll)} = 22.2$  mm, welche wiederum genutzt werden, um den Werkzeugpfad gemäß der anhand von Abbildung 4.12 geschilderten Vorgehensweise zu modifizieren. Die Durchführung von Experimenten mit dem korrigierten Werkzeugpfad führt auf die in Abbildung 4.16b) und c) schwarz gekennzeichneten Geometrie- und Radienverläufe, die nur geringfügig von den gestrichelten Soll-Verläufen abweichen. Als Vergleich sind die Bauteilgeometrien, die mit unkorrigiertem Werkzeugpfad produziert werden, in rot dargestellt. Der Ansatz der datengetriebenen Pfadkorrektur stellt sich als hocheffektiv heraus. Maximale radiale Abweichungen können von 2.08 mm auf unter 0.15 mm reduziert werden.<sup>10</sup>

<sup>10</sup>Ein weiterer experimenteller Validierungsansatz ist in Anhang A.5 erfasst. Dabei wird eine spirale Bewegungstrajektorie zur Durchführung eines Taumelschmiedeprozesses untersucht und die Performanz der in Tabelle 4.3 parametrisierten Regler miteinander verglichen.

---

## 4.4. Zwischenfazit

Im vorangegangenen Kapitel werden bestehende Erkenntnisse bezüglich der Regelung von Stoßelposen auf redundanten, nichtlinear-übersetzenden Servopressen (siehe [Hop21]) auf der Forschungsversion der 3DSP validiert und erweitert. Durch eine Regelung der Stoßelpose im Arbeitsraum können sowohl Stoßeltranslationen als auch -verkippen unter Last geregelt werden, was am Beispiel außermittiger Stauchversuche demonstriert wird. Als Nachteile der Regelung erweisen sich deren Recheneffizienz und die manuelle Wahl der Verstärkungsfaktoren, weswegen ein Ansatz zur systematischen, arbeitspunktabhängigen Auslegung ebendieser vorgestellt wird. Dazu werden Sollwerte der Stoßelpose über eine approximierende, KI-gestützte IK-Funktion in Sollwerte für die Stoßellager transformiert, was den Vorteil birgt, dass die Antriebs-Abtriebs-Übertragungsfunktion in mehrere Single-Input-Single-Output (SISO)-Systeme untergliedert werden kann. Sowohl simulative als auch experimentelle Untersuchungen am Beispiel eines Lochwalzprozesses zeigen, dass die Genauigkeit der Positionsregelung erheblich von der auf GS-Techniken basierenden Regelungsstrategie profitiert, jedoch das Auftreten von Schleppfehlern einer hochgenauen Fertigung lochgewalzter Bauteile entgegensteht.

Daher wird ein linearer, datengetriebener Ansatz gewählt, der den Werkzeugpfad der Walze modifiziert und Abweichungen zwischen Ist- und Soll-Geometrien kompensiert. Der Ansatz stellt sich als hocheffektiv heraus und führt zu maßhaltigen Lochgeometrien. Die Effektivität des Ansatzes ist jedoch auf lineare Zusammenhänge zwischen modifizierten Trajektorienparametern und resultierenden Bauteilgeometrien zurückzuführen. Nichtlineare Effekte wie etwa thermische oder elastische Relaxation, die nach Allwood et al. [All16] einer Regelung von Bauteileigenschaften bedürfen (siehe dazu Abbildung 2.7), spielen bei der Einstellung der Lochgeometrie im Lochwalzprozess eine untergeordnete Rolle, weswegen lineare Kompensationsansätze im vorgestellten Fall ausreichend sind. In den folgenden Kapiteln sollen daher Prozesse untersucht werden, in denen resultierende Bauteileigenschaften und zu präzisierende Führungsgrößen des Online-Regelkreises nichtlinear miteinander korrelieren, sodass der Einsatz KI-gestützter Algorithmen zielführender ist.

Die vorgestellte Methodik zur GS-basierten Regelung der 3DSP im Arbeitsraum ist übertragbar auf parallelkinematische Werkzeugmaschinen, deren Endeffektorpose sich aus einer Superposition linear geführter Lager und gleichzeitig sensorisch erfass-

---

ten Lagerpositionen ergibt. Sobald sichergestellt werden kann, dass die Position des jeweiligen Lagers ausschließlich von einem nicht-redundanten Antrieb abhängt (Zerlegung in mehrere SISO-Systeme) und die Kinematik zwischen jenem Antrieb und dem dazugehörigen Lager Nichtlinearität aufweist, kann der jeweilige Verstärkungsfaktor systematisch mittels der vorgestellten Methodik adaptiert werden. Ebenfalls ist die Methodik auf konventionelle, nichtlinear-übersetzende Servopressen (Kurbel- oder Kniehebelpressen) anwendbar, bei denen Positionsregelungen im Arbeitsraum angestrebt werden.

---

## 5. KI-gestützte Eigenschaftsregelungen

---

### 5.1. Anwendung überwachter Lernalgorithmen auf Freibiegeprozess

Ein erster Ansatz zur Verifizierung des in Kapitel 3 vorgestellten Konzepts zur Regelung von Bauteileigenschaften ist dessen Anwendung auf einen Freibiegeprozess. Biegeprozesse gehören zu den wichtigsten Vertretern von Blechumformprozessen und erzeugen endkonturnahe Geometrien unterschiedlichster Bauteile. Eine große Herausforderung, die sowohl in der umformtechnischen Forschung als auch in der industriellen Praxis von hoher Relevanz ist, sind Rückfederungseffekte, die einer genauen Einstellung des finalen Biegewinkels entgegenstehen. Rückfederungen treten aufgrund während Belastungsprozessen induzierten Spannungen auf und können anhand von Abbildung 5.1 erläutert werden. Während Biegeprozessen kommt es in Blechquerschnitten zu Streckungen bzw. Stauchungen abseits der neutralen Faser. Betrachtet man den in Abbildung 5.1a) grau hinterlegten Biegebereich, wird ersichtlich, dass die Außenkante infolge der Biegung verlängert und die Innenkante verkürzt wird. So kommt es orthogonal zur neutralen Faser zu dem in Abbildung 5.1a) grün eingezeichneten Spannungsverlauf, dessen Charakteristiken maximale Zugspannungen an der Außenkante und maximale Druckspannung an der Innenkante sind. Wird das Blech nun entlastet, stellen sich die blau eingezeichneten Eigenspannungen ein. Die starken Reduktionen der Spannungen auf den Bauteilkannten gehen mit Rückfederungen des Biegewinkels einher. Infolge der nach Entlastung des Bauteils eintretenden Stauchung der Außenkante und Streckung der Innenkante reduziert sich der unter Belastung eingestellte Biegewinkel  $\alpha^{(be)}$  zum entlasteten Biegewinkel  $\alpha^{(ent)}$ . Aus diesem Grund beforschen Wissenschaftler auf dem Gebiet der Umformtechnik unterschiedliche Ansätze, um Rückfederungen zu präzisieren

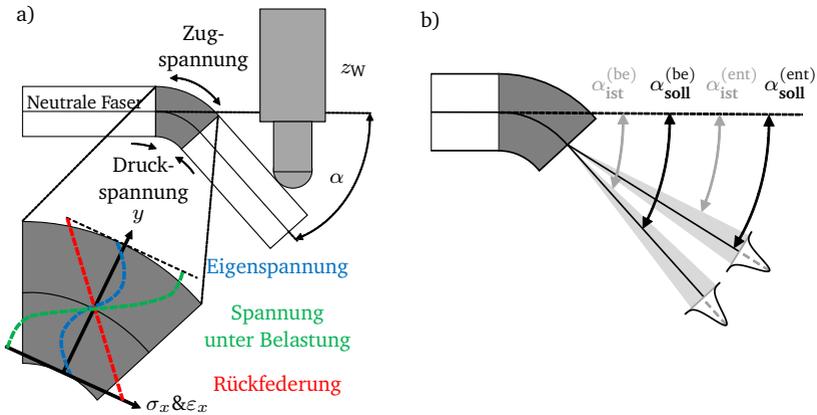


Abbildung 5.1.: a) Schematische Darstellung eines Freibiegeprozesses mit dazugehörigen Spannungsverläufen und b) präzierte und gewünschte Biegewinkel im belasteten und entlasteten Zustand

und greifen dazu auf analytische [GBH08], simulativ-numerische [PP02] und datengetriebene [Liu07] Ansätze zurück. Die grundsätzliche Gemeinsamkeit aller Ansätze wird anhand von Abbildung 5.1b) erläutert. Ziel der Anwendung aller Ansätze ist die Einstellung eines gewünschten Biegewinkels im entlasteten Zustand  $\alpha_{soll}^{(ent)}$ . Dieser wird erreicht, indem im belasteten Zustand der dazugehörige Biegewinkel  $\alpha_{soll}^{(be)}$  angefahren wird, sodass das Blech überbogen wird und sich die ideale Rückfederung  $s_{id} = \alpha_{soll}^{(be)} - \alpha_{soll}^{(ent)}$  einstellt. Die Rückfederung ist jedoch abhängig von einer Vielzahl an Material- und Prozessgrößen, deren Auswirkungen auf die Rückfederung nichtlinear und deren Größenwerte unbekannt sind oder Unsicherheit unterliegen. Daher präzisieren angewandte Modelle lediglich eine geschätzte Rückfederung  $\hat{s}$ , sodass der die Rückfederung kompensierende Biegewinkel im belasteten Zustand  $\alpha_{ist}^{(be)}$  unsicherheitsbehaftet ist. Wird der präzierte Biegewinkel im Prozess angefahren, stellt sich im entlasteten Zustand der Biegewinkel  $\alpha_{ist}^{(ent)}$  ein, der vom gewünschten Biegewinkel  $\alpha_{soll}^{(ent)}$  abweicht. Ziel der genutzten Modelle sollte es demnach sein, den Erwartungswert als auch die Streuung der Biegewinkelabweichung im entlasteten Zustand  $\Delta\alpha^{(ent)} = \alpha_{soll}^{(ent)} - \alpha_{ist}^{(ent)}$  zu minimieren und somit eine möglichst genaue Einstellung der Bauteilendkontur zu realisieren.

Eine Vorstellung ausgewählter Publikationen zur gezielten Einstellung rückgefeder-

---

ter Biegewinkel erfolgte bereits in Kapitel 2.2.3. Aus diesen Arbeiten lassen sich Defizite bestehender Veröffentlichungen ableiten, die im Rahmen der vorliegenden Arbeit überwunden werden sollen. Die vorgestellten Steuer- und Regelansätze beruhen größtenteils auf bauteilbezogenen Prädiktionen optimaler Hubhöhen. So wird in einer Vielzahl der Publikationen [FGR98; IDD00; Wan08; BHT15; Hav18; Gro15; Gro16] der Umstand genutzt, dass über die vertikale Translation des Biegestempels  $z_W$  der Biegewinkel manipuliert werden kann. Unsicherheit, die aus dem Übertragungsverhalten zwischen gesteuerter Werkzeugtranslation im Gelenkraum und resultierendem Biegewinkel entsteht (bspw. Verschleiß oder Maschinensteifigkeit), wird dabei unzureichend Rechnung getragen. Anwendungen, die eine echtzeitliche oder quasi-echtzeitliche Messung des Biegewinkels basierend auf taktiler oder optischer Messtechnik vornehmen und dieses Signal in die auf Maschinensteuerungen implementierten Positionsregelkreise von Umformmaschinen integrieren, finden sich derzeit nicht in der Literatur. Zudem beschränken sich einige Steuer- und Regelansätze auf simulative Untersuchungen [BHT15; Liu21] oder bedürfen der vorherigen Kenntnis von Halbzeugeigenschaften [Gro15; IDD00]. Aus diesem Grund soll im Folgenden gezeigt werden, dass

1. unterschiedliche überwachte ML-Algorithmen den die Rückfederung kompensierenden, belasteten Biegewinkel  $\alpha_{\text{soll}}^{(\text{be})}$  ohne Kenntnis der Materialeigenschaften basierend auf Kraftsignalen präzisieren,
2. Biegewinkel mit hoher zeitlicher Auflösung durch CCD-Kameras und weiterführende Bildverarbeitungsalgorithmen erfasst und
3. jene Signale in die Positionsregelung der 3DSP integriert werden können, um quasi-echtzeitlich den Biegewinkel im Arbeitsraum zu regeln.

Dazu wird in Kapitel 5.1.1 der Versuchsaufbau, in Kapitel 5.1.2 die Regelungsstrategie und abschließend in Kapitel 5.1.3 die Vorgehensweise zur Entwicklung der überwachten Lernalgorithmen anhand des KDT-EA-Modells vorgestellt.

### 5.1.1. Versuchsaufbau

Die experimentellen Biegeversuche werden mit zwei unterschiedlichen Materialien (AlMg3 und DC01) und drei unterschiedlichen Blechdicken (1 mm, 1.5 mm, 2 mm)

---

durchgeführt. Dabei wird in zwei Anwendungen unterteilt, die differenziert voneinander untersucht werden. Im ersten Anwendungsfall wird ein Datensatz erstellt, der sowohl Material- als auch Blechdickenschwankungen beinhaltet und es wird untersucht, ob die entwickelten Modelle unterschiedliches Rückfederungsverhalten zwischen Material- und Blechdickenvariationen abbilden können (Kapitel 5.1.4). Der zweite Anwendungsfall adressiert lediglich ein Material (DC01), bei dem durch schleifende Nachbearbeitung geringfügige Blechdickenschwankungen eingebracht werden. So soll untersucht werden, ob die Algorithmen aus aufgenommenen Kraftsignalen geringfügige Blechdickenschwankungen identifizieren und deren Effekt auf die Rückfederung kompensieren können (Kapitel 5.1.4).

Die Experimente werden auf dem Prototypen der 3DSP durchgeführt. In allen Versuchen werden Biegewinkel zwischen  $30^\circ$  und  $50^\circ$  angefahren. Die Biegewinkelvermessung wird durch eine im Werkzeugraum der Presse angebrachte CCD-Kamera (Basler acA1600-60gm) realisiert, deren aufgenommene Bilder mit etwa 40 Hz auf einen Computer übertragen werden und über das *Lab-VIEW Vision Assistant Express VI* verarbeitet werden. Dabei werden Kantendetektionsalgorithmen auf die aufgenommenen Bilder angewandt und die Winkel durch trigonometrische Beziehungen zwischen der Horizontalen und den Kanten des eingespannten Biegebauteils berechnet. Im Oberwerkzeug sind drei piezoelektrische Kraftsensoren (Kistler 9031A) verbaut, deren Signale über einen embedded Controller (cRIO 9082 National Instruments) mit einer Frequenz von 10 kHz ausgelesen, abgespeichert und an einen mit der 3DSP kommunizierenden Rechner gesandt werden. Zur Identifikation von Halbzeugeigenschaften werden die Bauteile bis  $23.75^\circ$  vorgebogen, der Prozess für kurze Zeit gestoppt und entstehende Kraftsignale auf dem Computer in ML-Pipelines eingespeist, die unter Nutzung unterschiedlicher Regressionsmodelle den durch die Regelung anzufahrenden, belasteten Biegewinkel  $\alpha_{\text{soll}}^{(\text{be})}$  präzisieren.<sup>1</sup>

### 5.1.2. Regelungskonzept

Abbildung 5.2 stellt das Blockschaltbild der Regelungsstrategie dar. Im Offline-Regelkreis wird ein KI-gestützter Produktregler eingesetzt, der unter Einspeisung der Soll-Biegewinkel im entlasteten Zustand  $\alpha_{\text{soll}}^{(\text{ent})}$  und aus den ersten  $23.75^\circ$  des

---

<sup>1</sup>Für genauere Details über den Versuchsaufbau sei auf [S10] verwiesen.

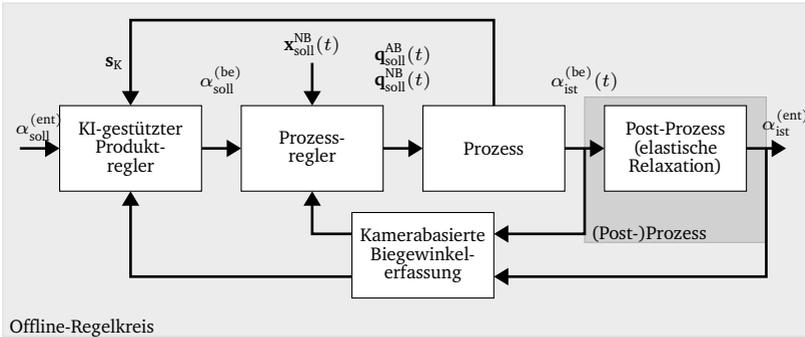


Abbildung 5.2.: Blockschaltbild des eigenschaftsgeregelten Freibiegeprozesses

Biegeprozesses aufgenommenen Kraftsignalen  $s_K$  den Biegewinkel prädiert, der im belasteten Zustand eingeregelt werden soll. Die Regelung des Biegewinkels findet dabei im Arbeitsraum der 3DSP statt, wobei der zeitliche Verlauf des Ist-Biegewinkels  $\alpha_{\text{ist}}^{(\text{be})}(t)$  kamerabasiert und unter Anwendung von Kantendetektionsalgorithmen erfasst wird. Dem Prozessregler werden Nebenbedingungen  $\mathbf{x}_{\text{soll}}^{\text{NB}}(t)$  zugeführt, mithilfe derer die für die Durchführung des Prozesses nicht notwendigen Antriebsfreiheitsgrade  $\mathbf{q}^{\text{NB}}$  geregelt werden. Da keine Stoßelkippungen für den Prozess notwendig sind und eine maximale Manipulierbarkeit des Biegewinkels ungeachtet der zur Verfügung gestellten Presskraft wünschenswert ist, gilt

$$\mathbf{x}_{\text{soll}}^{\text{NB}}(t) = \begin{bmatrix} \theta_x \\ \theta_y \\ t_{\text{OT}} \\ t_{\text{UT}} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ z_{\text{st}}(\alpha_{\text{ist}}^{(\text{be})}(t)) + \frac{h}{2} \\ z_{\text{st}}(\alpha_{\text{ist}}^{(\text{be})}(t)) - \frac{h}{2} \end{bmatrix}, \quad (5.1)$$

wobei die vertikale z-Translation des Stößels eine Funktion des im Prozess angefahrenen Biegewinkels  $\alpha_{\text{ist}}^{(\text{be})}(t)$  ist und die Hubhöhe auf  $h = 30 \text{ mm}$  gesetzt wird. Die aus dem KI-gestützten Produktregler prädierte, stationäre Führungsgröße  $\alpha_{\text{soll}}^{(\text{be})}$  und die formulierten Nebenbedingungen  $\mathbf{x}_{\text{soll}}^{\text{NB}}(t)$  werden anschließend in den Online-Prozessregler eingespeist und mithilfe des in Kapitel 4.2 vorgestellten Geschwindigkeitsregelkreises geregelt.

Vorteilhaft bei dem vorgestellten Regelkonzept ist die zeitkontinuierliche Erfassung

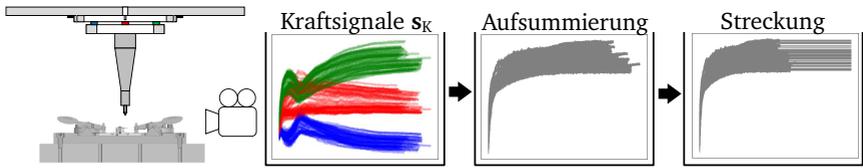


Abbildung 5.3.: Verwendetes Biegewerkzeug mit farblich hervorgehobenen Kraftmessringen (links) und schematische Visualisierung der Schritte zur Datenverarbeitung (rechts)

und damit direkte Biegewinkelregelung im Arbeitsraum der Maschine, wodurch eine Echtzeit-Kommunikation zwischen der Prozessgröße Biegewinkel unter Last und den Antrieben der Maschinenregelung geschaffen wird. Wie in [E11] hergeleitet, geht die kamerabasierte Biegewinkelregelung mit einer stationären Genauigkeit und damit Eliminierung bleibender Fehlerabweichungen einher, wodurch maschinen- und werkzeugseitige Unsicherheit wie Getriebesteifigkeiten oder Werkzeugverschleiß kompensierbar ist.

### 5.1.3. Entwurf des KI-gestützten Produktreglers

Die Entwicklung der im KI-gestützten Produktregler eingesetzten Modelle orientiert sich am in Kapitel 2.2.1 eingeführten KDT-EA-Prozess [E6]. Mit einer MLR, einem mehrschichtigen NN und einem CNN kommen drei überwachte Lerntechniken mit divergierenden Komplexitätsgraden zum Einsatz, deren Aufbau in Abbildung 5.4 abgebildet ist. Im Schritt der Datenerfassung sind die drei Kraftsignale  $s_K$  Ausgangspunkt aller Algorithmen, die gemäß Abbildung 5.3 im Oberwerkzeug durch Kraftmessringe erfasst werden. Ein aus dem Prozess aufgenommenes Bild zur Erfassung des Biegewinkels ist Abbildung 5.5 zu entnehmen. Zur Validierung der kamerabasierten Biegewinkelmessung werden deren Messergebnisse mit denen einer Offline 3D-Messung verglichen, die mithilfe des optischen Messsystems *GOM ATOS 5* durchgeführt wird. In Abbildung 5.5 sind die Biegewinkelabweichungen  $\Delta\alpha$  zwischen beiden Messsystemen für 30 Messungen festgehalten, die als Grundlage zur Schätzung einer WDF  $p(\Delta\alpha)$  herangezogen werden. Ein Großteil der Referenzmessungen weicht maximal  $\pm 0,4^\circ$  ab, weshalb die kamerabasierte Winkelvermessung

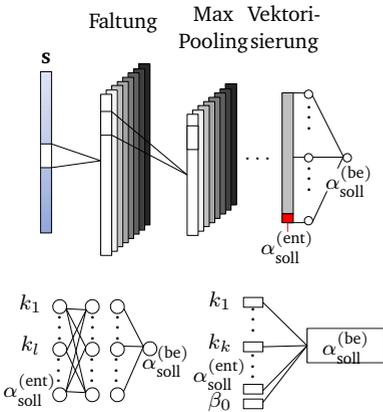


Abbildung 5.4.: Übersicht über die verwendeten Algorithmen mit entsprechenden Ein- und Ausgangsgrößen

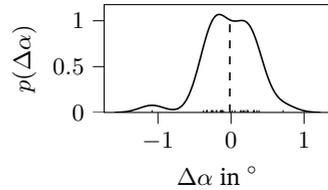
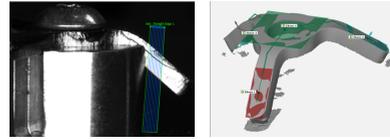


Abbildung 5.5.: Validierung der Biege-  
winkelerfassung durch Vergleich mit  
optischem 3D-Messsystem

als qualifiziert zur Biegewinkelregelung angesehen wird. Im Schritt der Datenvorbereitung (siehe Abbildung 5.3) werden die Kraftsignale aufsummiert und auf eine Länge gestreckt, indem der letzte Wert der erfassten Zeitreihe angehängt wird, bis die Zeitreihe eine definierte Länge besitzt. Anschließend werden die aufgenommenen Zeitreihen in die Matrixform  $\mathbf{S}_K$  umgewandelt und auf einen Wertebereich zwischen 0 und 1 skaliert. Die weitere Verarbeitung der Zeitreihen und Modellbildung erfolgt gemäß Abbildung 5.6 algorithmenspezifisch.

Zum Training des CNN bedarf es keiner Dimensionalitätsreduktion der Zeitreihen und damit keiner Extraktion von Kennwerten. CNN bieten den Vorteil, aus hochdimensionalen Daten eigenständig informationsreiche Kennwerte zu extrahieren und automatisieren den Prozessschritt der Datentransformation somit. Als Eingangsgrößen für die MLR und des NN werden Kennwerte gewählt, die mittels der *Python*-Bibliothek *Time Series Feature Extraction Library* (TSFEL) [Bar20] extrahiert werden. Zudem wird auf die Signalmatrix  $\mathbf{S}_K$  eine lineare Hauptkomponentenanalyse angewendet, aus der die zwei Hauptkomponenten mit den höchsten erfassten Varianzanteilen extrahiert werden. Weiterhin, wie in Abbildung 5.4 erfasst, wird der Soll-Biegewinkel nach Entlastung  $\alpha_{\text{soll}}^{(\text{ent})}$  als Kennwert herangezogen. Die Kennwertextraktion führt somit für  $m$  durchgeführte Biegeversuche auf eine Kennwertmatrix  $\mathbf{K} \in \mathbb{R}^{m \times 393}$ , wobei 390 Kennwerte der TSFEL-Bibliothek entstam-

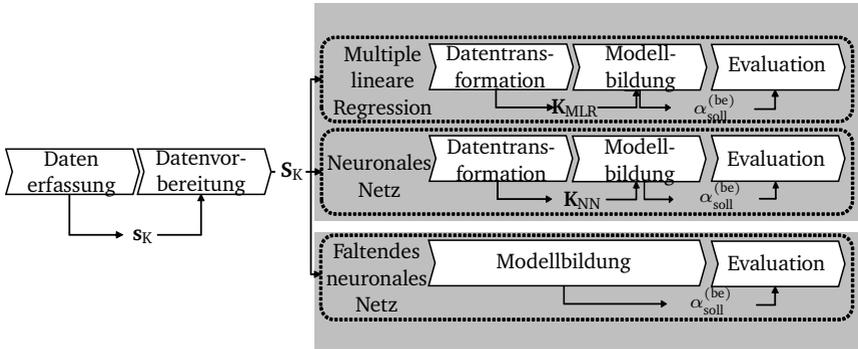


Abbildung 5.6.: Übersicht über Vorgehen zur algorithmenspezifischen Verarbeitung aufgenommener Kraftsignale nach dem KDTEA-Prozess

men. Eine Selektion möglichst informativer Kennwerte geht mit einer weiteren Dimensionalitätsreduktion einher und bedarf der Anwendung von Kennwertselektionstechniken. Diese sind einteilbar in Filter-, Wrapper- und hybride Methoden [KJ97], wobei Filter-Methoden auf einer meist korrelationsbasierten Analyse der Kennwerte beruhen und Wrapper-Methoden die Interaktion der Kennwerte mit dem angewandten Algorithmus berücksichtigen. Bei Letzteren erfolgt eine Optimierung der selektierten Kennwerte unter iterativer Einspeisung unterschiedlicher Kennwert-Teilmengen in den Algorithmus, wodurch Performanzen gesteigert werden, jedoch erhöhte Rechenkapazitäten zur Verfügung stehen müssen.

Da die Rechenintensitäten von NN und MLR massiv voneinander abweichen, werden die dem NN zugeführten Kennwerte durch einen korrelationsbasierten Filter-Algorithmus und die der MLR durch eine Wrapper-Methode selektiert. Für die Kennwertselektion des NN werden alle Kennwerte  $\mathbf{k}_i$  der Kennwertmatrix  $\mathbf{K}$  mit der gemessenen Rückfederung  $s_{\text{ist}} = \alpha_{\text{ist}}^{(\text{be})} - \alpha_{\text{ist}}^{(\text{ent})}$  über den Pearson-Korrelationskoeffizienten korreliert, sodass für den  $i$ -ten Kennwert der Korrelationskoeffizient

$$r_{i,\text{Pea}} = \frac{\sum_{j=1}^m (k_{i,j} - \bar{k}_i)(s_{\text{ist},j} - \bar{s}_{\text{ist}})}{\sqrt{\sum_{j=1}^m (k_{i,j} - \bar{k}_i)^2 \cdot \sum_{j=1}^m (s_{\text{ist},j} - \bar{s}_{\text{ist}})^2}} \quad (5.2)$$

vorliegt. Anschließend werden ausschließlich jene Kennwerte extrahiert, deren betragsmäßiger Korrelationskoeffizient einen Grenzwert gemäß  $|r_{i,\text{Pea}}| > r_{\text{Gre,Pea}}$  über-

schreitet, wodurch eine ausreichende Korrelation mit der Rückfederung sichergestellt wird. Die  $l$  extrahierten Kennwerte für das NN führen somit auf die Kennwertmatrix  $\mathbf{K}_{\text{NN}} \in \mathbb{R}^{m \times l}$ . Zur Stabilisierung des Trainingsprozesses des NN werden die Kennwerte zu standardnormalverteilten Variablen transformiert, sodass  $\mathbf{k}_{i,\text{NN}} \sim \mathcal{N}(0, 1)$  gilt. Die Kennwertselektion für die MLR erfolgt durch einen vorwärtsgerichteten Wrapper-Algorithmus, bei dem die vorliegenden Daten in Trainings- und Testdaten eingeteilt werden und die Performanz der MLR auf dem Testdatensatz unter iterativer Hinzunahme zusätzlicher Kennwerte überwacht wird. Führt eine Hinzunahme weiterer Kennwerte auf keine Performanzsteigerung auf dem Testdatensatz, bricht der Algorithmus ab und gibt  $k$  selektierte Kennwerte aus, die in der Kennwertmatrix  $\mathbf{K}_{\text{MLR}} \in \mathbb{R}^{m \times k}$  resultieren.

In der Prozessstufe der Modellbildung werden die Algorithmen trainiert und deren Hyperparameter optimiert. Entgegen des NN bedarf es bei der Anwendung der MLR keiner Hyperparameteroptimierung, da die Optimierung derer Kostenfunktion ein unbeschränktes, konvexes Optimierungsproblem darstellt und damit analytisch lösbar ist. Zur Findung geeigneter Hyperparameter für das NN wird eine Bayes'sche Optimierung durchgeführt, die die in Anhang A.2 spezifizierten Hyperparameter optimiert. Die Daten werden in 80% Trainings- und 20% Testdaten unterteilt, wobei 20% der Trainingsdaten als Validierungsdaten genutzt werden. Die initialen, exponentiell abfallenden Lernraten werden für NN und CNN auf 0.001 gesetzt, als Optimierer wird Adam [KB14] genutzt. Die Netze werden über 50 (CNN) bzw. 30 Epochen (NN) trainiert und Trainingsprozesse nach dem Early-Stopping-Prinzip abgebrochen, sofern die mittlere quadratische Abweichung auf dem Validierungsdatensatz über 10 (CNN) bzw. 5 Epochen (NN) nicht weiter optimiert werden kann. Abschließend werden die Ergebnisse der Modellbildung im Prozessschritt der Evaluation bewertet und miteinander verglichen. Um die Modelle vor der Validierung des Regelkonzeptes bewerten zu können, werden die mittleren quadratischen Abweichungen der im Prozess angefahrenen Biegewinkel gemäß

$$x_{\text{MQA}} = \frac{1}{N} \sum_{i=1}^N \left( \alpha_{\text{soll},i}^{(\text{be})} - \max \left( \alpha_{\text{ist},i}^{(\text{be})} \right) \right)^2 \quad (5.3)$$

berechnet. Nachdem die Modelle trainiert worden sind, dienen diese als KI-gestützter Produktregler und werden zur Offline-Regelung des Biegewinkels eingesetzt. In den nachgelagerten Validierungsversuchen wird die Güte des Offline-Produktreglers

---

durch die Biegewinkelabweichung des entlasteten Biegewinkels  $\Delta\alpha^{(\text{ent})} = \alpha_{\text{ist}}^{(\text{ent})} - \alpha_{\text{soil}}^{(\text{ent})}$  quantifiziert.

#### 5.1.4. Experimentelle Ergebnisse

Im folgenden Kapitel werden die Ergebnisse der Modellentwicklungen präsentiert, wobei zwischen Untersuchungen hinsichtlich unterschiedlichen Halbzeugen (Kapitel 5.1.4) und geringfügigen Blechdickenschwankungen (Kapitel 5.1.4) unterschieden wird.

##### Variationen des Halbzeugs

Im ersten Untersuchungsansatz werden die Modelle hinsichtlich der Fähigkeit untersucht, die Rückfederungseigenschaften unterschiedlicher Materialien (DC01 & AlMg3) und Blechdicken (1 mm; 1.5 mm & 2 mm) zu erlernen. Dazu wird der in Tabelle 5.1 dargelegte Versuchsplan aufgestellt und eine Versuchreihe bestehend aus 363 Biegeversuchen durchgeführt. Die durch den Prozessregler eingeregelter Biegewinkel unter Last  $\alpha_{\text{soil}}^{(\text{be})}$  werden dabei in 1-Grad-Inkrementen zwischen 30° und 50° variiert und jeder Versuch drei Mal wiederholt. Lediglich für den AlMg3 Werkstoff mit einer Blechdicke von 1.5 mm werden die Biegewinkel zwischen 40° und 50° in 2-Grad-Inkrementen variiert.

Abbildung 5.7 stellt die bereits aufsummierten Kraftsignale der drei im Oberwerkzeug angebrachten Kraftmessringe mit entsprechenden 99%-Konfidenzintervallen in frühen Prozessphasen dar. Es ist deutlich ersichtlich, dass sich die Kraftsignale infolge unterschiedlicher Halbzeugeigenschaften signifikant unterscheiden. Die 99%-Konfidenzintervalle der unterschiedlichen Halbzeug-Blechdicken-Kombinationen überlappen sich in weiten Teilen nicht. Die einzige Überlappung stellen Stahl- und Aluminiumbauteile mit einer Blechdicke von  $t_b = 1$  mm dar. Daher wird davon ausgegangen, dass die Kraftsignale ausreichenden Informationsgehalt über das Rückfederungsverhalten der unterschiedlichen Kombinationen beinhalten und der KI-gestützte Produktregler Korrelationen zwischen Kraftsignalen und Rückfederungen identifizieren kann.

Tabelle 5.1.: Überblick über Versuchsplan unter Nutzung unterschiedlicher Materialien und Blechdicken  $t_b$

Material	$t_b$ in mm	Biegewinkel unter Last		Versuche
		$\alpha_{\text{soll}}^{(\text{be})}$	in $^\circ$	
DC01	1.0	$\{\alpha_{\text{soll}}^{(\text{be})} \in \mathbb{N} \mid 30 \leq \alpha_{\text{soll}}^{(\text{be})} \leq 50\}$		63
DC01	1.5	$\{\alpha_{\text{soll}}^{(\text{be})} \in \mathbb{N} \mid 30 \leq \alpha_{\text{soll}}^{(\text{be})} \leq 50\}$		63
DC01	2.0	$\{\alpha_{\text{soll}}^{(\text{be})} \in \mathbb{N} \mid 30 \leq \alpha_{\text{soll}}^{(\text{be})} \leq 50\}$		63
AlMg3	1.0	$\{\alpha_{\text{soll}}^{(\text{be})} \in \mathbb{N} \mid 30 \leq \alpha_{\text{soll}}^{(\text{be})} \leq 50\}$		63
AlMg3	1.5	$\{\alpha_{\text{soll}}^{(\text{be})} \in \mathbb{N} \mid 30 \leq \alpha_{\text{soll}}^{(\text{be})} \leq 40\}$		48
AlMg3	2.0	$\bigcup \alpha_{\text{soll}}^{(\text{be})} \in \{42, 44, 46, 48, 50\}$		63
AlMg3	2.0	$\{\alpha_{\text{soll}}^{(\text{be})} \in \mathbb{N} \mid 30^\circ \leq \alpha_{\text{soll}}^{(\text{be})} \leq 50^\circ\}$		63

Abbildung 5.8 stellt Boxplots der resultierenden Rückfederungen  $s_{\text{ist}}$  für die Halbzeug-Blechdicken-Kombinationen dar. Rückfederungen treten im Größenbereich zwischen  $1^\circ$  und  $4^\circ$  auf. Mit zunehmender Blechdicke nehmen die Rückfederungen ab, was im abnehmenden Anteil elastischer Deformation an der gesamten Deformation über der Blechdicke begründet liegt. Gleichzeitig sind die Rückfederungswerte des Aluminiumwerkstoffes deutlich über denen des Stahlwerkstoffes, was im geringeren Elastizitätsmodul begründet liegt.

Die in Kapitel 5.1.3 beschriebenen Vorgehensweisen zur Kennwertselektion führen für die MLR auf 22 und für das NN auf 46 extrahierte Kennwerte<sup>2</sup>, wobei der Grenzwert des Pearson-Korrelationskoeffizientens zur Anwendung des Filter-Algorithmus  $r_{\text{Gre,Pea}}$  auf 0.6 gesetzt wird. Damit dienen  $\mathbf{S}_K \in \mathbb{R}^{363 \times 7307}$  (CNN),  $\mathbf{K}_{\text{MLR}} \in \mathbb{R}^{363 \times 22}$  und  $\mathbf{K}_{\text{NN}} \in \mathbb{R}^{363 \times 46}$  als Eingangsgrößen für die jeweiligen Modellbildungen. Tabelle 5.2 stellt die Ergebnisse der Modellentwicklungen dar.<sup>3</sup> Das CNN prädiziert den Biegewinkel am genauesten und führt auf die geringsten mittleren quadratischen Biegewinkelabweichungen auf dem Trainings- und Testdatensatz. Die MLR schneidet etwas schlechter ab, wobei ein erheblicher Performanzunterschied zwischen Trainings- und Testdatensatz zu verzeichnen ist. Die schlechteste Performanz weist das NN auf, was sich ebenfalls im unzureichenden Konvergenzverhalten aus

<sup>2</sup>Ergebnisse der Anwendung des vorwärtsgerichteten Wrapper-Algorithmus und die Abhängigkeit der mittleren quadratischen Biegewinkelabweichung  $x_{\text{MQA}}$  von der Anzahl genutzter Kennwerte sind Abbildung A.16 im Anhang zu entnehmen.

<sup>3</sup>Die aus der Bayes'schen Optimierung hervorgehenden Hyperparameter als auch der Verlauf der Verlustfunktionen über der Anzahl an Epochen sind dem Anhang (Tabelle A.3 & Abbildung A.17) zu entnehmen.

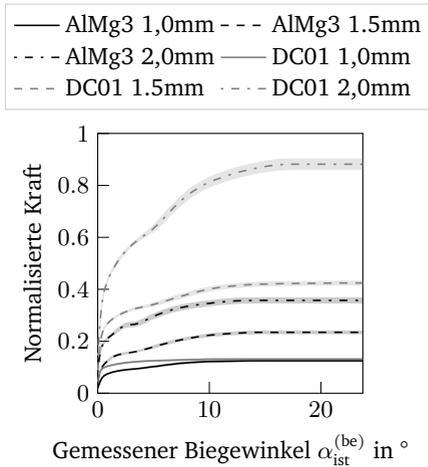


Abbildung 5.7.: Normalisierte Kraftverläufe

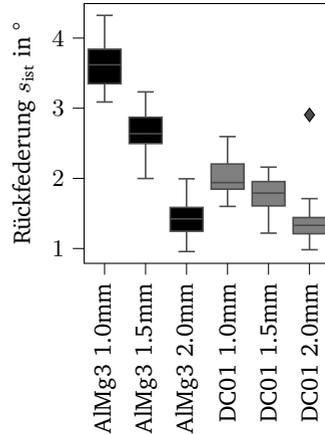


Abbildung 5.8.: Boxplots der Rückfederungen

Abbildung A.17 widerspiegelt.

Nach Entwicklung der Modelle werden diese als KI-gestützter Produktregler eingesetzt und Validierungsversuche durchgeführt. Gemäß des Versuchsplans in Tabelle 5.4 werden pro Modell 48 Versuche durchgeführt, bei denen die Modelle den im Prozess belasteten Biegewinkel präzisieren, der anschließend durch den Prozessregler kamerabasiert eingeregelt wird. Abbildung 5.9 und Tabelle 5.3 stellen die Ergebnisse der Abweichungen rückgefederter Biegewinkel dar. Trends aus den Ungenauigkeiten bei der Entwicklung der Modelle (siehe Tabelle 5.2) übertragen sich ebenfalls auf

Tabelle 5.4.: Überblick über Versuchsplan unter Nutzung unterschiedlicher Materialien und Blechdicken  $t_b$  für Validierungsversuche des KI-gestützten Produktreglers

Material	$t_b$ in mm	Entlasteter Biegewinkel $\alpha_{\text{soll}}^{(\text{ent})} \in \dots$ in $^\circ$	Versuche
DC01	1.0	{28, 29, 33, 34, 38, 39, 43, 44}	24
DC01	1.5	{30, 31, 35, 36, 40, 41, 45, 46}	24
DC01	2.0	{32, 33, 37, 38, 42, 43, 47, 48}	24
AlMg3	1.0	{27, 28, 32, 33, 37, 38, 42, 43}	24
AlMg3	1.5	{29, 30, 34, 35, 39, 40, 44, 45}	24
AlMg3	2.0	{31, 32, 36, 37, 41, 42, 46, 47}	24

Datensatz	MLR	NN	CNN
Training	0.066	0.138	0.061
Test	0.094	0.134	0.069

Tabelle 5.2.:  $x_{MQA}$  in  $^{\circ 2}$  auf Trainings- und Testdatensatz

Fehlermetrik	MLR	NN	CNN
$x_{MQA}^{(ent)}$	0.40	0.79	0.26
$\max( \Delta\alpha^{(ent)} )$	1.88	2.65	1.02

Tabelle 5.3.: Fehlermetriken  $x_{MQA}^{(ent)}$  in  $^{\circ 2}$  und  $\max(|\Delta\alpha^{(ent)}|)$  in  $^{\circ}$  für rückgefederter Biegewinkel unter Einsatz der unterschiedlichen Modelle als Kl-gestützter Produktregler

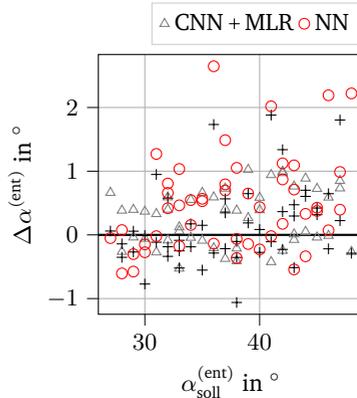


Abbildung 5.9.: Biegewinkelabweichungen  $\Delta\alpha$  für unterschiedliche Modellarten

die Genauigkeit der nach dem Prozess gemessenen, rückgefederter Biegewinkel. So führt das CNN zu den geringsten mittleren quadratischen als auch maximalen Abweichungen, wohingegen das NN zu den höchsten Abweichungen führt. Wie bei der Entwicklung der Modelle angedeutet, führt die MLR auf Abweichungen, die zwischen denen der auf NN basierenden Algorithmen liegen. Abbildung 5.9 gibt Einblicke in die Abweichungen rückgefederter Biegewinkel aller durchgeführten Validierungsversuche. Der Einsatz der MLR und des NN führt mehrfach auf Abweichungen von über einem Grad, was inakzeptabel für eine industrielle Applikation ist. Das CNN geht dagegen nur selten mit Abweichungen von über  $0,5^{\circ}$  einher und nur ein einziges Mal mit einer Abweichung von knapp über  $1^{\circ}$ .

Abbildung 5.10 stellt die rückgefederter Biegewinkelabweichungen sowohl für die unterschiedlichen Materialien als auch Modelle separiert voneinander dar. Aus den WDF und eingezeichneten Mittelwerten geht hervor, dass alle Algorithmen zu unterschiedlichen Abweichungsverteilungen für die Materialien führen. Alle Algorithmen führen bei der Nutzung von Stahlblech zu geringeren Biegewinkelabweichungen, wohingegen das Aluminiumblech aufgrund positiver Abweichungen tendenziell überbogen wird. Die größte Genauigkeit und damit den niedrigsten, systematischen mittleren Fehler weist die Anwendung der MLR auf, wohingegen das CNN auf die

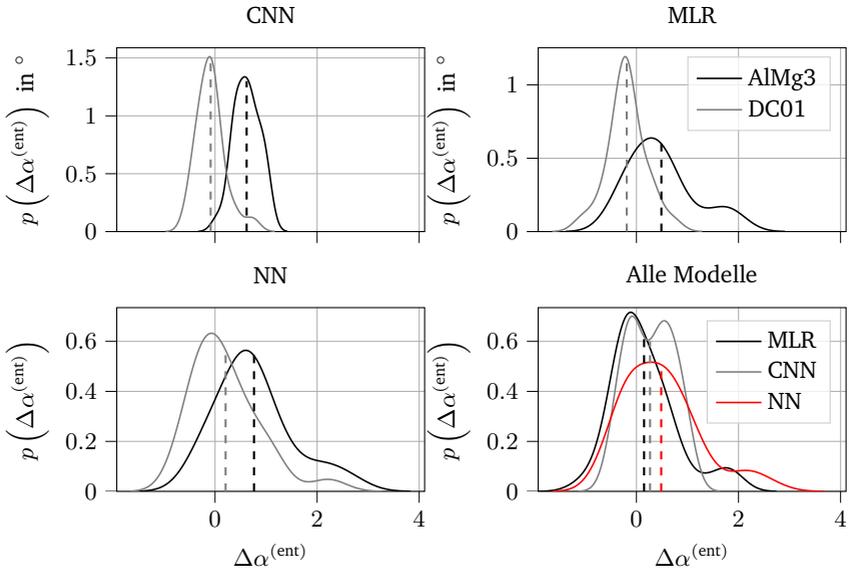


Abbildung 5.10.: Modell- und materialspezifischer Vergleich der Abweichungen rückgefederter Biegewinkel anhand geschätzter WDF  $p(\Delta\alpha^{(ent)})$

höchste Präzision und damit die geringste Streuung führt.

### Variationen der Blechdicke

Im zweiten Untersuchungsansatz werden die Auswirkungen geringfügiger Blechdickenschwankungen auf die Performanz des KI-gestützten Produktreglers untersucht. Dazu werden die Ausgangsblechdicken (1 mm; 1.5 mm & 2 mm) der Biegeteile aus dem Werkstoff DC01 durch schleifende Bearbeitung um bis zu 0.27 mm reduziert und geprüft, ob die Algorithmen fähig sind, aus den aufgenommenen Kraftsignalen die Auswirkungen reduzierter Blechdicken auf die Rückfederung zu erlernen. Analog zur beschriebenen Vorgehensweise aus Kapitel 5.1.3 ergibt sich für die Untersuchungen hinsichtlich Blechdickenvariationen der in Tabelle 5.5 dargelegte Versuchsplan, der gleichzeitig Einblicke in die Variationen der Blechdickenbereiche gibt. Insgesamt werden 171 Versuche durchgeführt und belastete Biegewin-

Tabelle 5.5.: Überblick über Versuchsplan zur Entwicklung des KI-gestützten Produktreglers bei geringfügigen Blechdickenvariationen

Material	$t_b \in \dots$ in mm	Biegewinkel unter Last $\alpha_{\text{soll}}^{(\text{be})} \in \dots$ in $^\circ$	Versuche
DC01	[0.85, 1.0]	{30, 33, 36, 39, 42, 45, 48}	57
DC01	[1.26, 1.51]	{30, 33, 36, 39, 42, 45, 48}	57
DC01	[1.73, 2.01]	{30, 33, 36, 39, 42, 45, 48}	57

Tabelle 5.6.: Überblick über Versuchsplan bei schwankenden Blechdicken für Validierungsversuche des KI-gestützten Produktreglers

Material	$t_b \in \dots$ in mm	Entlasteter Biegewinkel $\alpha_{\text{soll}}^{(\text{ent})} \in \dots$ in $^\circ$	Versuche
DC01	[0.84, 1.0]	{28, 29, 31, 32, 34, 35, 37, 38, 40, 41, 43, 46}	36
DC01	[1.31, 1.49]	{28, 29, 31, 32, 34, 35, 37, 38, 40, 41, 43, 46}	36
DC01	[1.8, 2.0]	{28, 29, 31, 32, 34, 35, 37, 38, 40, 41, 43, 46}	36

kel in 3-Grad-Inkrementen zwischen  $30^\circ$  und  $48^\circ$  angefahren. Analog zu dem in Kapitel 5.1.4 bereits angewandtem Vorgehen führt die Anwendung des Wrapper-Algorithmus zur Kennwertselektion für die MLR auf eine Kennwertanzahl von 4, wohingegen der korrelationsbasierte Filter-Ansatz für das NN ( $r_{i,\text{Pea}} > 0,7$ ) auf die Selektion von 56 Kennwerten führt. Dies führt wiederum auf die Dimensionen  $\mathbf{K}_{\text{MLR}} \in \mathbb{R}^{171 \times 4}$ ,  $\mathbf{K}_{\text{NN}} \in \mathbb{R}^{171 \times 56}$  und  $\mathbf{S}_{\text{K}} \in \mathbb{R}^{171 \times 4751}$ , welche als Eingangsgrößen für die Modellbildung dienen. Der Versuchsplan zur Durchführung entsprechender Validierungsversuche ist Tabelle 5.6 zu entnehmen, wobei pro Blechdickengruppe 36 Versuche durchgeführt werden und die Blechdicken sich in der angegebenen Toleranz befinden.<sup>4</sup> Abbildungen 5.11 und 5.12 geben eine Übersicht über die resultierenden Abweichungen des rückgefederten Biegewinkels und darauf basierend geschätzte WDF. Da der Einfluss eines zweiten Werkstoffs im Vergleich zu Kapitel 5.1.4 entfällt, sind die erzielten Genauigkeiten für alle Modellarten erheblich höher. Bis auf einen Versuch, bei dem das NN die Aufgabe des KI-gestützten Produktreglers

<sup>4</sup>Ergebnisse der Bayes'schen Hyperparameteroptimierung sind im Anhang in Tabelle A.4, mittlere quadratische Biegewinkelabweichungen trainierter Modelle auf Test- und Trainingsdatensatz in Tabelle A.5 zu finden.

Tabelle 5.7.: Fehlermetriken für rückgefederte Biegewinkel unter Einsatz der unterschiedlichen Modelle als KI-gestützter Produktregler und Korrelationskoeffizienten der Rückfederungen zwischen Messungen und modellbasierten Prädiktionen

Fehlermetrik	MLR	NN	CNN
$x_{MQA}^{(ent)}$ in $^{\circ 2}$	0,062	0,52	0,078
$\max( \Delta\alpha^{(ent)} )$ in $^{\circ}$	0,49	1,49	0,59
$r_{Pea}^{(ist Mod)}$	0,72	0,31	0,73

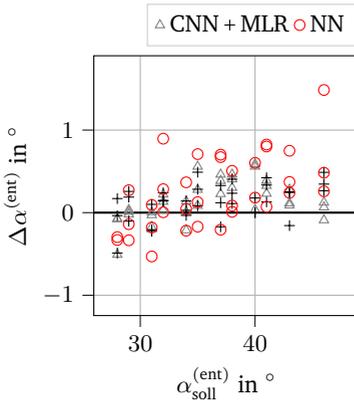


Abbildung 5.11.: Biegewinkelabweichungen  $\Delta\alpha$  für unterschiedliche Modellarten

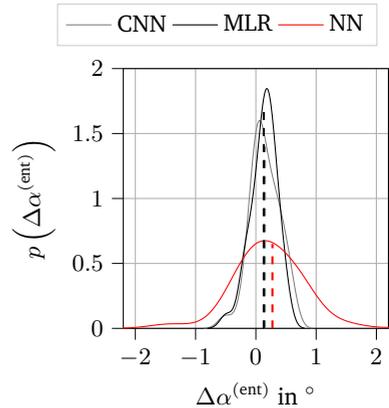


Abbildung 5.12.: Vergleich modellspezifischer WDF

übernimmt, kann der Biegewinkel in allen Validierungsversuchen auf  $\pm 1^{\circ}$  genau eingeregelt werden. Sowohl aus den geschätzten WDF in Abbildung 5.12 als auch aus den in Tabelle 5.7 erfassten Fehlermetriken geht hervor, dass die MLR und das CNN zu ähnlichen Biegewinkelabweichungen führen, wohingegen das NN die Biegewinkel erheblich schlechter einstellt. Abbildung 5.13 gibt Einblicke in die Korrelationen zwischen gemessenen und durch die Modelle prädierte Rückfederungen und der Blechdicke. Eingezeichnet sind für die jeweiligen Blechdickenbereiche lineare Regressionsgleichungen mit entsprechenden Bestimmtheitsmaßen  $R^2$ . Dabei korreliert die Blechdicke negativ mit der gemessenen Rückfederung, wobei die Stärke der negativen Korrelation mit zunehmender Blechdicke abnimmt. Dies ist an den abnehmenden Bestimmtheitsmaßen und abnehmenden Regressionssteigungen

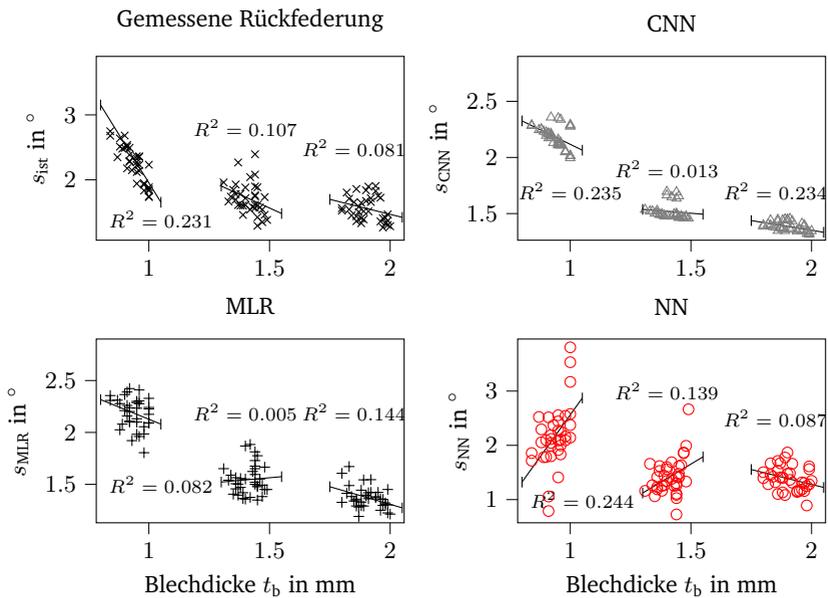


Abbildung 5.13.: Vergleich gemessener und durch unterschiedliche Modelle prädi-zierter Rückfederungen für Biegeversuche mit variierender Blechdicke

zu erkennen, die für den Blechdickenbereich  $t_b \in [0, 84, 1.0]$  mm auf  $R^2 = 0.231$  führt, wohingegen für  $t_b \in [1, 31, 1.49]$  mm  $R^2 = 0.107$  und für  $t_b \in [1, 8, 2]$  mm  $R^2 = 0.081$  gilt. Die Prädiktionen des CNN und der MLR bilden die negativen Korrelationen zwischen Blechdicke und Rückfederung weitestgehend ab, wohingegen die Prädiktionen des NN in zwei der drei Blechdickenbereiche auf stark positive Korrelationen führt und demnach nicht fähig sind, die sich aus den Blechdickenvariationen ergebenden Auswirkungen auf die Rückfederung zu erlernen. Lässt man die Rückfederungsprädiktionen der Modelle  $s_{\text{Mod}}$  für  $\text{Mod} \in [\text{CNN} \text{ MLR} \text{ NN}]$  mit den gemessenen Biege­winkeln  $s_{\text{ist}}$  linear korrelieren, erhält man die in Tabelle 5.7 erfassten Pearson-Korrelationskoeffizienten  $r_{\text{Pea}}^{(\text{ist}|\text{Mod})}$ . Auch anhand dieser Werte lässt sich die Überlegenheit des CNN und der MLR gegenüber dem NN verdeutlichen, aus Kraftsignalen die zu erwartende Rückfederung zu präzisieren.

### 5.1.5. Performanzvergleich weißer und schwarzer Modelle

Nachdem die in Kapitel 5.1.4 angewandten Black-Box-Modelle auf den Biegeprozess appliziert wurden und sich das CNN kapitelübergreifend am qualifiziertesten für die Regelaufgabe erwiesen hat, stellt sich die Frage, ob der KI-gestützte Produktregler analytischen White-Box-Modellen überlegen ist. Dazu werden die Biege­winkel­prädiktionen des CNN aus den Validierungsversuchen aus Kapitel 5.1.4 mit denen eines analytischen White-Box-Modells nach [BC04] gegenübergestellt. Das zur Prädiktion von Rückfederungen in Abkantprozessen von Buranathiti und Cao entwickelte, analytische White-Box-Modell basiert auf elastostatischen Gleichungen und erlaubt eine Prognose der Rückfederung unter Kenntnis von multiplen Material- und Prozessparametern. Vereinfacht kann die Rückfederungsprognose nach [BC04] durch die analytische Funktion

$$s_{\text{ana}} = f_{\text{ana}} \left( E, Y, t, R, v, n, K, \alpha^{(\text{be})} \right) \quad (5.4)$$

beschrieben werden, wobei  $E$  den Elastizitätsmodul,  $Y$  die Streckgrenze,  $t$  die Blechdicke,  $R$  den Radius der verrundeten Biegekante,  $v$  die Poissonzahl,  $n$  den Verfestigungsexponenten,  $K$  die Verfestigungskonstante nach Ludwik und  $\alpha^{(\text{be})}$  den im Prozess maximal vorliegenden Biege­winkel unter Last darstellen. Vorteilhaft bei der Nutzung von White-Box-Modellen ist eine Berücksichtigung von Unsicherheiten

$\delta x_i$  in den Eingabeparametern  $x_i$ . Eine Fortpflanzung der Unsicherheit modellierter Eingangsgrößen auf die Prädiktion des Biegewinkels ist, wie in [E18] für ingenieurtechnische Anwendungen demonstriert, durch eine Gauß'sche Fehlerfortpflanzung der Form

$$\delta s = \sqrt{\sum_{i=1}^N \left( \frac{\partial f_{\text{ana}}}{\partial x_i} \cdot \delta x_i \right)^2} \quad (5.5)$$

möglich, wobei die partiellen Differenzialterme in geeigneter Softwareumgebung durch symbolisches Differenzieren erzeugbar sind. Eine Implementierung des Modells in *Python*, eine Differenzierung unter Zuhilfenahme der Bibliothek *SymPy* [Meu17] und die Einspeisung der in Tabelle A.6 festgehaltenen Eingangsgrößen mitsamt Unsicherheiten führt auf die in Abbildung 5.14 rot gekennzeichneten Prädiktionen mit transparent hinterlegten Unsicherheitsintervallen. Gleichzeitig sind

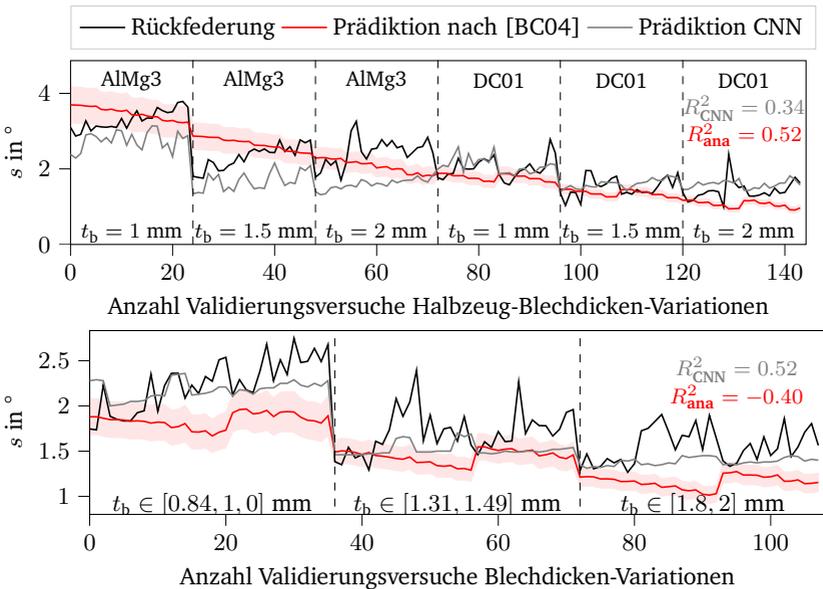


Abbildung 5.14.: Modell- und materialspezifischer Vergleich der Abweichungen rückgefederter Biegewinkel anhand geschätzter WDF  $p(\Delta\alpha^{(\text{ent})})$

Abbildung 5.14 die gemessenen und durch das CNN prädizierten Rückfederungen

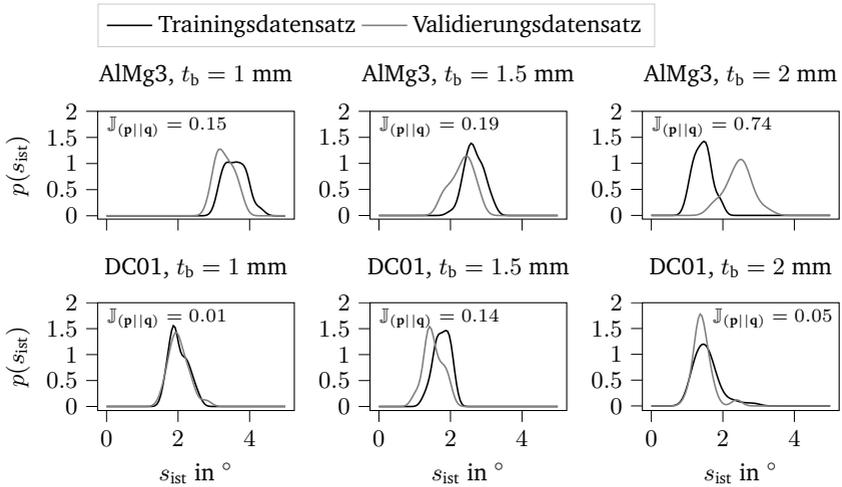


Abbildung 5.15.: Geschätzte WDF der gemessenen Rückfederungen auf Trainings- und Validierungsdatensatz aus Kapitel 5.1.4 und dazugehörige Jensen-Shannon-Divergenzen  $\mathbb{J}(p||q)$

zu entnehmen. Durch einen Abgleich gemessener und prädizierter Rückfederungen werden die in Abbildung 5.14 festgehaltenen Bestimmtheitsmaße berechnet. Für die Validierungsversuche aus Kapitel 5.1.4, in denen sowohl Material als auch Blechdicke variiert wurden, zeigt sich, dass das analytische Modell zu genaueren Prädiktionen und damit einem höheren Bestimmtheitsmaß führt. Dies ist zurückzuführen auf systematische Abweichungen zwischen Prädiktionen des CNN und gemessener Rückfederung unter Nutzung der Aluminiumlegierung. Hinsichtlich der Versuche aus Kapitel 5.1.4 ist erkennbar, dass das CNN dem analytischen Modell deutlich überlegen ist. Das analytische Modell unterschätzt die Rückfederung in den meisten Versuchen und führt im Gegensatz zum CNN auf ein negatives Bestimmtheitsmaß. Ein Erklärungsansatz für die mangelnde Prädiktionsgüte des CNN für die Aluminiumbauteile bei den Versuchen mit Halbzeug-Blehdicken-Variationen lässt sich durch eine Analyse von dessen Ein- und Ausgangsgrößen herleiten. Abbildung 5.15 bildet geschätzte WDF der gemessenen Rückfederungen  $s_{ist}$  für die unterschiedlichen Halbzeug-Blehdicken-Kombinationen ab, die das Resultat der Trainings- und Validierungsversuche darstellen. Aufgrund der Experimentdurchführung an unter-

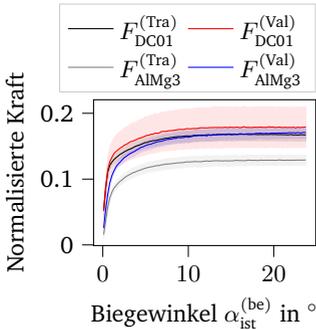


Abbildung 5.16.: Kraftsignale auf Trainings- und Validierungsdatensatz

	$\mathbb{W}_{i,1\text{mm}}$	$\mathbb{W}_{i,1.5\text{mm}}$	$\mathbb{W}_{i,2\text{mm}}$
$\mathbb{W}_{\text{DC01},j}^{(\text{Tra})}$	0.33	4.58	1.67
$\mathbb{W}_{\text{DC01},j}^{(\text{Tra} \text{Val})}$	2.34	2.91	1.74
$\mathbb{W}_{\text{AlMg3},j}^{(\text{Tra})}$	0.33	0.34	0.94
$\mathbb{W}_{\text{AlMg3},j}^{(\text{Tra} \text{Val})}$	1.84	3.53	5.86

Tabelle 5.8.: Wasserstein-Distanzen zur Quantifizierung der Ähnlichkeit datensatzübergreifender und -spezifischer WDF basierend auf Kraftsignalen

schiedlichen Versuchstagen und der Nutzung von Material aus unterschiedlichen Chargen ist divergierendes Rückfederungsverhalten zu beobachten. Quantifizieren lassen sich Unterschiede der jeweiligen WDF durch die in Anhang A.12 beschriebene Jensen-Shannon-Divergenz  $\mathbb{J}_{(p||q)} \in [0, 1]$ . Eine Jensen-Shannon-Divergenz von 0 geht mit identischen WDF einher, wohingegen ein Wert von 1 auf starke Abweichungen zwischen beiden Funktionen hindeutet. Hohe Unterschiede zwischen dem Rückfederungsverhalten auf Trainings- und Validierungsdatensatz lassen sich für die Aluminiumbauteile verzeichnen, wohingegen die WDF der Rückfederungen von Stahlbauteilen weitestgehend gut übereinstimmen, was ebenfalls durch niedrige Jensen-Shannon-Divergenzen bestätigt wird. Unterschiede der als Eingangsgrößen dienenden Kraftsignale zwischen Trainings- und Validierungsdatensatz werden mithilfe der Wasserstein-Distanz  $\mathbb{W}_{ij}^{(\text{Tra}|\text{Val})}$  quantifiziert, deren Beschreibung und Berechnungsvorschriften für den vorliegenden Anwendungsfall in Anhang A.13 enthalten sind. Unterschiede innerhalb des Trainingsdatensatzes werden durch  $\mathbb{W}_{ij}^{(\text{Tra})}$  erfasst, dienen als Vergleichswert und beruhen auf einer gleichmäßigen Aufteilung des Trainingsdatensatzes und der Berechnung der dazugehörigen, multivariaten WDF.<sup>5</sup>

Abbildung 5.16 zeigt Mittelwerte und 80%-Konfidenzintervalle von Kraftsignalen 1 mm dicker Stahl- und Aluminiumbauteile für Trainings- ( $F_{i,1\text{mm}}^{(\text{Tra})}$ ) und Validierungs-

<sup>5</sup>Für nähere Informationen sei auf Anhang A.13 verwiesen.

---

datensatz  $\left(F_{i,1\text{mm}}^{(\text{Val})}\right)$ . Für die Aluminiumbauteile ist ersichtlich, dass die Kraftsignale stark voneinander abweichen und sich die Konfidenzintervalle von Trainings- und Validierungsdatensatz nicht überlappen. Für die Stahlbauteile überlappen die Konfidenzintervalle durchgehend, der qualitative und quantitative Mittelwertverlauf stimmen gut überein. Unterschiede sind jedoch in den Konfidenzintervallen zu erkennen, da die Kraftsignale des Validierungsdatensatzes deutlich stärker streuen. Jene Unterschiede lassen sich ebenfalls aus den in Tabelle 5.8 erfassten Wasserstein-Distanzen ablesen. Während die datensatzspezifischen Wasserstein-Distanzen  $\mathbb{W}_{i,1\text{mm}}^{(\text{Tra})} = 0.33$  Vergleichswerte darstellen, drücken sich die unterschiedlichen quantitativen Verläufe (AlMg3, 1mm) und Varianzen (DC01, 1mm) in vergleichsweise hohen Wasserstein-Distanzen (1.84 bzw. 2.34) aus. Diese Unterschiede lassen sich für alle Blechdicken bei Verwendung von Aluminiumbauteilen verzeichnen, da Unterschiede der Kraftsignale zwischen Trainings- und Validierungsdatensatz für Stahlbauteile mit höheren Blechdicken erheblich niedriger sind. In Kombination mit den unterschiedlichen Rückfederungen zwischen Trainings- und Validierungsdatensatz für Aluminiumbauteile (siehe Abbildung 5.15) kann so erklärt werden, weshalb das CNN die Rückfederungen der Aluminiumbauteile (siehe Abbildung 5.14) unpräzise prädiziert, wohingegen die Rückfederungen von Stahlbauteilen mit deutlich höherer Genauigkeit vorhergesagt werden können.

Dies lässt darauf hindeuten, dass auf den Prozess einwirkende Unsicherheit in Form von beispielsweise Halbzeugschwankungen, Modifizierungen des Versuchsaufbaus oder Messunsicherheit die Performanz von überwachten Lernansätzen massiv beeinflussen. Im präsentierten Anwendungsfall sind Trainings- und Validierungsdatensatz an unterschiedlichen Versuchstagen aufgenommen worden, wobei zwischen den Versuchstagen ein Werkzeugeinbau und -ausbau erfolgte und das für Trainings- und Validierungszwecke eingesetzte Halbzeug aus unterschiedlichen Chargen stammt. Damit geht eine Gefährdung der Reproduzierbarkeit von Rückfederungsverhalten und Messdatenaufnahme einher, die aufgrund der mangelnden Modellrobustheit von überwachten Lernansätzen resultierende Performanzen stark gefährden. Weiterhin bieten überwachte Lernansätze nur begrenzte Modellflexibilität und adaptieren sich nicht eigenständig an neue experimentelle Bedingungen. Dies resultiert bei der Anwendung überwachter Lernalgorithmen oftmals in einem zeitlich degradierendem Performanzverhalten [Vel22], woraus sich die Notwendigkeit der Anwendung flexibilitätsfördernder Techniken ergibt. Dabei können *Domain Adaptation*-Techniken [E7],

---

die mitunter die Diskrepanz beschriebener Wasserstein-Distanzen zwischen zeitlich versetzt aufgenommenen Datensätzen minimieren [She18], oder kontinuierliche Lernansätze [Par19], die ein stetes Nachtrainieren der Modelle ermöglichen, zum Einsatz kommen. Ein weiterer Ansatz ist die Nutzung von RL, deren Modelladaptivität durch eine fortlaufende Zuordnung von Belohnungswerten zu gewählten Aktionen sichergestellt wird. Dieser Ansatz wird im folgenden Unterkapitel für einen V-Gesenkbiegeprozess verfolgt.

## **5.2. Anwendung bestärkender Lernalgorithmen auf Gesenkbiegeprozess**

Im zweiten Anwendungsfall werden die Potenziale von RL zur Regelung eines V-Gesenkbiegeprozesses demonstriert. Ziel der Anwendung ist erneut eine möglichst genaue Einstellung des rückgefederten Biegewinkels unter Nutzung unterschiedlicher Materialien. Dazu wird ein flexibles Gesenkbiegewerkzeug für den Prototypen der 3DSP konstruiert und in Betrieb genommen, das die Einstellung von Biegewinkeln zwischen  $80^\circ$  und  $110^\circ$  ermöglicht. Analog zu den vorgestellten Untersuchungen am Freibiegeprozess werden im Folgenden der Versuchsaufbau, das Regelungskonzept sowie das Vorgehen zum Entwurf des KI-gestützten Produktreglers dargelegt. Anschließend erfolgt eine Präsentation der Ergebnisse in Kapitel 5.2.4, wobei auf FEM-Simulationen basierende als auch experimentelle Ergebnisse vorgestellt werden. Eine zu Abbildung 5.1 (Freibiegen) korrespondierende Darstellung der Spannungsverläufe und Biegewinkel ist Abbildung 5.17 zu entnehmen. Diese dient erneut der Visualisierung von prädizierten und gewünschten Biegewinkeln für den V-Gesenkbiegeprozess, deren Bezeichnung konsistent zum vorangegangenen Unterkapitel gehalten wird.

### **5.2.1. Versuchsaufbau**

Die experimentellen Versuche werden mit drei unterschiedlichen Materialien (DC01, AlMg3, Cu) in zwei (0.5 mm, 1 mm) bzw. drei unterschiedlichen Blechdicken (zusätzlich 0.75 mm für DC01) durchgeführt. Die Experimente werden erneut auf dem

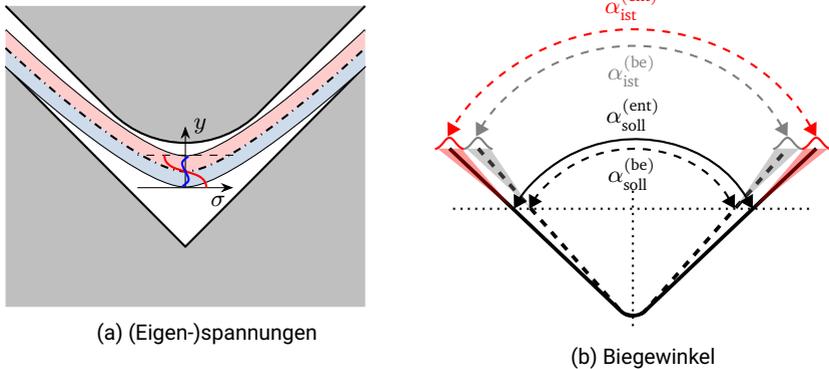
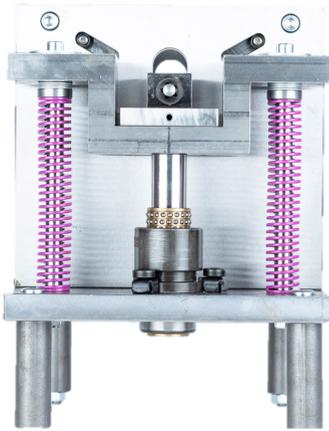


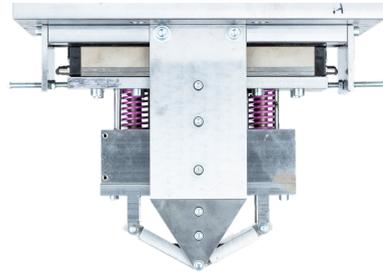
Abbildung 5.17.: Spannungszustände und Biegewinkel im V-Gesenkbiegeprozess

Prototypen der 3DSP durchgeführt und Biegewinkel zwischen  $80^\circ$  und  $110^\circ$  eingestellt. Zur Realisierung des Versuchsplans ist ein flexibles Gesenkbiegewerkzeug notwendig, das in Abhängigkeit der vertikalen Stößeltranslation  $z_{st}$  den Biegewinkel manipulieren kann. Dazu wird das in Abbildung 5.18 dargestellte Gesenkbiegewerkzeug konstruiert und gefertigt, das aus einem flexiblem V-Gesenk und dazugehörigem Stempel besteht. Die Gesenkhälften werden in der Gesenkmitte durch eine Welle rotatorisch geführt, die einen gemeinsamen Drehpunkt beider Gesenkhälften darstellt. Im oberen Bereich beider Gesenkhälften sind Zapfen angebracht, die in die an den Gesenkaußenwänden vorgesehenen Langlöcher eingreifen, wodurch die kinematische Kopplung zwischen Hubhöhe und Gesenkwinkel sichergestellt wird. Ein ähnliches Konstruktionsprinzip wird für den Stempel erarbeitet, bei dem der gemeinsame Drehpunkt beider Stempelhälften an der Stempelspitze angeordnet ist und sich der Stempelwinkel aus der orthogonal zur Hubrichtung wirkenden Translation der Führungsschlitzen im oberen Stempelteil ergibt.<sup>6</sup> Die kontinuierliche Biegewinkelerfassung erfolgt analog zum Freibiegeprozess aus Kapitel 5.1 über eine CMOS-Kamera (aca2040-25gm - Basler ace), die die Kanten der Gesenkhälften kontinuierlich erfasst und deren Winkel zueinander über Kantendetektionsalgorithmen und trigonometrische Beziehungen bestimmt. Erneut findet das *Lab-VIEW Vision*

<sup>6</sup>Weitere Visualisierungen des Werkzeugs in Form von Prinzipskizzen (Abbildung A.18), CAD-Darstellung (Abbildung A.21) und Bildern aus dem Prozess (Abbildung A.22) sind Anhang A.14 zu entnehmen. Eine detaillierte Beschreibung der Werkzeugkonstruktion befindet sich in [S14].



(a) Gesenk



(b) Stempel

Abbildung 5.18.: Bilder des Gesenkbiegewerkzeugs bestehend aus Gesenk und Stempel [S14]

*Assistant Express VI* Anwendung, das die Bilder mit einer Abtastfrequenz von etwa 25 Hz auswertet.

### 5.2.2. Regelungskonzept

Abbildung 5.19 stellt das Blockschaltbild der Regelungsstrategie für das V-Gesenkbiegen dar. Im Vergleich zur Regelung des Freibiegens ergeben sich dabei zwei elementare Unterschiede. Da die Performanz bestärkender Lernalgorithmen in besonderem Maße von einer hoher Datenverfügbarkeit abhängt [Dul20] und eine experimentelle Aufnahme eines solchen Datensatzes nur unter enormem Ressourceneinsatz realisierbar ist, wird auf eine FEM-Simulation zurückgegriffen, mithilfe der synthetisierte Daten erzeugt werden. In der Simulation wird ein Datensatz aufgenommen, der aus jeder durchgeführten Simulation sowohl den belasteten und entlasteten Biegewinkel  $\alpha_{\text{ist}}^{(\text{be})}$  bzw.  $\alpha_{\text{ist}}^{(\text{ent})}$  als auch Materialparameter  $\mathbf{m}$  speichert. Dabei ist die FEM-Simulation mit dem RL-Algorithmus gekoppelt, sodass die Aktionswahl des Algorithmus den belasteten Biegewinkel determiniert und Materialparameter, die dem Algorithmus zusammen mit dem entlasteten Soll-Winkel  $\alpha_{\text{soll}}^{(\text{ent})}$  als Zustände

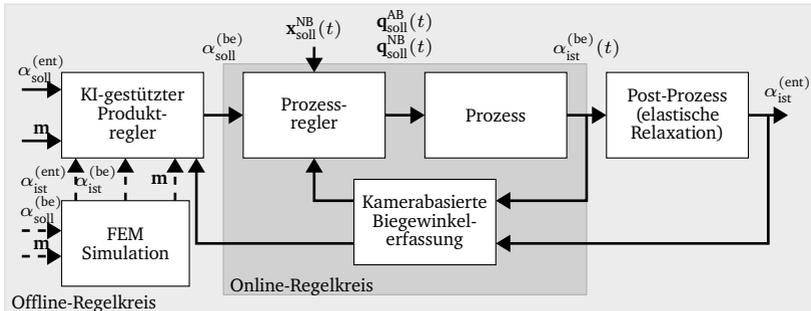


Abbildung 5.19.: Blockschaltbild des eigenschaftsgeregelten Gesenkbiegeprozesses

zugeführt werden, zufällig gewählt werden. Das auf Simulationsdaten basierende RL-Modell wird anschließend experimentell validiert, wobei die unweigerlich auftretenden Unterschiede zwischen Simulationen und Experimenten<sup>7</sup> durch erneute Updates der Entscheidungsstrategie Berücksichtigung finden. Beim Update werden die Simulationsdaten durch Experimentaldaten substituiert, wodurch eine Modelladaptation an die experimentellen Prozessbedingungen erfolgen soll. Die Nutzung der Simulation zur Generierung synthetisierter Daten geht mit dem Umstand einher, dass ausschließlich in der Simulation erfassbare Daten als Zustände für den RL-Algorithmus herangezogen werden können. Daher wird auf eine Erhebung von Kraftsignalen verzichtet, sodass ausschließlich sowohl in der Simulation als auch im Experiment vorliegende Materialparameter  $\mathbf{m}$  als Zustandsgrößen genutzt werden.

Der restliche Aufbau des Regelungskonzeptes bleibt im Vergleich zum Freibiegeprozess aus Kapitel 5.1 unverändert. Der KI-gestützte Produktregler gibt als Ausgangsgröße einen Soll-Biegewinkel im belasteten Zustand  $\alpha_{\text{soll}}^{(\text{be})}$  aus, der innerhalb des Online-Regelkreises durch den Prozessregler kamerabasiert eingeregelt wird. Die im Werkzeugraum verbaute Kamera misst sowohl den belasteten als auch entlasteten Biegewinkel nach der Prozessdurchführung und stellt Letzteren dem Produktregler zur Verfügung. Für die Regelung gelten die gleichen Nebenbedingungen wie bereits in Formel 5.1 beschrieben. Die Führungsgrößen für die Stoßelkippfreiheitsgrade werden zu Null gesetzt, die Spindelantriebe regeln die Totpunkte der Maschine, so-

<sup>7</sup>In der RL-Literatur oftmals als *Sim-to-Real-Gap* bezeichnet [Zha20], welche zusätzliche Maßnahmen zum Transfer von Simulationsergebnissen in die Realität erfordert (siehe bspw. [ZQW20]).

---

dass diese äquidistant um die aktuelle Stößelhöhe platziert werden und die Hubhöhe 30 mm beträgt.

### 5.2.3. Entwurf des KI-gestützten Produktreglers

Im ersten Entwurfschritt des auf RL-Methoden basierenden Produktreglers erfolgt die Festlegung des Algorithmus. Da der Biegewinkel im belasteten Zustand die Ausgangsgröße des Produktreglers und damit eine metrisch skalierte Variable darstellt, bietet sich die Anwendung von Algorithmen mit kontinuierlichem Aktionsraum an. Gleichzeitig ist es wünschenswert, dass erhobene Datensätze mehrfach zum Nachtrainieren des Algorithmus genutzt werden können und nicht an die direkte Anwendung der jeweiligen Entscheidungsstrategie gebunden sind. Genannte Gründe schränken die Wahl auf Off-Policy AC-Algorithmen ein.<sup>8</sup> Mit Deep Deterministic Policy Gradient (DDPG), Twin Delayed Deep Deterministic Policy Gradient (TD3) und Soft Actor-Critic (SAC) stehen mehrere Off-Policy AC-Algorithmen bereit, die die genannten Anforderungen erfüllen. Aus Gründen geringerer Sensitivität gegenüber Hyperparametern als auch höheren Performanzen bei Anwendung in populären RL-Umgebungen [Haa18b] wird nachfolgend die Anwendung des SAC-Algorithmus fokussiert. Die Implementierung und das Training erfolgt in *Python* über die Bibliothek *StableBaselines3*. [Raf21] Abbildung 5.20 stellt den Ablauf zum Entwurf und der Anwendung des KI-gestützten Produktreglers dar. Die Untersuchungen gliedern sich dabei in einen simulativen und einen experimentellen Teil, die aufeinanderfolgend abgehandelt werden. RL- und insbesondere AC-Algorithmen zeichnen sich durch hohe Datenineffizienzen aus und bedürfen bei zustandsabhängigen Aktionswahlen großen Datenmengen. Daher wird im Schritt der simulativen Untersuchungen eine FEM-Simulation für den V-Gesenkbiegeprozess erstellt und mit einem *Python*-Skript verknüpft, bei dem der genutzte SAC-Algorithmus nach Einspeisung von Zuständen  $s_{SAC}^{(Sim)}$  den belasteten Soll-Biegewinkel prädiziert. Ein Vorteil der simulativen Untersuchungen ist die Beaufschlagung der Zustände mit Unsicherheit, um zu untersuchen,

---

<sup>8</sup>Für Erklärungen der Funktionsweisen von RL- und AC-Algorithmen sei auf Anhang A.9 verwiesen. Dieser beinhaltet die für das Verständnis von RL-Algorithmen elementaren Grundlagen und Lösungsansätze von Markov-Entscheidungsprozessen sowie die speziell für AC-Algorithmen relevanten Beschreibungen von parametrisierbaren Bewertungsfunktionen und Entscheidungsstrategien. Der für die nachfolgenden Untersuchungen relevante AC-Algorithmus Soft-Actor-Critic (SAC) wird detailliert in Anhang A.9.3 erklärt.

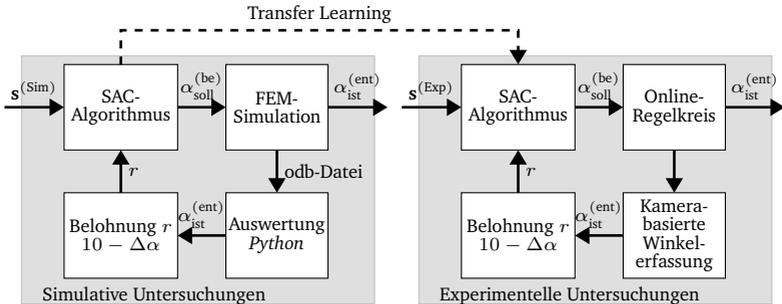


Abbildung 5.20.: Aufbau des KI-gestützten Produktreglers bei Anwendung auf Gesenkbiegeprozess

inwiefern der KI-gestützte Produktregler mit stochastisch schwankenden Parametern umgeht. Dazu werden simulative Untersuchungen mit zwei Zustandsräumen durchgeführt, die sich durch

$$\mathbf{s}^{(\text{Sim})} = \begin{cases} \mathbf{s}_{\text{dis}}^{(\text{Sim})} = \begin{bmatrix} \alpha_{\text{soll}}^{(\text{ent})} & t_b & m_{\text{dis}} \end{bmatrix}^T, & \text{diskreter Zustandsraum} \\ \mathbf{s}_{\text{st}}^{(\text{Sim})} = \begin{bmatrix} \alpha_{\text{soll}}^{(\text{ent})} & t_b & R_m & E & v \end{bmatrix}^T, & \text{stetiger Zustandsraum} \end{cases} \quad (5.6)$$

umschreiben lassen. Bei Verwendung des diskreten Zustandsraumes werden sowohl der Soll-Biegewinkel im entlasteten Zustand  $\alpha_{\text{soll}}^{(\text{ent})}$ , die Blechdicke  $t_b$  als auch der diskrete Materialparameter

$$m_{\text{dis}} = \begin{cases} 0, & \text{für DC01} \\ 0.5, & \text{für Alu} \\ 1, & \text{für Kupfer} \end{cases}, \quad (5.7)$$

der in Abhängigkeit des genutzten Materials zwischen den drei diskreten Werten variiert. Der stetige Zustandsraum charakterisiert das verwendete Material über die Zugfestigkeit  $R_m$ , das Elastizitätsmodul  $E$  und die Poisson-Zahl  $v$ , was den Vorteil birgt, dass die beiden letztgenannten Materialparameter mit Unsicherheit beaufschlagt und die Auswirkungen der Unsicherheit auf die Modellperformanz analysiert werden können. Dazu werden vier unterschiedliche, simulative Datensätze erzeugt, in denen die zwei Parameter mit unterschiedlich starker Unsicherheit beaufschlagt

Parameter	KU	GU	MU	HU
$E_i \pm \delta E$	$E_i \pm 0$	$E_i \pm 2500$	$E_i \pm 5000$	$E_i \pm 10000$
$v_i \pm \delta v$	$v_i \pm 0$	$v_i \pm 0.01$	$v_i \pm 0.02$	$v_i \pm 0.04$
$N$	3094	1725	3310	2069

Tabelle 5.9.: Unsichere Modellierung der Materialparameter in Abhängigkeit des verwendeten Simulationsdatensatzes ( $E_i$  in  $\text{N mm}^{-2}$ :  $E_{\text{DC01}} = 210000$ ,  $E_{\text{Alu}} = 70000$ ,  $E_{\text{Kup}} = 130000$ ;  $v_i$ :  $v_{\text{DC01}} = 0.3$ ,  $v_{\text{Alu}} = 0.33$ ,  $v_{\text{Kup}} = 0.35$ ) sowie Anzahl durchgeführter Simulationen  $N$

werden. Tabelle 5.9 stellt die Stichprobenanzahlen  $N$  sowie Unsicherheitsintervalle dar, wobei in den unsicherheitsbehafteten Simulationen die Materialparameter zufällig aus den jeweiligen Intervallen ausgewählt werden (Annahme: Gleichverteilung). Die Datensätze werden im Folgenden als *Keine Unsicherheit* (KU), *Geringe Unsicherheit* (GU), *Mittlere Unsicherheit* (MU) und *Hohe Unsicherheit* (HU) bezeichnet. Die gewählte Aktion des SAC-Algorithmus ( $\alpha_{\text{soll}}^{(\text{be})}$ ) wird an die in der Softwareumgebung *Abaqus* implementierte FEM-Simulation<sup>9</sup> übergeben und eine korrespondierende Simulation durchgeführt, deren Ergebnisdatei als odb-Datei abgespeichert und anschließend durch ein *Python*-Skript ausgewertet wird. Dabei werden die Knotenpositionen des Blechs in einem Numpy-Array festgehalten und zur Berechnung des Biegewinkels jeweils eine LR für jeden Biegeschenkel durchgeführt, deren Steigungen über trigonometrische Berechnungen abschließend zum Ist-Biegewinkel im entlasteten Zustand  $\alpha_{\text{ist}}^{(\text{ent})}$  führen. Die Güte der gewählten Aktion gilt es nach Auswertung des Biegewinkels über eine Belohnungsfunktion  $r$  zu quantifizieren, die zu

$$r = 10 - \Delta\alpha = 10 - \left| \alpha_{\text{soll}}^{(\text{ent})} - \alpha_{\text{ist}}^{(\text{ent})} \right| \quad (5.8)$$

gewählt wird. Nach der Durchführung der Simulationen wird das auf KU trainierte SAC-Modell mit stetigem Zustandsraum gespeichert und ein Transfer Learning (TL)-Ansatz<sup>10</sup> verfolgt, um das Modell in der realen Anwendung zu applizieren.

<sup>9</sup>Nähere Informationen über den Aufbau und Ablauf der FEM-Simulation sind den Abbildungen A.19 und A.20 sowie Tabelle A.9 in Anhang A.14 zu entnehmen. Eine detaillierte Beschreibung der Simulation befindet sich in [S14].

<sup>10</sup>TL bezeichnet die Nutzung vortrainierter ML-Modelle, deren Modellparameter auf einem Datensatz trainiert und anschließend auf einen anderweitigen Datensatz appliziert und feinabgestimmt werden. In der Regel werden TL-Techniken angewendet, um die Modellperformanz bei geringer Datenverfügbarkeit zu steigern. Für nähere Informationen über TL sei auf [WKW16] verwiesen, [Zhu23] diskutiert TL im Kontext der Anwendung von RL.

---

Dazu werden analog zum Freibiegeprozess aus Kapitel 5.1 kamerabasiert geregelte Gesenkbiegeversuche durchgeführt, in denen der SAC-Algorithmus wiederum den belasteten Soll-Biegewinkel  $\alpha_{\text{soll}}^{(\text{be})}$  vorgibt, der durch den Online-Regelkreis mithilfe der kamerabasierten Biegewinkelerfassung quasi-echtzeitlich eingeregelt wird. Ebenfalls detektiert die Kamera nach dem Prozess die Rückfederung und den entlasteten Ist-Biegewinkel  $\alpha_{\text{ist}}^{(\text{ent})}$ , woraufhin analog zu den simulativen Untersuchungen die Belohnung gemäß Formel 5.8 berechnet wird. Ziel des TL-Ansatzes ist die Prüfung, ob der Agent auf die unterschiedlichen Rückfederungen zwischen Simulation und Experiment adaptieren kann und demzufolge eine höhere Modelladaptivität aufweist als die in Kapitel 5.1 vorgestellten überwachten Lernalgorithmen.

## 5.2.4. Simulative und experimentelle Ergebnisse

### Simulative Ergebnisse

Die Durchführung der Simulationen führt auf das in Abbildung 5.21 visualisierte Rückfederungsverhalten für die drei untersuchten Materialien. Während in den oberen Plots die Rückfederung  $s_{\text{ist}}$  über den in der Simulation maximal vorliegenden belasteten Biegewinkel  $\alpha_{\text{ist}}^{(\text{be})}$  für Datensatz KU (Materialparameter nicht unsicherheitsbehaftet) dargestellt werden, sind entsprechende Plots für den unsicherheitsbehafteten Datensatz MU in der zweiten Zeile aufgetragen. Es wird ersichtlich, dass sowohl die Blechdicke als auch das verwendete Material elementaren Einfluss auf das Rückfederungsverhalten aufweisen und dass eine Beaufschlagung der Materialparameter mit Unsicherheit ebenfalls in Schwankungen der Rückfederungswerte resultiert.<sup>11</sup> Die gegensätzlichen Gradienten der Rückfederung für unterschiedliche Blechdicken lassen sich durch die notwendigen Prägekräfte erklären, die bei dickeren Blechen erheblich größer ausfallen. Die Prägekräfte werden in der Simulation als auch im realen Werkzeug weggebunden über Federn aufgebracht, wodurch gerade bei großen Gesenkwinkeln (und damit geringer Eintauchtiefe des Stempels in das Gesenk) nur moderate Prägekräfte aufgebracht werden können, welche bei dicken Blechdicken in hohen Rückfederungen resultieren. Jenes Phänomen ist für Alu mit einer Blechdicke von  $t_b = 1$  mm als auch für DC01 mit Blechdicken von

---

<sup>11</sup>Eine analoge Abbildung für die Datensätze GU und HU befindet sich in Anhang A.14 in Abbildung A.23 und unterstreicht den Einfluss von Unsicherheit auf die Rückfederung.

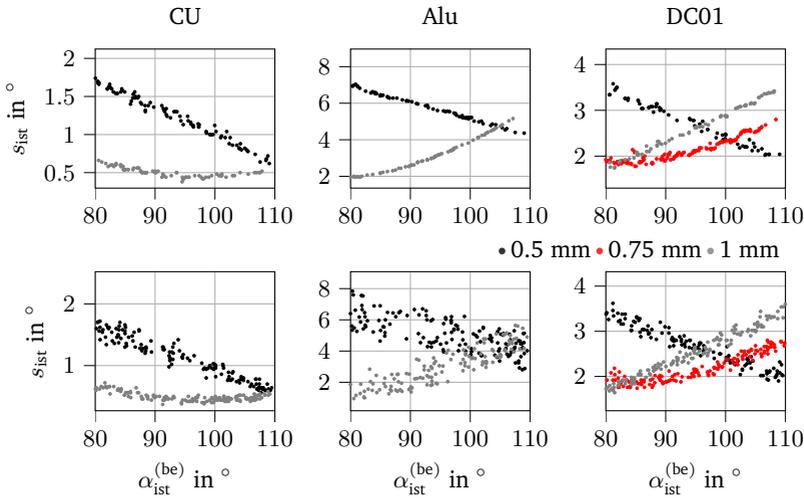


Abbildung 5.21.: Simulatives Rückfederungsverhalten für FEM-Simulationen mit konstanten (Datensatz KU oben) und unsicherheitsbehafteten Materialparametern (Datensatz MU unten)

$t_b \in [0.75 \quad 1]$  zu beobachten.

Abbildung 5.22 stellt sowohl für die unterschiedlichen Zustandsräume (diskret und stetig) als auch für die Datensätze KU (ohne Materialparameterschwankungen) und MU (mit Materialparameterschwankungen) die Belohnungsverläufe des SAC-Algorithmus während des Trainings dar. Der Lernbeginn der Algorithmen setzt nach 500 Trainingsschritten ein und führt für alle untersuchten Zustandsraum-Datensatz-Kombinationen auf ein ähnliches Konvergenzverhalten. Dabei treten lediglich geringfügige Performanzunterschiede zwischen stetigem und diskretem Zustandsraum auf, weswegen im weiteren Verlauf der Arbeit ausschließlich Algorithmen mit stetigem Zustandsraum analysiert werden. Dies bietet vor allem in der Simulation den Vorteil, dem Algorithmus Informationen über aufgebrachte Unsicherheit der Materialparameter zurückzuführen und zu prüfen, ob dieser entsprechende Informationen performanzfördernd verwerten kann. Abbildung 5.22 gibt ebenfalls Aufschluss über die Auswirkungen aufgebrachter Unsicherheit auf die erhaltenen Belohnungen, die bei Verzicht auf Materialparameterschwankungen (KU) höher ausfallen als im unsicherheitsbehafteten Fall (MU). Tabelle 5.10 lässt

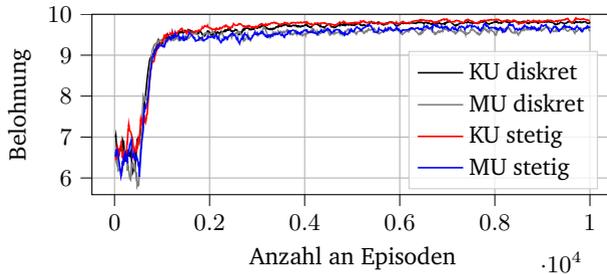


Abbildung 5.22.: Vergleich der Belohnungsverläufe bei Training des SAC-Algorithmus mit diskretem und stetigem Zustandsraum basierend auf Datensätzen mit (MU) und ohne Materialparameterschwankungen (KU)

tiefere Einblicke in das Performanzverhalten der Algorithmen bei unterschiedlichen Unsicherheitsgraden zu. Dabei wird unterschieden zwischen Modellen, die keine Informationen über schwankende Materialparameter erhalten (schwarz) und Modellen, die die exakten Werte der unsicherheitsbehafteten Materialparameter als Eingangszustände eingespeist bekommen und somit Kenntnis über die auftretende Unsicherheit haben (grau). Dargestellt werden in der Tabelle Mittelwerte der maximalen und durchschnittlichen Biegewinkelabweichungen aus 30 trainierten Modellen für jede Datensatz-Informationszustand-Kombination. Es ist ersichtlich, dass mit zunehmender Unsicherheit der Materialparameter die Performanz der Modelle abnimmt, wobei Kenntnisse über die im Prozess auftretende Unsicherheit erheblich zu einer Performanzsteigerung beitragen. Beispielsweise führt die Anwendung der mit Informationen über die Unsicherheit angereicherten Modelle auf den HU-Datensatz auf geringere maximale und durchschnittliche Biegewinkelabweichungen ( $1.72^\circ$  bzw.  $0.19^\circ$ ) als die Modelle ohne Kenntnis über auftretende Unsicherheit auf den GU-Datensatz ( $2.28^\circ$  bzw.  $0.21^\circ$ ). Im Gegensatz zu den Modellen ohne Zusatzinformationen zeigt die Performanz der mit Zusatzinformationen angereicherten Modelle eine Invarianz gegenüber zunehmenden Materialparameterschwankungen auf, woraus geschlossen werden kann, dass die Modelle fähig sind, die Auswirkungen auftretender Unsicherheit auf die Rückfederung zu erlernen und zu kompensieren. Abbildung 5.23 visualisiert die zunehmenden Biegewinkelabweichungen mit steigender Unsicherheit für die nicht mit Informationen angereicherten Modelle als WDF. Anhand der Abbildung ist ersichtlich, dass die Streuungen der Winkelabweichungen

Fehlermetrik	KU	GU	MU	HU
$\max( \Delta\alpha )$ in $^\circ$	0.88	2.28	2.58	4.52
$\max( \Delta\alpha )$ in $^\circ$	-	1.59	1.96	1.72
$\overline{ \Delta\alpha }$ in $^\circ$	0.16	0.21	0.33	0.51
$\overline{ \Delta\alpha }$ in $^\circ$	-	0.17	0.19	0.19

Tabelle 5.10.: Maximale und durchschnittliche Biegewinkelabweichungen unter Einsatz des SAC-Algorithmus als KI-gestützter Produktregler auf den unterschiedlichen Simulationsdatensätzen ohne (schwarz) und mit Kenntnis (grau) über Unsicherheit der Materialparameter (Mittelwerte basierend auf jeweils 30 trainierten Modellen)

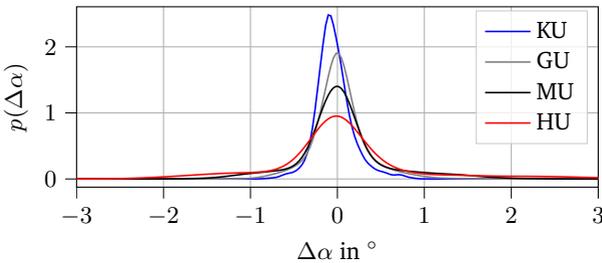


Abbildung 5.23.: Vergleich von WDF der Biegewinkelabweichungen unter Einsatz der Modelle auf mit unterschiedlichen Unsicherheitsgraden versehenen Simulationsdatensätzen

mit zunehmender Unsicherheit zunehmen und insbesondere auf dem HU-Datensatz Biegewinkelabweichungen von  $\pm 2^\circ$  eine nicht zu vernachlässigende Auftretenswahrscheinlichkeit aufweisen. Vergleicht man die in Abbildung 5.23 abgebildeten WDF mit denen der mit Informationen angereicherten Modelle, führt dies auf Abbildung 5.24. Dargestellt sind die entsprechenden Funktionen als Mittelwerte der 30 Modelle, die transparent hinterlegten Bereiche kennzeichnen die 99%-Konfidenzintervalle aus jeweils 30 WDF. Außerdem ist ersichtlich, dass die Performanz der Modelle mit Kenntnis über schwankende Materialparameter datensatzübergreifend vergleichbar bleibt, wohingegen die Modelle ohne ebendiese Kenntnis aufgrund schwankender Rückfederung (siehe Abbildung 5.21) einem Performanzverlust unterliegen. Während die Diskrepanzen zwischen beiden Modellvarianten für den GU-Datensatz noch relativ gering ausfällt, nehmen die Diskrepanzen der Biegewinkelabweichungen

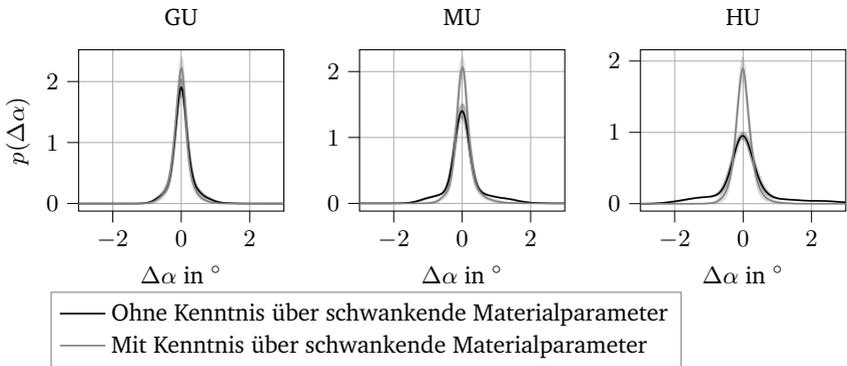


Abbildung 5.24.: Vergleich der WDF der Biegewinkelabweichungen für Modelle mit und ohne Kenntnis über auftretende Schwankungen der Materialparameter

zwischen den Modellvarianten mit steigender Unsicherheit zu. Daraus ist abzuleiten, dass eine Quantifizierung der sich auf die jeweilige Bauteileigenschaft übertragenden Unsicherheit insbesondere dann zielführend ist, sofern das Maß der auftretenden Unsicherheit als hoch einzustufen ist. In Anbetracht bereits untersuchter Korrelationen zwischen Halbzeugeigenschaften und sensorisch erfassten Prozessgrößen [Sch22], die sich letztendlich auch in Bauteileigenschaften widerspiegeln [Hav18; Gro16], bietet das vorgestellte Vorgehen die Möglichkeit, Schwankungen der Bauteileigenschaften in mehrstufigen Umformprozessen basierend auf Sensordaten vorgelagerter Stufen zu reduzieren. Dies geht in zukünftigen experimentellen Untersuchungen mit der Notwendigkeit einher, Unsicherheit in vorgelagerten Prozessstufen sensorisch zu erfassen und diese dem KI-gestützten Produktregler in Form von Signalen oder aus Signalen extrahierten Kennwerten bereitzustellen.

### Experimentelle Ergebnisse

Nachdem die simulativen Untersuchungen abgeschlossen sind, werden das auf dem KU-Datensatz trainierte Modell experimentell als KI-gestützter Produktregler eingesetzt und Versuche mit dem bereits beschriebenen Versuchsaufbau bestehend aus entwickeltem Werkzeug und kamerabasierter Online-Prozessregelung durchgeführt. Dazu werden drei unterschiedliche Versuchsreihen realisiert, deren Bezeichnungen

Datensatz	$N$	Winkelinkrement	$\alpha_{\text{soll}}^{(\text{ent})} \in \dots^\circ$
Sim2Real	95	$2.5^\circ$	[75, 110]
Training	330	$1^\circ$	[80, 110]
Validierung	175	$2.5^\circ$	[80, 110]

Tabelle 5.11.: Übersicht über experimentell durchgeführte Versuchsreihen und deren Versuchsparameter

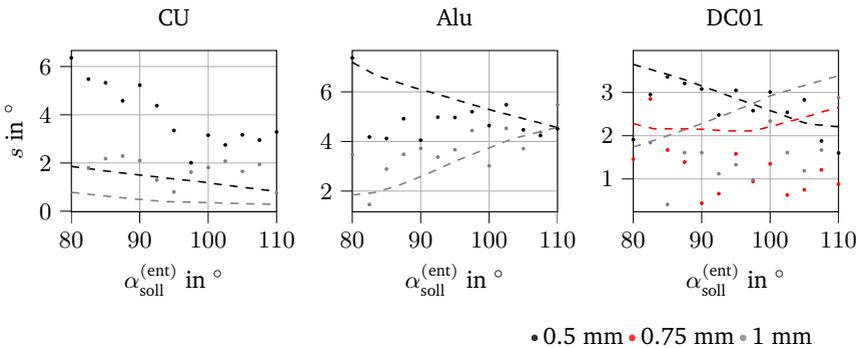


Abbildung 5.25.: Vergleich der experimentellen Rückfederungen auf dem Datensatz *Sim2Real* und den prädizierten Rückfederungen des ausschließlich auf Simulationsdaten trainierten SAC-Algorithmus (gestrichelte Linie)

und Versuchsparameter in Tabelle 5.11 aufgelistet sind. Der Datensatz *Sim2Real* wird genutzt, um die Performanz des in der Simulation entwickelten SAC-Algorithmus im experimentellen Prozess zu analysieren. Aufgrund von Unterschieden im Rückfederungsverhalten zwischen Simulation und Experiment wird mit dem *Trainingsdatensatz* eine umfangreiche Versuchsreihe durchgeführt, in denen die Soll-Biegewinkel in  $1^\circ$ -Inkrementen variiert werden. Der Datensatz wird im Anschluss genutzt, um den auf Simulationsdaten vortrainierten Agenten nachzutrainieren und auf das Rückfederungsverhalten im Experiment abzustimmen. Letztendlich wird die Performanz des nachtrainierten Agenten erneut mithilfe des *Validierungsdatensatzes* analysiert und geprüft, in welchem Maße die Sim-to-Real-Gap kompensiert werden kann. Abbildung 5.25 vergleicht die vom SAC-Algorithmus prädizierten Rückfederungswerte mit den real auftretenden des Datensatzes *Sim2Real*. Es ist ersichtlich,

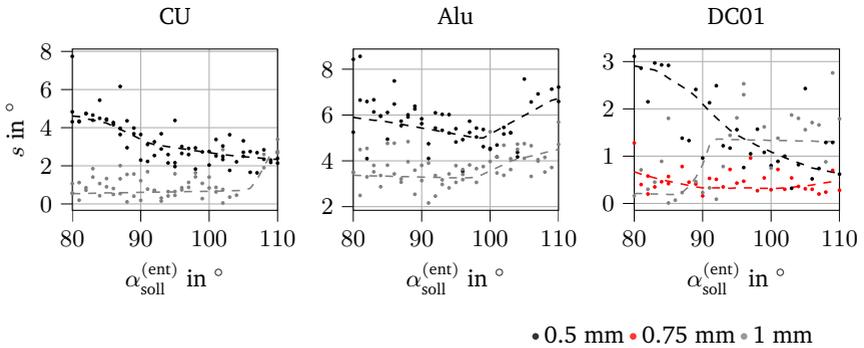


Abbildung 5.26.: Vergleich der experimentellen Rückfederungen auf dem *Trainingsdatensatz* und den prädizierten Rückfederungen des auf Experimentaldaten nachtrainierten SAC-Algorithmus (gestrichelte Linie)

dass elementare Unterschiede im Rückfederungsverhalten zwischen Simulation und Experiment auftreten, die der Algorithmus aufgrund fehlender Kenntnis über das reale Rückfederungsverhalten nicht erlernen kann. Zwar stimmen die Prädiktionen des SAC-Algorithmus stark mit den in Abbildung 5.21 dargestellten, simulativen Rückfederungswerten überein, jedoch federn insbesondere der Kupfer- und Aluminiumwerkstoff mit geringer Blechdicke anders als in der Simulation zurück. Aus diesem Grund wird der *Trainingsdatensatz* aufgenommen und der SAC-Algorithmus nachtrainiert, sodass dieser die Chance erhält, auf die experimentellen Gegebenheiten zu adaptieren.

Jene Adaption ist anhand von Abbildung 5.26 ersichtlich. Gezeigt werden die Rückfederungswerte auf dem Trainingsdatensatz und die entsprechenden Prädiktionen des nachtrainierten SAC-Algorithmus. Es zeigt sich, dass die Prädiktionen des Algorithmus mit zufriedenstellender Genauigkeit die experimentell generierten Rückfederungsverläufe abbilden und das Modell somit befähigt ist, basierend auf Kenntnis der Materialparameter die Rückfederung abzuschätzen. Abweichungen zwischen prädizierten und realen Rückfederungen liegen in Unsicherheit begründet, über die der SAC-Algorithmus im Gegensatz zu den simulativen Untersuchungen keine Informationen erhält.

Das auf dem *Trainingsdatensatz* nachtrainierte Modell wird anschließend auf dem

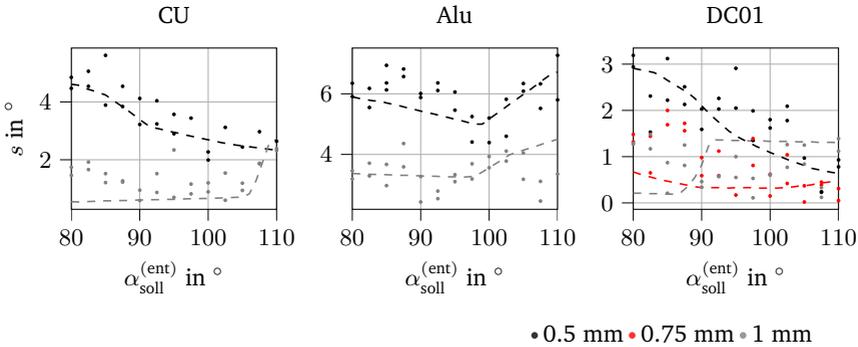
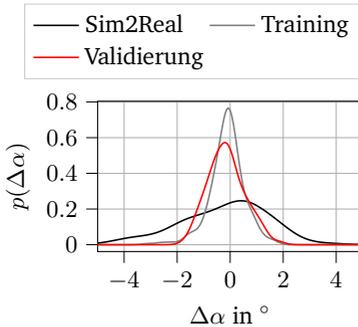


Abbildung 5.27.: Vergleich der experimentellen Rückfederungen auf dem *Validierungsdatensatz* und den prädizierten Rückfederungen des auf Experimentaldaten nachtrainierten SAC-Algorithmus (gestrichelte Linie)

Validierungsdatensatz erneut erprobt, was auf die Verläufe in Abbildung 5.27 führt. Da der SAC-Algorithmus nicht erneut auf dem Validierungsdatensatz nachtrainiert wird, sind die Prädiktionen in Abbildungen 5.26 und 5.27 identisch. Auch hier zeigt der nachtrainierte Agent eine zufriedenstellende Performanz, da der *Trainings-* und *Validierungsdatensatz* hohe Ähnlichkeiten aufweisen. Lediglich das Rückfederungsverhalten des 0.75 mm dicken Stahlbleches weist für niedrige Soll-Biegewinkel Unterschiede zwischen *Trainings-* und *Validierungsdatensatz* auf, weswegen in diesen Bereichen vergleichsweise hohe Biegewinkelabweichungen vorliegen. Dies lässt darauf hindeuten, dass RL-Algorithmen sich grundsätzlich zur Regelung von Bauteileigenschaften eignen, jedoch kurzzyklische Updates der Modelle erforderlich sind, um die Modellparameter kontinuierlich zu aktualisieren, sodass jüngste Zusammenhänge zwischen Bauteileigenschaften, Zuständen und Aktionen durch das Modell reflektiert werden. Dies gilt vor allem beim Auftreten besonderer Prozessereignisse, die Einfluss auf die in Kapitel 2.1 beschriebenen Unsicherheitsquellen nehmen, wie etwa Coil-, Sensorik- oder Werkzeugwechsel, Hubzahländerungen und Neuanläufe der Produktion nach langen Stillstandszeiten.

Abbildung 5.28 gibt abschließend einen vergleichenden Überblick über die WDF der Biegewinkelabweichungen unter Anwendung des SAC-Algorithmus auf die unterschiedlichen experimentellen Datensätze. Während die Auftretenswahrschein-



Datensatz	$ \overline{\Delta\alpha} $	$\max  \Delta\alpha $	$R^2$
Sim2Real	1.28	4.5	-0.03
Training	0.48	3.13	0.88
Validierung	0.57	1.86	0.86

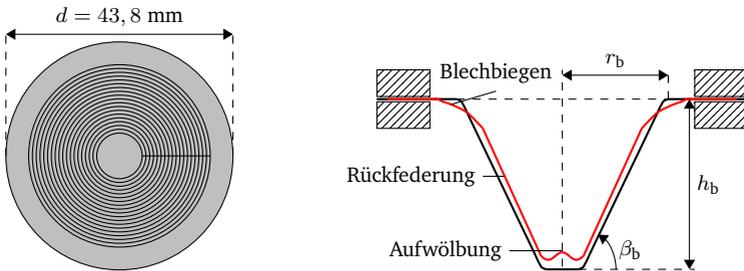
Tabelle 5.12.: Fehlermetriken für Biegewinkelabweichungen bei der Anwendung des SAC-Algorithmus auf unterschiedlichen experimentellen Datensätzen

Abbildung 5.28.: WDF der Biegeabweichung des SAC-Algorithmus auf die unterschiedlichen experimentellen Datensätzen

lichkeiten von Biegeabweichungen  $\pm 2^\circ$  für die Datensätze, bei denen ein nachtrainiertes Modell zum Einsatz kommt (Trainings- und Validierungsdatensatz), nahezu 0 sind, treten bei einem ausschließlich auf Simulationsdaten trainierten Agenten (Sim2Real) Biegeabweichungen von bis zu  $5^\circ$  auf. Tabelle 5.12 vergleicht die unterschiedlichen Performanzen der Modelle anhand von drei Fehlermetriken und zeigt ebenfalls anhand der durchschnittlichen Biegeabweichung  $|\overline{\Delta\alpha}|$ , der maximal auftretenden Biegeabweichung  $\max |\Delta\alpha|$  und den jeweiligen Bestimmtheitsmaßen  $R^2$ , die sich aus prädizierten und realen Rückfederungen ergeben, dass ein nachträgliches Training auf Experimentaldaten wesentlich zur Performanzsteigerung der Modelle beiträgt.

### 5.3. Anwendung bestärkender Lernalgorithmen auf SPIF-Prozess

Ein Übertrag des RL-basierten Regelungsansatz erfolgt nachfolgend auf einen SPIF-Prozesses, bei dem mehrere geometrische Bauteileigenschaften gleichzeitig manipuliert werden. SPIF stellt einen inkrementellen Umformprozess dar, bei dem die Werkzeugspitze lokal das eingespannte Blech kontaktiert und die Formgebung durch den zurückgelegten Werkzeugspitzenpfad determiniert wird. Vorteil des Verfahrens ist die freie Formgebung, wobei sich die finale Bauteilgeometrie aufgrund eingebrachter Eigenspannungen erst nach Entnahme des Bauteils aus der Einspannvorrichtung



(a) Visualisierung des Werkzeugspitzenpfades aus der Draufsicht (b) Auftretende Fehlerbilder bei SPIF-Bauteilen aus der Seitenansicht in A. a. [Lu16]

Abbildung 5.29.: Werkzeugspitzenpfad und typische Fehlerbilder in rotationssymmetrischen SPIF-Prozessen

einstellt. Abbildung 5.29 zeigt einen für die Fertigung eines rotationssymmetrischen Kegelstumpfes zu realisierenden Werkzeugspitzenpfad aus der Draufsicht und typische Fehlerbilder von SPIF-Bauteilen aus der Seitenansicht. Nahe der Einspannzzone kommt es zu Blechbiegeeffekten [MAF07], die zwangsläufig auftreten und nicht ausgeregelt werden können. [HD11b] Ein weiteres Fehlerbild sind Aufwölbungen am Boden des Kegelstumpfes, die auch als Kissenbildung bezeichnet werden [AH15] und einer ebenen Deckfläche des Kegelstumpfes entgegenstehen. Aus Rückfederungseffekten resultierende Geometrieabweichungen beeinflussen die Maßhaltigkeit des Bauteils an jeglichen Stellen und sind maßgeblich über Optimierungen des Werkzeugspitzenpfades kompensierbar. In den vergangenen Jahren sind erhebliche Forschungsbemühungen betrieben worden, um insbesondere rückfederungsinduzierte Geometrieabweichungen zu kompensieren, wobei unterschiedliche Ansätze verfolgt wurden. Modifikationen des Werkzeugpfades unter Nutzung variabler vertikaler Zustellung [ACG06; Att08], MPC [Lu16; Lu17; HD11a], mehrstufige Umformung [Hir04] und weitere Korrekturalgorithmen [Fu13; Beh13] finden sich in der Literatur und stellen lediglich einen kleinen Auszug ausgewählter Anwendungen dar. Die Anwendung bestärkender Lernalgorithmen zur Kompensation von Geometrieabweichungen von SPIF-Bauteilen wird ebenfalls in der Literatur vorgeschlagen [Sto16], ist jedoch nach Wissen des Verfassers der vorliegenden Arbeit bislang experimentell noch nicht erprobt worden. Aus diesem Grund wird im Folgenden ein RL-basierter Regelansatz vorgestellt, der rückfederungsinduzierte Geometrieabweichungen für

---

rotationssymmetrische Kegelstumpfe kompensieren soll.

### 5.3.1. Versuchsaufbau

Zur Versuchsdurchführung kann auf ein bestehendes SPIF-Werkzeug zurückgegriffen werden, das an den Stößel des Prototypens der 3DSP montiert wird und bereits in zahlreichen SPIF-Versuchsreihen zum Einsatz kam [Ste17; HHG17; Hop18]. Abbildung 5.30 bildet den Werkzeugraum des Prototypens der 3DSP mit eingebautem SPIF-Werkzeug ab. Durch eine vertikale Translation des Stößels bei zeitgleicher

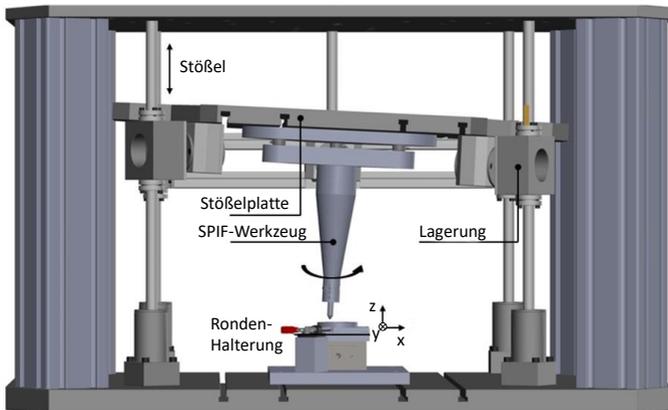


Abbildung 5.30.: 3DSP mit montiertem SPIF-Werkzeug und Rondenhalterung [Ste17]

Verkipfung um die raumfesten x- und y-Achsen wird ein dreidimensionaler Werkzeugspitzenpfad realisiert, der bei Blecheingriff zur dreidimensionalen Umformung der eingespannten Ronde führt. Als Versuchsmaterial werden DC04-Blechrenden mit einer Dicke von 0.5 mm und einem Durchmesser von 43.8 mm genutzt.

### 5.3.2. Regelungskonzept

Das Blockschaltbild in Abbildung 5.31 gibt einen Überblick über das realisierte Regelungskonzept. Als Eingangsgröße des KI-gestützten Produktreglers dienen Soll-Bauteileigenschaften des SPIF-Kegelstumpfes  $\mathbf{p}_{\text{ Soll}} = \begin{bmatrix} r_b & h_b & \beta_b \end{bmatrix}^T$ , wobei gemäß

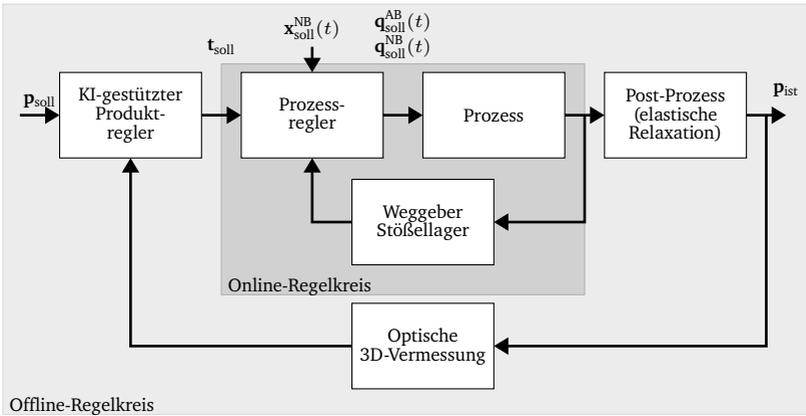
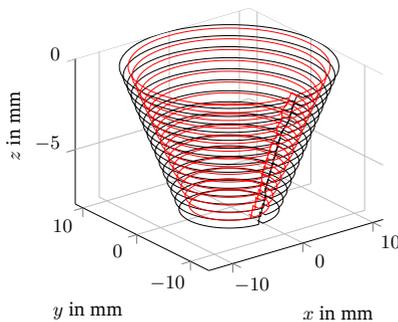


Abbildung 5.31.: Blockschaltbild des eigenschaftsgeregelten SPIF-Prozesses

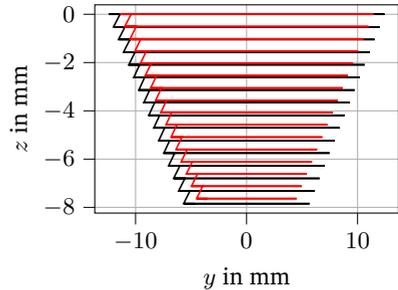
Abbildung 5.29b  $r_b$  den Radius,  $h_b$  die Höhe und  $\beta_b$  den Flankenwinkel des SPIF-Bauteils kennzeichnen. Der Produktregler erhält nach jedem Versuch geometrische Daten über das produzierte Bauteil, die durch das in Anhang A.6 beschriebene, optische 3D-Messgerät (Hexagon Absolute Arm 8525-7) erfasst werden. Entsprechende Geometrieabweichungen werden anschließend durch die Auswertung der stl-Messdateien erfasst und dem Produktregler zugeführt, der auf dieser Basis Trajektorienparameter des nächsten zu fertigenden Bauteils anpasst. Dabei gibt der Produktregler modifizierte Geometriemerkmale  $\mathbf{p}_{\text{mod}} = [r_{\text{mod}} \quad h_{\text{mod}} \quad \beta_{\text{mod}}]^T$  aus, die über kinematische Beziehungen in raumfeste Koordinaten der Werkzeugspitze  $\mathbf{x}_{\text{TCP}} = [x \quad y \quad z]^T$  und abschließend über ein inverses Kinematikmodell des Werkzeugs in Führungsgrößen für den Online-Prozessregler in Stößelkoordinaten  $\mathbf{x}_{\text{st},\text{soll}} = [\theta_x \quad \theta_y \quad z_{\text{st}}]^T$  transformiert werden.<sup>12</sup> Der Online-Prozessregler regelt die Stößelpose der 3DSP durch das in Kapitel 4.2 vorgestellte Regelgesetz und erhält als Nebenbedingung für die Regelung der Totpunkte erneut

$$\mathbf{x}_{\text{soll}}^{(\text{NB})} = \begin{bmatrix} t_{\text{OT}} \\ t_{\text{UT}} \end{bmatrix} = \begin{bmatrix} z_{\text{st}}(t) + \frac{h}{2} \\ z_{\text{st}}(t) - \frac{h}{2} \end{bmatrix} \quad (5.9)$$

<sup>12</sup>Siehe dazu auch oberer Strang in Abbildung 5.33.



(a) Dreidimensionale Ansicht



(b) Zweidimensionale Ansicht

Abbildung 5.32.: Unterschiedlich parametrisierte Werkzeugspitzenpfade im SPIF-Prozess im raumfesten Koordinatensystem

mit einer Hubhöhenvorgabe von  $h = 30$  mm.

Abbildung 5.32 stellt zwei unterschiedlich parametrisierte Werkzeugspitzenpfade, die sich hinsichtlich aller modifizierbaren Geometriemerkmale geringfügig unterscheiden, im raumfesten Koordinatensystem drei- und zweidimensional dar.<sup>13</sup> Es ist ersichtlich, dass der Produktregler über Ausgabe von modifizierten Geometriemerkmale den Werkzeugspitzenpfad maßgeblich beeinflussen kann und somit die Geometrie des SPIF-Bauteils determiniert.

### 5.3.3. Entwurf des KI-gestützten Produktreglers

Aus den bereits in Kapitel 5.2.3 erläuterten Gründen wird erneut auf die Anwendung des SAC-Algorithmus als KI-gestützter Produktregler zurückgegriffen. Im Gegensatz zu den Untersuchungen beim Gesenkbiegen wird aus Komplexitätsgründen auf eine FEM-gestützte Generierung eines synthetisierten Datensatzes verzichtet. Damit besteht ebenfalls keine Gelegenheit zum Vortrainieren des Algorithmus, weswegen Konvergenz des Algorithmus bei geringerer Datenverfügbarkeit nur dann zu erwarten ist, wenn im Vergleich zur Anwendung beim Gesenkbiegen die Komplexität der

<sup>13</sup>Die Werkzeugpfade basieren auf folgenden modifizierten Geometriemerkmale: schwarz  $r_{\text{mod}} = 8,59$  mm,  $h_{\text{mod}} = 7,85$  mm,  $\beta_{\text{mod}} = 45,1^\circ$ ; rot:  $r_{\text{mod}} = 7,56$  mm,  $h_{\text{mod}} = 7,64$  mm,  $\beta_{\text{mod}} = 44,1^\circ$ . Die modifizierten Radiusangaben beziehen sich auf den mittleren Radius bei Bauteilhöhe  $h_{\text{mod}}/2$ .

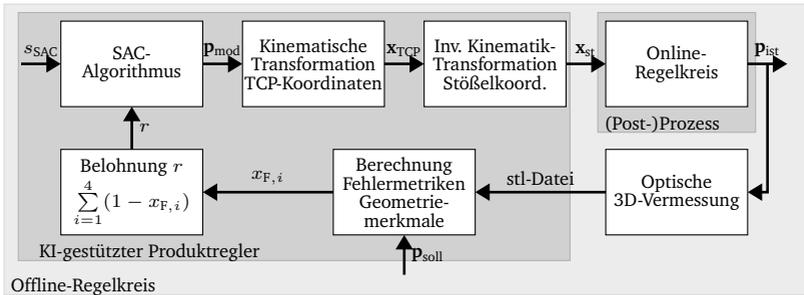


Abbildung 5.33.: Aufbau des KI-gestützten Produktreglers bei Anwendung auf SPIF-Prozess

Lernaufgabe drastisch reduziert wird. Daher wird eine zustandsunabhängige Anwendung des SAC-Algorithmus verfolgt und im Gegensatz zu den Untersuchungen beim Biegen keine Halbzeug-, Blechdicken- oder Geometrievariation vorgenommen. Ziel der Anwendung des Produktreglers ist es damit, den Werkzeugspitzenpfad für eine bestimmte Bauteilgeometrie bei gleichbleibendem Halbzeug und gleichbleibender Blechdicke zu optimieren.

Zum Entwurf des RL-basierten Produktreglers bedarf es erneut der Formulierung der Zustands- und Aktionsräume sowie der Definition einer Belohnungsfunktion. Abbildung 5.33 gibt einen tieferen Einblick in die Funktionsweise des Produktreglers. Als Aktionen gibt der SAC-Algorithmus die modifizierten Geometriemerkmale  $\mathbf{p}_{\text{mod}}$  aus, aus denen über kinematische Transformationen die Führungsgrößen des Positionsregelkreises  $\mathbf{t}_{\text{soll}}$  der 3DSP generiert werden. Eingangsgröße in der Rückführung des Regelkreises sind 3D-Messdateien der Bauteilgeometrien, die als stl-Dateien vorliegen. Aus den 3D-Messdaten werden anschließend Geometriemerkmale berechnet und mit den gewünschten Geometriemerkmale  $\mathbf{p}_{\text{soll}}$  verglichen. Dabei werden die Bauteilhöhe  $h$ , Radien in x- und y-Richtung  $r_x$  und  $r_y$  sowie der Flankenwinkel  $\beta$  mit den gewünschten Geometriemerkmale verglichen und darauf basierend Fehlermetriken  $x_{F,i}$  berechnet. Die entsprechenden Größen werden basierend auf mehreren Messwerten an unterschiedlichen Stellen berechnet und anschließend

---

über die Fehlermetriken des mittleren Fehlers (Radius)

$$x_{F,i}^{(\text{MF})} = \frac{1}{N} \sum_{j=1}^N (\mathbf{p}_{\text{soll},ij} - \mathbf{p}_{\text{ist},ij}) \quad (5.10)$$

und der Wurzel des quadratischen Mittelwerts der Abweichungen (Höhe und Flankenwinkel)

$$x_{F,i}^{(\text{RMSE})} = \sqrt{\frac{1}{N} \sum_{j=1}^N (\mathbf{p}_{\text{soll},ij} - \mathbf{p}_{\text{ist},ij})^2} \quad (5.11)$$

quantifiziert.<sup>14</sup> Aus den Fehlermetriken der vier Bauteileigenschaften wird der Be-  
lohnungswert des gefertigten Bauteils berechnet, der sich zu

$$r = \sum_{i=1}^4 (1 - x_{F,i}) \quad (5.12)$$

ergibt. Die Zustandsunabhängigkeit des Algorithmus wird sichergestellt, indem für  $s_{\text{SAC}}$  ein konstanter Wert vorgegeben wird.

Die Implementierung des SAC-Algorithmus erfolgt erneut in *Python* über die *Stable-Baseline3*-Bibliothek [Raf21]. Es wird auf die initial implementierten Netztopologien und Hyperparameter zurückgegriffen. Ausgewählte Hyperparameter werden durch die Erstellung einer virtuellen Umgebung, die vereinfachte Beziehungen zwischen Trajektorienparametern und resultierenden Bauteileigenschaften postuliert, optimiert.<sup>15</sup>

### 5.3.4. Experimentelle Ergebnisse

Der experimentelle Versuchsumfang umfasst die Fertigung von insgesamt 45 Bauteilen. Davon werden am Anfang 5 Bauteile mit zufälligen modifizierten Geometrie-  
merkmalen gefertigt und zusätzlich ein weiteres Bauteil, dessen Werkzeugspitzen-  
pfad exakt zur gewünschten Bauteilgeometrie korrespondiert, wodurch Rückfed-  
erungseffekte unberücksichtigt bleiben (unmodifizierter Werkzeugspitzenpfad). Die

---

<sup>14</sup>Für genauere Erklärungen der Berechnung von Fehlermetriken sei auf Anhang A.15 verwiesen.

<sup>15</sup>Ergebnisse der virtuellen Umgebung für die Hyperparameter Anzahl an Gradientenschritten sowie initialer Entropie-Koeffizient des SAC-Algorithmus sind in Abbildung A.28 in Anhang A.15 visualisiert. Weitere Informationen zur virtuellen Umgebung sind [S7] zu entnehmen.

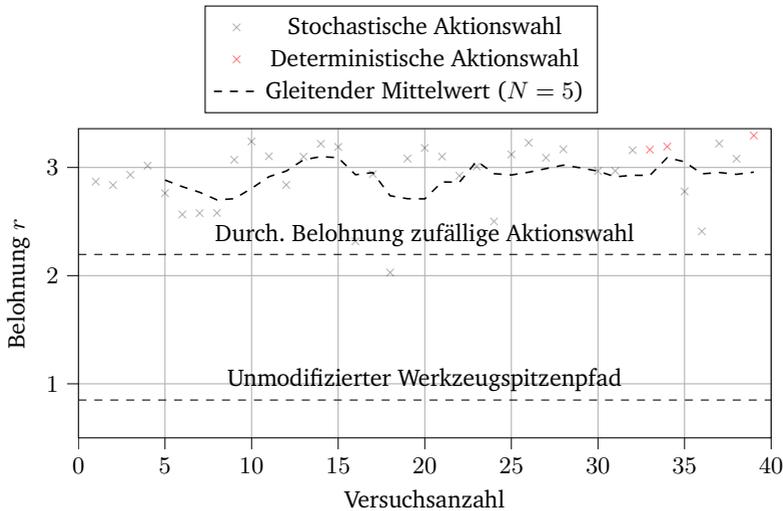


Abbildung 5.34.: Verlauf erhaltener Belohnungswerte über der Versuchsanzahl bei explorierendem SAC-Algorithmus

fünf Bauteile mit zufällig gewählten modifizierten Geometriemerkmalen erzielen einen durchschnittlichen Belohnungswert von 2.2. Das Bauteil, dessen Werkzeugspitzenpfad die Rückfederung nicht einbezieht, führt auf einen Belohnungswert von 0.85. Abbildung 5.34 stellt die erhaltenen Belohnungswerte über die 39 durchgeführten Versuche bei explorierendem SAC-Algorithmus dar und visualisiert vergleichend die durchschnittlich erhaltene Belohnung bei zufälliger Aktionswahl und bei unmodifiziertem Werkzeugspitzenpfad. Nach jedem Versuch werden die generierten Aktions-Belohnungswert-Kombinationen abgespeichert und das Modell mit 30 Gradienten-Updates nachtrainiert. Es ist ersichtlich, dass der Agent bereits nach 6 Vorversuchen Aktionen wählt, die zu deutlich maßhaltigeren Bauteilen führen im Vergleich zur zufälligen Aktionswahl und insbesondere zum unmodifizierten Werkzeugspitzenpfad. Die grau hinterlegten Belohnungen resultieren aus Versuchen, in denen der SAC-Algorithmus stochastische Aktionen wählt, weswegen in vereinzelt Versuchen Abfälle der Belohnungswerte zu beobachten sind. Gegen Ende der Versuchsreihe werden daher drei Versuche bei deterministischer Aktionswahl durchgeführt (rot eingezeichnet), die allesamt auf Belohnungswerte von  $r > 3$

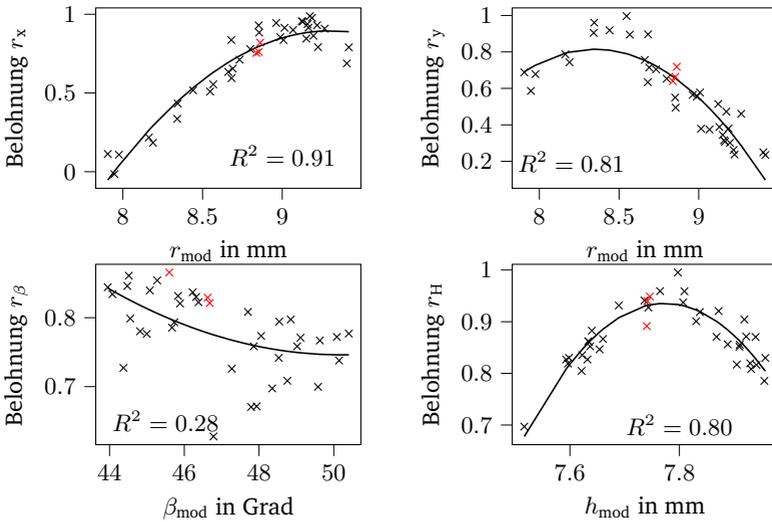


Abbildung 5.35.: Zusammenhang zwischen gewählten Aktionen und Teilbelohnungen im SPIF-Prozess

führen.

Einen Einblick in die Zusammenhänge zwischen Aktionswahl und erhaltener Teilbelohnungswerte bietet Abbildung 5.35. Erkennbar ist, dass die Aktionen mit den entsprechenden Teilbelohnungswerten korrelieren, sodass über die Aktionswahlen des Algorithmus die Belohnungen (und damit die geometrischen Bauteileigenschaften) manipulierbar sind. Aus diesem Grunde sind quadratische Regressionsfunktionen und deren Bestimmtheitsmaße in die jeweiligen Graphen eingezeichnet, die quantifizieren, in welchem Maße die Aktionswahl die Belohnung determiniert. Es ist ersichtlich, dass über den modifizierten Radius sowohl die Teilbelohnung bezüglich des Bauteilradius in x- als auch y-Richtung bestimmt wird. Die deterministisch gewählten Aktionen zum Ende der Versuchsreihe (rot eingezeichnet) wählen aus isolierter Sicht der einzelnen Bauteilradien keine optimalen Aktionen. Aggregiert man jedoch beide Belohnungswerte ist ersichtlich, dass der Algorithmus erlernt hat, die Summe beider Belohnungswerte zu maximieren.<sup>16</sup> Eine Erhöhung der Radienwahl würde demzufolge mit höheren Belohnungswerten bezüglich der Radien-Teilbelohnung  $r_x$

<sup>16</sup>Für eine entsprechende Visualisierung siehe Abbildung A.29 in Anhang A.15.

---

eingehen, jedoch die Teilbelohnung des Radius in y-Richtung  $r_y$  negativ beeinflussen, was auf anisotropes Materialverhalten hindeutet. Bezüglich der Wahl des Flankenwinkels ist die geringste Korrelation zwischen Aktionswahl  $\beta_{\text{mod}}$  und dazugehöriger Teilbelohnung  $r_\beta$  zu erkennen. Dies liegt darin begründet, dass Kreuzeinflüsse der Radienwahl den optimalen Flankenwinkel überlagern und die optimale Festlegung des Flankenwinkels demzufolge ebenfalls vom gewählten Radius abhängt. Trotz der Kreuzeinflüsse zeigen die deterministischen Aktionswahlen des SAC-Algorithmus, dass dieser den Flankenwinkel an den gewählten Radius anpassen kann, was zu Teilbelohnungen von  $r_\beta > 0.8$  führt. Weiterhin ist erkennbar, dass der Zusammenhang zwischen modifizierter Höhe  $h_{\text{mod}}$  und korrespondierender Teilbelohnung  $r_H$  durch eine Parabel beschrieben werden kann und die deterministisch gewählten Aktionen nah am Hochpunkt der gefitteten Parabel liegen. Daraus lässt sich schließen, dass es der Agent trotz niedriger Anzahl an Versuchen erlernt hat, Trajektorienparameter zu erlernen, die zu signifikant maßhaltigeren Bauteilen führen.

Abbildung 5.36 vergleicht die Geometrien von SPIF-Bauteilen, die auf einem unmodifiziertem Werkzeugspitzenpfad (keine Rückfederungskompensation) und einem Versuch mit deterministischer Aktionswahl (letzter Versuch aus Abbildung 5.34) beruhen. Obgleich die sich aus dem Blechbiegeeffekt und der Aufwölbung resultierenden Geometrieabweichungen nicht kompensiert werden, sind erhebliche Reduktionen der aus Rückfederungseffekten resultierenden Geometrieabweichungen erzielt worden. Sowohl die Ausprägung der Höhendifferenz an der tiefsten Bauteilstelle als auch Radien- und Flankenwinkelabweichungen sind durch die Anwendung des KI-gestützten Produktreglers weitestgehend eliminiert worden, konfliktäre Optimierungskriterien stehen weiteren Genauigkeitssteigerungen entgegen. Die sich aus Messunsicherheit ergebenden Konfidenzintervalle der gemessenen Bauteilgeometrie decken sich über weite Teile mit der Soll-Geometrie der Bauteilflanke, wodurch die Wirksamkeit der Anwendung des Produktreglers unter Beweis gestellt wird.

## 5.4. Zwischenfazit

Unterschiedliche Unsicherheitseinflüsse führen zu abweichenden Bauteileigenschaften und bedürfen einer kaskadierten Regelung ebendieser. Im vorangegangenen Kapitel werden drei Anwendungen eines KI-gestützten Produktreglers vorgestellt,

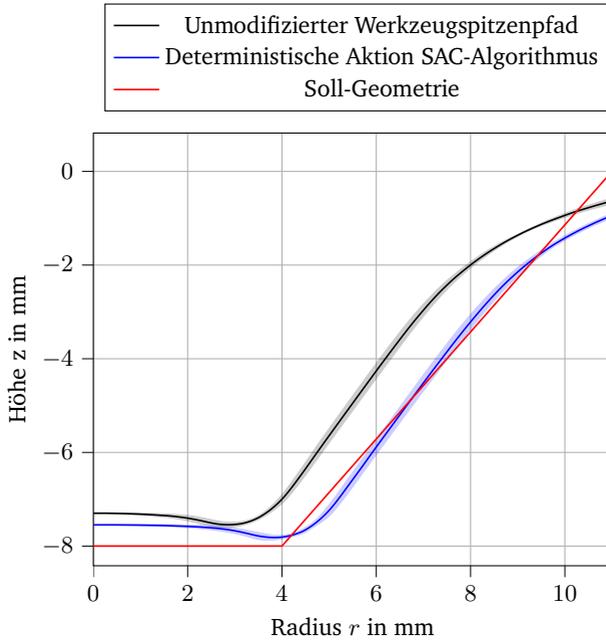


Abbildung 5.36.: Vergleich der Schnittansichten von produzierten SPIF-Bauteilen [S7]

die aufzeigen, dass Informationen vorangegangener Produktionsschritte mitsamt sensorisch erfassten Bauteileigenschaften dienlich sind, um optimierte Führungsgrößen für den Online-Prozessregler zur Fertigung darauffolgender Bauteile abzuleiten. Die Anwendung überwachter Lerntechniken basierend auf gemessenen Kraftsignalen lässt eine Charakterisierung des zu produzierenden Bauteils zu und stellt dem Produktregler Informationen über Materialart als auch Blechdicke zur Verfügung. Diese Informationen können über überwachte Lernmethoden verwertet werden, um durch Rückfederungen induzierte Geometrieabweichungen zu kompensieren. Anhand simulativer Untersuchungen in einem flexiblen Gesenkbiegeprozess kann aufgezeigt werden, wie sich schwankende Materialparameter auf das Rückfederungsverhalten auswirken und wie die Bereitstellung von Informationen über diese Schwankungen durch RL Beiträge zu höherer Bauteilmaßhaltigkeit leisten. Das ausschließlich auf Simulationsdaten trainierte RL-Modell führt bei direkter Anwen-

---

dung auf den realen Prozess jedoch zu hohen Abweichungen, da das simulative und experimentelle Rückfederungsverhalten der Bauteile fundamentale Unterschiede aufweist. Da RL-Algorithmen sich jedoch schnell an neue Umgebungsbedingungen anpassen können, führt ein nachträgliches Training des Modells mit Experimentaldaten auf signifikante Reduktionen der Geometrieabweichungen, wodurch die gerade in umformtechnischen Anwendungen hohen Anforderungen an Modelladaptivitäten unter Beweis gestellt werden. Weiterhin wird am Beispiel eines SPIF-Prozess die Eignung von RL-Algorithmen zur Optimierung von dreidimensionalen Werkzeugspitzenpfaden unter Beweis gestellt. Nach einer vergleichsweise geringen Anzahl an Versuchsdurchführungen findet der Algorithmus Trajektorienparameter, die in Abhängigkeit zur spezifizierten Belohnungsfunktion zu gewünschten Bauteilgeometrien führen, wodurch Rückfederungseffekte kompensiert werden.

Die Untersuchungen geben Einblicke in die Potenziale und Herausforderungen von ML-Algorithmen zur gezielten Einstellung von Bauteileigenschaften in umformtechnischen Prozessen und lassen eine Ableitung von verallgemeinerbaren Aussagen zu. Sowohl bei der Anwendung von überwachten als auch bestärkenden Lernverfahren bedarf es einer steten Adaption der Modellparameter an jüngste Fertigungsergebnisse, sodass die Modelle stets auf Basis aktueller Zusammenhänge zwischen Steuerparametern und resultierenden Bauteileigenschaften trainiert werden. Ausschließlich durch kurzzyklische Modelladaptionen kann gewährleistet werden, dass zeitlich veränderliche Prozessrandbedingungen Berücksichtigung finden. Stochastisch schwankende Prozessparameter wie etwa geringfügige Schwankungen der Blechdicke oder Festigkeitskennwerte sind über Aufnahmen zusätzlicher Messgrößen identifizierbar. Deren Auswirkungen auf Bauteileigenschaften können unter Einspeisung korrelierender Messgrößen (Kräfte, Beschleunigungen, Blechdicke) in die Algorithmen prädiziert werden, sodass bauteilspezifische Materialcharakterisierungen oder Messdatenaufnahmen in vorgelagerten Prozessen als probates Mittel angesehen werden, um stochastisch schwankende Parameter zu beherrschen. Probleme bezüglich der Dateneffizienz von ML-Algorithmen können durch synthetisierte Datenerzeugungen mittels FEM-Simulationen gemindert werden, sodass ein dem Einsatz im Realprozess vorgelagertes Training der Modelle basierend auf Simulationsdaten ermöglicht wird. Dabei gilt es zu berücksichtigen, dass Simulationen und Realprozesse ähnliche Zusammenhänge zwischen Steuerparametern und resultierenden Bauteileigenschaften aufweisen, sodass die aus Simulationsdaten

---

generierten Modelle die Zusammenhänge im Realprozess möglichst genau abbilden. Geringfügige Abweichungen sind anschließend durch ein erneutes Training der Modelle auf Realdaten kompensierbar.

Vergleicht man überwachte mit bestärkenden Lernalgorithmen, bietet RL aufgrund des zugrundeliegenden Funktionsprinzips entscheidende Vorteile. RL-Algorithmen optimieren die Steuerparameter des Prozesses unter Zuhilfenahme einer manuell parametrisierten Belohnungsfunktion auf direktem Wege und eines direkten Feedbacks aus dem Prozess in Form von Belohnungswerten. Stochastische Algorithmen explorieren dabei im (mehrdimensionalen) Parameterraum und erkunden diesen umfassender. Überwachte Lernalgorithmen weisen diese Fähigkeit nicht auf und spiegeln lediglich optimale Steuerparameter basierend auf der verfügbaren Datengrundlage wider. Eine Exploration von optimalen Parametern unter Einbringung stochastischer Elemente in die Aktionswahl ist mit den Algorithmen nicht möglich, sodass die Wahrscheinlichkeit der Wahl suboptimaler Steuerparameter als höher einzustufen ist.

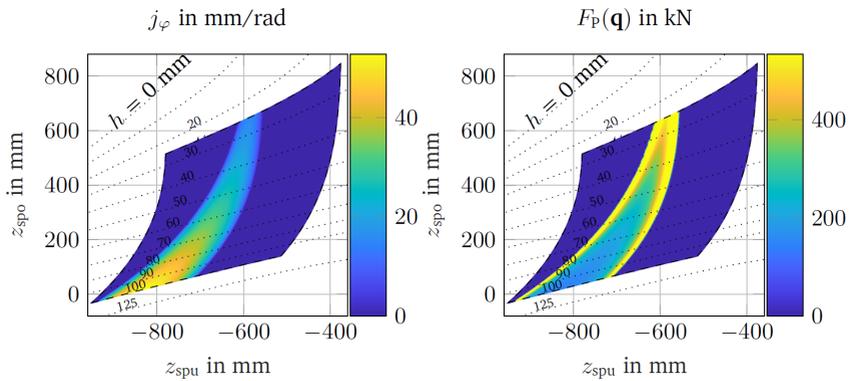
---

## 6. Simulationsgestützte Optimierung von Antriebstrajektorien

---

### 6.1. Einführung in die Problemstellung

Bei den in Kapitel 4 eingeführten 3DSP-Versuchsständen handelt es sich um überaktivierte und demzufolge redundante Werkzeugmaschinen. Diese zeichnen sich - wie in Kapitel 2.3.2 vorgestellt - durch eine Verfügbarkeit von mehr Antriebs- als Abtriebsfreiheitsgraden aus. Redundanzen werden bei mehrachsigen Manipulatoren oftmals genutzt, um zusätzliche Nebenbedingungen in Positionsregelungen zu erfüllen, die beispielsweise eine Maximierung von Distanzen zu singulären Stellungen, die Vermeidung von Kollisionen mit umliegenden Objekten oder einen energieoptimierten Betrieb adressieren. Aus der Analyse des in Abbildung 4.4 dargelegten Blockschaltbildes ist ersichtlich, dass die Redundanz der 3DSP derzeit zur Regelung des OT und UT genutzt wird. Dabei werden OT und UT äquidistant um die aktuelle Höhe des Stößelmittelpunktes angeordnet und die Hubhöhe möglichst hoch gewählt, wodurch eine maximale Manipulierbarkeit der Stößelpose gewährleistet wird. Aus regelungstechnischer Sicht ist eine solche Totpunktpositionierung wünschenswert, da geringe Stellwege der Exzenterantriebe zu einer hohen Dynamik der Stößelbewegungen führen. Oftmals trägt eine solche Positionierung den Anforderungen an umformtechnische Prozesse und einen energieeffizienten Betrieb von Werkzeugmaschinen unzureichend Rechnung, da die aus den Nenn Drehmomenten der Exzenterantriebe resultierenden Presskräfte am Stößel zwischen den Totpunkten Minimalwerte annehmen (siehe Abbildung 2.12 für konventionelle Kurbel- und Kniehebelpressen und Abbildung 4.3 für unterschiedliche Antriebskonfigurationen der 3DSP). Besonders



(a) Geschwindigkeitsübersetzung  $j_{\varphi}$  von Exzenterantrieb  $\varphi_i$  auf Stoßellager  $R_i$  für eine festgelegte Stoßellagerposition  
 (b) Abrufbare Presskraft  $F_P(\mathbf{q})$  am Stoßellager  $R_i$  bei Abruf des Nenn Drehmomentes am Exzenterantrieb  $\varphi_i$

Abbildung 6.1.: Vergleich der Übersetzungen von Geschwindigkeit und Kraft zwischen Exzenterantrieb  $\varphi_i$  und Stoßellager  $R_i$

relevant wird dieser Umstand unter Berücksichtigung der in Abbildung 4.6 visualisierten Kraft- und Antriebsdrehmomentenverläufe während der durchgeführten Stauchversuche. In den Stauchversuchen werden Stauchkräfte von bis zu 210 kN aufgebracht, was etwa 13% der verfügbaren Presskraft an der Forschungsversion der 3DSP beträgt. Bedingt durch die aus Prozesssicht suboptimale Platzierung der Totpunkte, wodurch die Stauchoperation mittig zwischen den Totpunkten durchgeführt wird, werden Drehmomente einer exzentrischen Antriebseinheit von bis zu 5000 Nm erforderlich, was etwa 71% des verfügbaren Nenn Drehmomentes entspricht. Abbildung 6.1 stellt die Geschwindigkeits- und Kraftübersetzung einer Getriebeeinheit der 3DSP für eine Positionierung des Stoßellagers auf einer festgelegten Höhenposition dar. In Abhängigkeit der Positionierung der Spindeltriebe in deren Prozessfenster wird dabei die Winkelposition des Exzenterantriebes so gewählt, dass die festgelegte Höhenposition des Stoßellagers hervorgerufen wird.

Es wird deutlich ersichtlich, dass über die Positionierung der Spindeltriebe im Prozessfenster wesentlich Einfluss auf das Pressverhalten im entsprechenden Arbeitspunkt genommen werden kann. Die Substitutionalität zwischen Geschwindigkeits- und Kraftübersetzung ist auch an dieser Stelle klar erkennbar, da Spindelpositio-

---

nierungen mit hoher Kraftübersetzung (und damit unmittelbarer Nähe zu den Totpunkten<sup>1</sup>) zu geringen Manipulierbarkeiten führen und vice versa. Dunkelblau gekennzeichnete Bereiche im Spindelprozessfenster korrespondieren zu Spindelpositionen, die einem Erreichen der Stößellagerhöhe entgegenstehen, sodass bei einer vollen Rotation des Exzenterantriebes die geforderte Höhe nicht anfahrbar ist. Weiterhin sind in Abbildung 6.1 die entsprechenden Hubhöhen als gepunktete Kennlinien eingezeichnet. Während bei minimaler Hubhöhe von 25 mm fast über den gesamten Hub die mechanisch begrenzte Kraft von 53,3 t aufgebracht werden kann, kommt es bei hohen Hubhöhen zu einem massiven Kraftabfall zwischen den Totpunkten. Dies gilt umgekehrt ebenfalls für die Geschwindigkeitsübersetzung. Daraus lässt sich die Notwendigkeit der Ermittlung optimierter Antriebspfade für redundante Servopressen motivieren. Unter Kenntnis der im Prozess zu erwartenden Presskraft- und Abtriebspositionsverläufe gilt es im Folgenden zu demonstrieren, inwiefern sich White- und Black-Box-Modelle zur Optimierung der Antriebspfade eignen. Als White-Box-Ansatz wird in Kapitel 6.2 eine MPC entworfen, die eine umfassende Modellbildung voraussetzt und Optimierungen des Antriebsverhaltens über Minimierung eines manuell formulierten Gütefunktional vornimmt.<sup>2</sup> Als gegensätzlicher Ansatz werden unterschiedliche AC-Algorithmen als Unterform bestärkender Lernalgorithmen für die Lösung der Problemstellung herangezogen und miteinander verglichen. Diese verzichten vollständig auf eine pressenspezifische Modellierung und versuchen das Antriebsverhalten unter Maximierung erwarteter Belohnungen zu optimieren, wobei die Wahl der Belohnungsfunktion wiederum manuell erfolgt und als Freiheitsgrad zur Manipulation resultierender Antriebspfade angesehen werden kann.<sup>3</sup>

Im Folgenden werden in Kapitel 6.2 die auf MPC und in 6.3 die auf AC-Algorithmen basierenden Ansätze und deren Formulierungen vorgestellt. Anschließend werden in Kapitel 6.4 die Ergebnisse beider Ansätze simulativ miteinander verglichen. Dies wird am Beispiel zweier Prozesse demonstriert. Einerseits erfolgen in Kapitel 6.4.1 Untersuchungen an dem im Kapitel 4.2 bereits experimentell durchgeführten Stauchversuch, der keine Stößelkippung und lediglich eine translatorische Höhenbewegung des Stößels erfordert. Dies stellt eine Übertragbarkeit auf redundante Servopressen

---

<sup>1</sup> Siehe dazu auch Abbildung A.30.

<sup>2</sup> Grundlagen der MPC sind Anhang A.10 zu entnehmen.

<sup>3</sup> Grundlagen des RL sind Anhang A.9 zu entnehmen. Die für AC-Algorithmen relevanten Techniken parametrisierbarer Bewertungsfunktionen und Entscheidungsstrategien werden in Anhang A.9.2 vorgestellt.

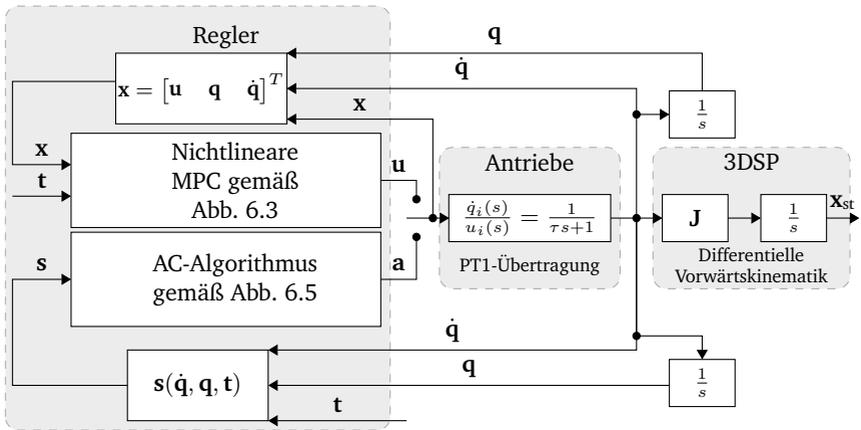


Abbildung 6.2.: Übergeordnetes Blockschaltbild unter Anwendung von MPC und AC-Algorithmen zur Findung optimaler Antriebspfade redundanter Servopressen

mit ausschließlich einem Stoßelfreiheitsgrad sicher. Andererseits wird in Kapitel 6.4.2 ein Taumelschmiedeprozess mit gewünschter Stoßelklippung untersucht und aufgezeigt, welcher Ansatz sich zur Einstellung spiraler Stoßelbewegungspfade eignet.

Abbildung 6.2 stellt ein übergeordnetes Blockschaltbild für die Anwendung von MPC und AC-Algorithmen zur Findung optimaler Antriebspfade von redundanten Servopressen dar. Anhand der Abbildung sind die prinzipiellen Funktionsweisen beider Ansätze erklärbar.<sup>4</sup> Die Antriebe werden - analog zu simulativen Untersuchungen in Kapitel 4 - mithilfe eines zeitverzögerten Gliedes erster Ordnung modelliert, wobei die entsprechenden Zeitkonstanten  $\tau$  experimentell ermittelt werden und für alle Antriebe 70 ms betragen<sup>5</sup>. Die daraus resultierenden Geschwindigkeiten werden über ein differentielles Vorwärtskinematikmodell in Geschwindigkeiten der Stoßelfreiheitsgrade transformiert und anschließend aufintegriert, woraus sich die

<sup>4</sup>Es sei darauf verwiesen, dass die beiden Ansätze aus unterschiedlichen wissenschaftlichen Communities entstammen, weswegen die Notationen von Stell- und Zustandsgrößen voneinander abweichen. Während in der Regelungstechnik Stellgrößen mit  $u$  und Zustandsgrößen mit  $x$  deklariert werden, werden Stellgrößen bei der Anwendung bestärkender Lernalgorithmen als Aktionen bezeichnet und mit  $a$  notiert. Zustände (engl.: states) werden mit  $s$  notiert. Die vorliegende Arbeit wechselt daher in Abhängigkeit vom angewandten Regler entsprechende Notationen, um Konsistenz mit der Fachliteratur sicherzustellen.

<sup>5</sup>Siehe für die experimentelle Bestimmung der Antriebszeitkonstanten Anhang A.2.

dreidimensionale Stoßelpose  $\mathbf{x}_{st}$  ergibt. Die Blöcke *Antriebe* und *3DSP* stellen die Regelstrecke dar. Die MPC fasst sowohl kinematische Größen der Antriebe  $\begin{bmatrix} \mathbf{q} & \dot{\mathbf{q}} \end{bmatrix}^T$  als auch optimierte Stellgrößen  $\mathbf{u}$  zu einem Zustandsvektor  $\mathbf{x}$  zusammen, die gemeinsam mit Informationen über Soll-Trajektoriengrößen  $\mathbf{t}$  die Eingangsgrößen der MPC darstellen. Demgegenüber werden die Zustände  $\mathbf{s}$  des AC-Ansatzes modellbasiert berechnet. Detailliertere Informationen über die Entwürfe beider Regleransätze sind den folgenden Unterkapiteln zu entnehmen.

## 6.2. Formulierung des modellprädiktiven Reglers

Die Implementierung der MPC beruht auf Vorarbeiten von Li [S8] und verfolgt das Ziel, unter Kenntnis der Soll-Verläufe von Stoßelpose  $\mathbf{x}_{st}^{(soll)}$  und Prozesskraft  $F_p^{(soll)}$  einen auf White-Box-Modellen beruhenden Ansatz zur Ermittlung optimierter Antriebspfade zu entwickeln. Dazu ist im ersten Schritt eine Zustandsraumdarstellung der 3DSP erforderlich. Als Zustände werden, wie bereits in Abbildung 6.2 dargestellt, sowohl die vorliegenden Positionen und Geschwindigkeiten der Antriebe als auch deren Geschwindigkeitsstellgrößen eingeführt. Der Zustand des  $i$ -ten Antriebs lässt sich somit durch den dreidimensionalen Vektor  $\mathbf{x}_{q_i} = \begin{bmatrix} q_i & \dot{q}_i & u_i \end{bmatrix}^T$  beschreiben. Damit ergibt sich die Zustandsraumdarstellung des korrespondierenden Antriebs zu

$$\dot{\mathbf{x}}_{q_i} = \begin{bmatrix} \dot{q}_i \\ \ddot{q}_i \\ \dot{u}_i \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 1 & 0 \\ 0 & -\frac{1}{\tau} & \frac{1}{\tau} \\ 0 & 0 & 0 \end{bmatrix}}_{\mathbf{A}_{q_i}} \begin{bmatrix} q_i \\ \dot{q}_i \\ u_i \end{bmatrix} + \underbrace{\begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}}_{\mathbf{b}_{q_i}} \dot{u}_i, \quad (6.1)$$

bei der die Ableitung der Geschwindigkeitsstellgröße  $\dot{u}_i$  die Stellgröße der MPC und physikalisch eine Beschleunigung darstellt. Dies erlaubt eine indirekte Manipulation der Geschwindigkeitsstellgröße über die Beschleunigung (siehe dazu Abbildung 6.3), was einerseits in geglätteten Bewegungspfaden für die Antriebe resultiert, andererseits die Möglichkeit bietet, die Zykluszeit der MPC ( $t_{MPC} = 10$  ms) höher zu wählen als die der 3DSP Regelstrecke ( $t_{3DSP} = 1$  ms). Eine Visualisierung der Verläufe der Ausgangsgröße des Reglers  $\dot{u}_{q_i}$  und des Eingangs der Strecke  $u_{q_i}$  ist Abbildung 6.4b zu entnehmen. Wird die in Formel 6.1 dargestellte Zustandsraumdarstellung

für einen Antrieb auf alle fünf Antriebe der 3DSP erweitert, geht daraus

$$\dot{\mathbf{x}} = \begin{bmatrix} \dot{x}_{q1} \\ \vdots \\ \dot{x}_{q5} \end{bmatrix} = \underbrace{\begin{bmatrix} \mathbf{A}_{q1} & \mathbf{0}_m & \cdots & \mathbf{0}_m \\ \mathbf{0}_m & \mathbf{A}_{q2} & \cdots & \mathbf{0}_m \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_m & \mathbf{0}_m & \cdots & \mathbf{A}_{q5} \end{bmatrix}}_{\mathbf{A} \in \mathbb{R}^{15 \times 15}} \begin{bmatrix} x_{q1} \\ \vdots \\ x_{q5} \end{bmatrix} + \underbrace{\begin{bmatrix} \mathbf{b}_{q1} & \mathbf{0}_v & \cdots & \mathbf{0}_v \\ \mathbf{0}_v & \mathbf{b}_{q2} & \cdots & \mathbf{0}_v \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_v & \mathbf{0}_v & \cdots & \mathbf{b}_{q5} \end{bmatrix}}_{\mathbf{B} \in \mathbb{R}^{15 \times 5}} \begin{bmatrix} \dot{\mathbf{u}}_1 \\ \vdots \\ \dot{\mathbf{u}}_5 \end{bmatrix} \quad (6.2)$$

hervor, wobei  $\mathbf{0}_m \in \mathbb{R}^{3 \times 3}$  eine Null-Matrix und  $\mathbf{0}_v \in \mathbb{R}^{3 \times 1}$  einen Null-Vektor notieren. Es wird angenommen, dass sich die aus dem Prozess resultierende Gesamtprozesskraft  $F_{p,ges}$  gleichmäßig auf die drei Getriebeeinheiten der 3DSP verteilt, sodass die exzentrischen Antriebseinheiten des  $i$ -ten Kniehebelgetriebes eine Kraft von  $F_{p,i}^{(soll)}(t) = F_{p,ges}^{(soll)}(t)/3$  bereitstellen müssen. Die Aufstellung des Gütefunktional (Kostenfunktion) erfordert eine Berechnung der zu bestrafenden Größen aus den in der Zustandsraumdarstellung definierten Zuständen. Um die Stoßelpose  $\mathbf{x}_{st}$  zu berechnen, wird auf das vorwärtskinematische Modell der Presse zurückgegriffen<sup>6</sup>, das eine nichtlineare Abbildung der Antriebspositionen  $f_{ste} : \mathbf{q} \rightarrow \mathbf{x}_{st}$  darstellt. Wie bereits im Grundlagenteil der Arbeit anhand von Formel 2.11 erläutert, ist die durch die exzentrische Antriebseinheit am Stoßeldruckpunkt bereitgestellte Presskraft über inverse differentielle Modelle berechenbar. Werden die verfügbaren Presskräfte der drei Stoßeldruckpunkte der 3DSP vektoriell mit  $\mathbf{F}_p = [F_{p,1} \ F_{p,2} \ F_{p,3}]^T$  beschrieben, ergeben sich diese unter Kenntnis der am Antrieb verfügbaren Nenn-drehmomente  $M_{\varphi,i} = 7000 \text{ Nm}$  zu

$$\mathbf{F}_p(\mathbf{q}) = \begin{bmatrix} j_{\varphi,1}^{-1} & 0 & 0 \\ 0 & j_{\varphi,2}^{-1} & 0 \\ 0 & 0 & j_{\varphi,3}^{-1} \end{bmatrix} \begin{bmatrix} M_{\varphi,1} \\ M_{\varphi,2} \\ M_{\varphi,3} \end{bmatrix}. \quad (6.3)$$

Dabei stellen  $j_{\varphi,1}(\varphi_i, \mathbf{q}_{sp})$  erneut nichtlineare Abbildungen der Antriebspositionen dar und führen somit auf die Funktion zur Berechnung der verfügbaren Prozesskraft  $f_p : \mathbf{q} \rightarrow \mathbf{F}_p$ .

Im Folgenden werden Abweichungen von den Sollgrößen mit  $\Delta \mathbf{x}_{st}(\mathbf{q}) = \mathbf{x}_{st}(\mathbf{q}) - \mathbf{x}_{st}^{(soll)}$  bzw.  $\Delta \mathbf{F}_p(\mathbf{q}) = \mathbf{F}_p(\mathbf{q}) - \mathbf{F}_p^{(soll)}$  notiert und dienen der Aufstellung der Kosten-

<sup>6</sup>Siehe [Hop21] für die Herleitung des kinematischen Modells.

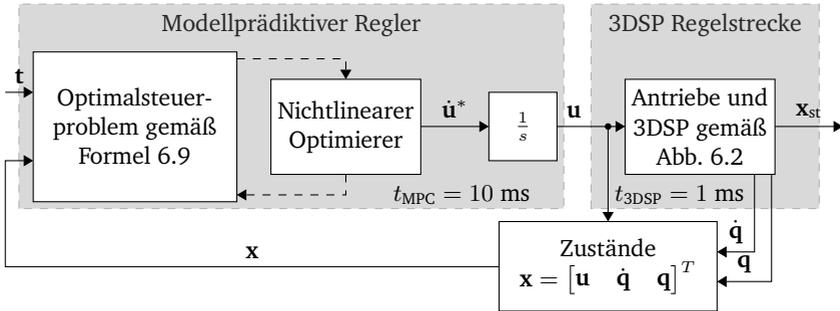


Abbildung 6.3.: Übersicht über die entworfene MPC

funktion. Dabei wird der Lagrange-Term der Kostenfunktion zu

$$L(\mathbf{x}, \dot{\mathbf{u}}) = \Delta \mathbf{x}_{\text{st}}^T(\mathbf{q}) \mathbf{Q} \Delta \mathbf{x}_{\text{st}}(\mathbf{q}) + \mathbf{u}^T \mathbf{W} \mathbf{u} + \dot{\mathbf{u}}^T \mathbf{J} \dot{\mathbf{u}} + \Delta \hat{\mathbf{F}}_p^T(\mathbf{q}) \mathbf{Z} \Delta \hat{\mathbf{F}}_p(\mathbf{q}) \quad (6.4)$$

festgelegt mit

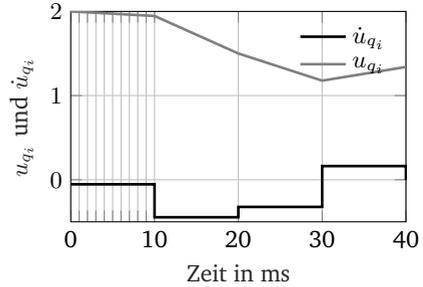
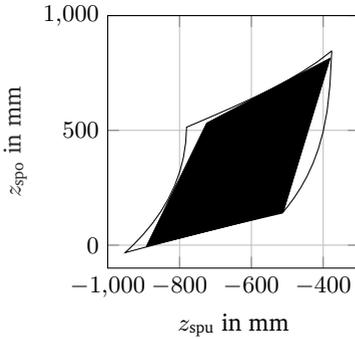
$$\Delta \hat{\mathbf{F}}_{p,i}(\mathbf{q}) = \begin{cases} 0, & \text{wenn } \Delta F_{p,i}(\mathbf{q}) \geq 0, \\ \Delta F_{p,i}(\mathbf{q}), & \text{wenn } \Delta F_{p,i}(\mathbf{q}) < 0 \end{cases}, \quad (6.5)$$

da ausschließlich Unterschreitungen der vorgegebenen Prozesskraft ( $F_{p,i}(\mathbf{q}) < F_{p,i}^{\text{(soll)}}$ ) bestraft werden sollen.  $\mathbf{Q} \in \mathbb{R}^{3 \times 3}$ ,  $\mathbf{W} \in \mathbb{R}^{5 \times 5}$ ,  $\mathbf{J} \in \mathbb{R}^{5 \times 5}$  und  $\mathbf{Z} \in \mathbb{R}^{3 \times 3}$  repräsentieren positiv definite Diagonalmatrizen mit entsprechenden Gewichtungsfaktoren, die die Abweichungen der Stoßelpose  $\Delta \mathbf{x}_{\text{st}}(\mathbf{q})$ , Geschwindigkeitsstellgrößen  $\mathbf{u}$ , Beschleunigungsstellgrößen  $\dot{\mathbf{u}}$  bzw. Unterschreitungen der gewünschten Prozesskraft  $\Delta \mathbf{F}_p(\mathbf{q})$  bestrafen.<sup>7</sup> Der Mayer-Term der Kostenfunktion lautet

$$V(\mathbf{x}) = \Delta \mathbf{x}_{\text{st}}^T(\mathbf{q}) \mathbf{Q}_e \Delta \mathbf{x}_{\text{st}}(\mathbf{q}) \quad (6.6)$$

mit der positiv definiten, diagonalen Gewichtungsmatrix  $\mathbf{Q}_e \in \mathbb{R}^{3 \times 3}$  und bestraft hohe Abweichungen der Stoßelpose im letzten Zeitschritt des Prädiktionshorizontes. Ein großer Vorteil der MPC ist die triviale Einbettung von (nichtlinearen) Beschränkungen. Als lineare Beschränkungen werden die Beträge der Antriebsgeschwindig-

<sup>7</sup>Da in der Kostenfunktion unterschiedliche Größen mit unterschiedlichen Einheiten bestraft werden, bedarf es einer Skalierung der einzelnen Terme der Kostenfunktion. Anhang A.17 bietet Einblicke in das Vorgehen zur Skalierung einzelner Terme und beinhaltet weitere Angaben zu *Acados*-Einstellungen.



(a) Linearisierte Grenzen des Prozessfensters zur Formulierung der Beschränkungen für die Regler ( $t_{\text{MPC}} = 10$  ms) und Strecke ( $t_{3\text{DSP}} = 1$  ms) Spindelpositionen  $\mathbf{q}_{\text{sp}}$

(b) Beziehung zwischen Ausgangsgröße der MPC  $\dot{u}_{q_i}$  und Eingang der Regelstrecke  $u_{q_i}$  unter Nutzung unterschiedlicher Zykluszeiten für den Regler ( $t_{\text{MPC}} = 10$  ms) und Strecke ( $t_{3\text{DSP}} = 1$  ms)

Abbildung 6.4.: Linearisiertes Prozessfenster zur Beschränkung der Spindelpositionen (links) und Beziehung zwischen Reglerstellgröße und Streckeneingang (rechts)

keiten und -beschleunigungen durch  $\bar{\mathbf{q}}$  und  $\bar{\dot{\mathbf{q}}}$  sowie dazugehörige Stellgrößen durch  $\bar{\mathbf{u}}$  und  $\bar{\dot{\mathbf{u}}}$  definiert. Ebenfalls muss sichergestellt werden, dass die Spindelantriebe zu keinem Zeitpunkt das in Kapitel 4 vorgestellte Prozessfenster verlassen. Eine Beschränkung des Prozessfensters ist durch eine nichtlineare, kinematische Transformation im zweidimensionalen Raum bestehend aus Hubhöhe und UT möglich (siehe Prozessfenster  $h$  und  $t_{\text{UT}}$  in Abbildung 4.2) und bietet den Vorteil von linearen Prozessfenstergrenzen. Um jedoch die Nichtlinearitäten der Transformation zu umgehen, wird an dieser Stelle eine direkte, lineare Beschränkung des Spindelprozessfensters gewählt, wobei das in Abbildung 6.4a schwarz gefärbte Polygon die linearisierten Grenzen visualisiert. Mathematisch können die entsprechenden Beschränkungen durch die Ungleichung

$$\mathbf{C}\mathbf{q}_{\text{sp}} \leq \bar{\mathbf{h}} \quad (6.7)$$

mit  $\mathbf{C} \in \mathbb{R}^{4 \times 2}$  umschrieben werden, wobei  $\bar{\mathbf{h}}$  die linearen Grenzen des Polygons quantifiziert. Darüber hinaus wird eine weiche Beschränkung für die Prozesskraft formuliert, die bei einem Verstoß nicht direkt zum Prozessabbruch führt. Da in Formel 6.3 die Nenndrehmomente der Servoantriebe zur Berechnung der verfügbaren Prozesskraft herangezogen werden, jedoch zeitlich begrenzte Überschreitungen der

Nenn Drehmomente bis zum Spitzendrehmoment durchaus erlaubt sind, wird die weiche Beschränkung

$$\mathbf{F}_p^{(\text{soll})} \leq \mathbf{F}_p(\mathbf{q}) + \Delta \hat{\mathbf{F}}_p(\mathbf{q}) \quad (6.8)$$

mit der Slack-Variablen  $\Delta \hat{\mathbf{F}}_p(\mathbf{q})$  eingeführt. So wird eine Unterschreitung der Prozesskraft bzw. eine Überschreitung des Nenn Drehmomentes in der Kostenfunktion zwar bestraft, gleichzeitig wird dem Regler jedoch die Möglichkeit gegeben, entsprechende Antriebspositionen kurzzeitig anzufahren.

Damit kann das Optimalsteuerproblem in diskreter Notation zu

$$\begin{aligned} \min_{\dot{\mathbf{u}}_k} \quad & \sum_{i=0}^{N-1} \Delta \mathbf{x}_{\text{st},i|k}^T(\mathbf{q}) \mathbf{Q} \mathbf{x}_{\text{st},i|k}(\mathbf{q}) + \mathbf{u}_{i|k}^T \mathbf{W} \mathbf{u}_{i|k} \\ & + \dot{\mathbf{u}}_{i|k}^T \mathbf{J} \dot{\mathbf{u}}_{i|k} + \Delta \hat{\mathbf{F}}_{p,i|k}^T(\mathbf{q}) \mathbf{Z} \Delta \hat{\mathbf{F}}_{p,i|k}(\mathbf{q}) \\ & + \mathbf{x}_{\text{st},N|k}^T(\mathbf{q}) \mathbf{Q}_e \mathbf{x}_{\text{st},N|k}(\mathbf{q}) \\ \text{s.t.} \quad & \mathbf{x}_{i+1|k} = f_{\text{ERK3}}(\mathbf{x}_{i|k}, \dot{\mathbf{u}}_{i|k}, \Delta t_{i|k}), \\ & \mathbf{x}_{0|k} = \mathbf{x}(t_k) \\ & \mathbf{C} \mathbf{q}_{\text{sp},i|k} \leq \bar{\mathbf{h}} \\ & |\dot{\mathbf{q}}_{i|k}| \leq \bar{\dot{\mathbf{q}}} \\ & |\ddot{\mathbf{q}}_{i|k}| \leq \bar{\ddot{\mathbf{q}}} \\ & |\mathbf{u}_{i|k}| \leq \bar{\mathbf{u}} \\ & |\dot{\mathbf{u}}_{i|k}| \leq \bar{\dot{\mathbf{u}}} \\ & \mathbf{F}_{p,i|k}^{(\text{soll})} \leq \mathbf{F}_{p,i|k}(\mathbf{q}) + \Delta \hat{\mathbf{F}}_{p,i|k}(\mathbf{q}), \end{aligned} \quad (6.9)$$

zusammengefasst werden.  $(i|k)$  steht dabei stellvertretend für  $(k+i|k)$ , wohingegen  $f_{\text{ERK3}}(\mathbf{x}_{i|k}, \mathbf{u}_{i|k}, \Delta t_{i|k})$  einen Runge-Kutta-Integrator dritter Ordnung repräsentiert, der zur Berechnung zukünftiger Zustände  $\mathbf{x}_{i+1|k}$  basierend auf der Zustandsraumdarstellung aus Formel 6.2 genutzt wird. Die Länge des Prädiktionshorizontes wird durch  $N = 10$  beschrieben.

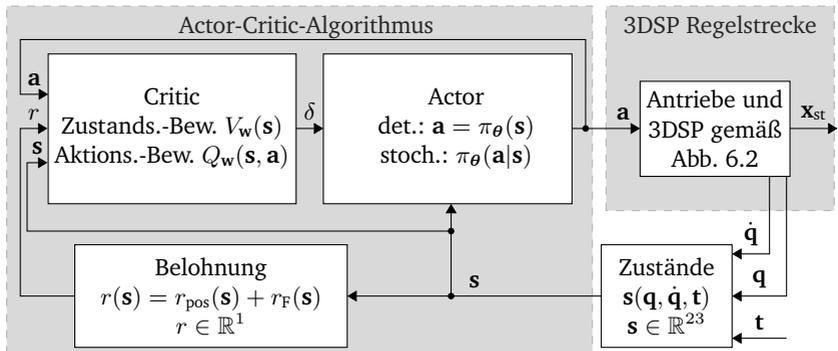


Abbildung 6.5.: Übersicht über den entwickelten AC-Ansatz zur Regelung der 3DSP

### 6.3. Formulierung des Actor-Critic-Ansatzes

Die Simulationsumgebung für die Anwendung der AC-Algorithmen wird aus Gründen der Kompatibilität mit dem bestehenden 3DSP-Simulationsmodell ebenfalls zu Matlab/Simulink gewählt. In dieses wird ein neuer Regelungsmodus eingeführt, der die Anwendung ausgewählter AC-Algorithmen mit unterschiedlichen Zustands- und Aktionsräumen als auch Belohnungsfunktionen erlaubt. Für die finale Applikation der Algorithmen wird auf die RL-Toolbox [Mat23] von *Mathworks* zurückgegriffen. Nähere Informationen über die Implementierung in das Simulationsmodell sind der Masterthesis von Rojahn zu entnehmen. [S11]

Im ersten Schritt bedarf es der Definition von Zustands- und Aktionsräumen sowie der Festlegung einer sinnvoll gewählten Belohnungsfunktion. Weiterhin sind Hyperparameteroptimierungen für eine erfolgreiche Applikation der AC-Algorithmen unausweichlich, da deren Performanz bei suboptimaler Hyperparameterwahl massiv beeinträchtigt wird. Mit Trust Region Policy Optimization (TRPO) [Sch15] und Proximal Policy Optimization (PPO) [Sch17] wird auf zwei On-Policy-Algorithmen zurückgegriffen. Darüber hinaus wird die Eignung von Off-Policy-Algorithmen zur Regelung der 3DSP geprüft, wobei die Algorithmen DDPG [Lil15], TD3 [FHM18] und SAC [Haa18a; Haa18b] Berücksichtigung finden.

Abbildung 6.5 gibt eine Übersicht über den entwickelten AC-Ansatz zur Regelung der 3DSP. AC-Algorithmen verfügen grundsätzlich über einen Critic bestehend aus

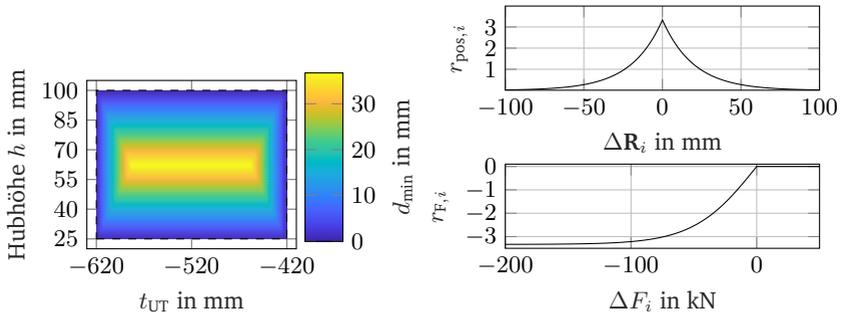
mindestens einer parametrisierten Zustands-Bewertungs-Funktion  $V_w(\mathbf{s})$  und/oder Aktions-Bewertungs-Funktion  $Q_w(\mathbf{s}, \mathbf{a})$  mit Parametervektoren  $\mathbf{w}$ . Dem Critic werden Informationen über Zustände  $\mathbf{s}$ , skalare Belohnungswerte  $r$  und ggf. Aktionen  $\mathbf{a}$  bereitgestellt. Über gradientenbasierte Optimierungsverfahren wird eine temporale Differenz  $\delta$  berechnet und an den Actor weitergegeben, der mit diesem die Parameter  $\theta$  seiner Entscheidungsstrategie  $\pi_\theta$  aktualisiert. Der Actor kann dabei in Abhängigkeit des angewandten Algorithmus als deterministischer  $a = \pi_\theta(\mathbf{s})$  oder stochastischer Actor  $\pi_\theta(\mathbf{a}|\mathbf{s})$  dargestellt werden, wobei bei Letzterem die Aktionswahl durch eine bedingte Wahrscheinlichkeitsverteilung determiniert wird.<sup>8</sup> Übergeordnetes Ziel der Anwendung von AC-Algorithmen ist die Findung einer optimalen Entscheidungsstrategie, die die Summe der erwarteten, diskontierten Belohnungswerte maximiert.

Der Aktionsraum der angewandten AC-Algorithmen besteht im Gegensatz zu der in Kapitel 6.2 vorgestellten MPC aus direkten Geschwindigkeitsvorgaben für die Antriebe, sodass  $\mathbf{a} = [\dot{\mathbf{q}}_\varphi^{(\text{soll})} \quad \dot{\mathbf{q}}_{\text{sp}}^{(\text{soll})}]^T \in \mathbb{R}^5$  gilt. Insgesamt werden den Algorithmen 23 Zustände über Positionen, Geschwindigkeiten, bereitgestellte Kräfte und Positionierungen innerhalb des Spindelprozessfensters zur Verfügung gestellt. Dies führt auf den Zustandsvektor

$$\mathbf{s} = \begin{bmatrix} \mathbf{R}^{(\text{soll})}(\mathbf{q}) & \mathbf{R}^{(\text{ist})}(\mathbf{x}_{\text{st}}^{(\text{soll})}) & \Delta \mathbf{F}_p(\mathbf{q}, F_p^{(\text{soll})}) \\ & d_{\min} & \mathbf{q} & \dot{\mathbf{q}} & \dot{\mathbf{R}}(\dot{\mathbf{q}}) \end{bmatrix}^T \in \mathbb{R}^{23} \quad (6.10)$$

mit den Stoßellagerpositionen  $\mathbf{R}^{(\text{ist})}(\mathbf{q}) \in \mathbb{R}^3$  und  $\mathbf{R}^{(\text{soll})}(\mathbf{x}_{\text{st}}^{(\text{soll})}) \in \mathbb{R}^3$ , den Differenzen zwischen Soll- und Ist-Prozesskraft  $\Delta \mathbf{F}_p(\mathbf{q}, F_p^{(\text{soll})}) \in \mathbb{R}^3$ , den Antriebspositionen  $\mathbf{q} \in \mathbb{R}^5$  und -geschwindigkeiten  $\dot{\mathbf{q}} \in \mathbb{R}^5$  sowie den Stoßellagergeschwindigkeiten  $\dot{\mathbf{R}}(\dot{\mathbf{q}}) \in \mathbb{R}^3$ .  $d_{\min}$  quantifiziert die minimale Distanz zu den Grenzen des Spindelprozessfensters in der Hubhöhen-UT-Repräsentation und ist in Abbildung 6.6a visualisiert. Zusätzlich ist eine Unterschreitung von  $d_{\min} < 1$  mm als Endzustand einer Episode definiert, sodass bei zu starker Annäherung an die Grenzen des Spindelprozessfensters die Simulation abgebrochen wird, wodurch in der entsprechenden Episode keine weiteren Belohnungen gesammelt werden können. Um schnelleres Konvergenzverhalten zu erzielen, werden alle Komponenten des Zustandsvektors vor

<sup>8</sup>Tiefgreifendere Erklärungen der Funktionsweisen von parametrisierten Bewertungsfunktionen (Critic) und Entscheidungsstrategien (Actor) sind Anhang A.9.2 zu entnehmen.



(a) Minimaler Abstand  $d_{\min}$  zu den Grenzen (b) Belohnungsfunktionen für Stößellagerposi-  
 tionen  $r_{\text{pos},i}$  und aufgebrauchte Kräfte  $r_{F,i}$  für  
 Totpunkt-Repräsentation  $i$ -te Getriebeeinheit

Abbildung 6.6.: Visualisierung des minimalen Abstands  $d_{\min}$  zu Grenzen des Spindelprozessfensters (links) und Teilkomponenten der Belohnungsfunktion (rechts)

Einspeisung in die Algorithmen auf einen Wertebereich zwischen 0 und 1 skaliert.<sup>9</sup> Die Belohnungsfunktion gliedert sich gemäß den Verläufen in Abbildung 6.6b in zwei Einzelkomponenten, welche einerseits die Genauigkeit der  $i$ -ten Stößellagerposition über

$$r_{\text{pos},i} = \frac{10}{3} \cdot e^{-50 \cdot |\Delta \mathbf{R}_i|} \quad (6.11)$$

mit  $\Delta \mathbf{R}_i = \mathbf{R}_i^{(\text{soll})} - \mathbf{R}_i^{(\text{ist})}$  belohnen und andererseits Unterschreitungen der bereit-zustellenden Kraft über

$$r_{F,i} = \begin{cases} 0, & \text{wenn } F_{P,i}(\mathbf{q}) \geq F_{P,i}^{(\text{soll})}, \\ -\frac{10}{3} \cdot \left(1 - \frac{2}{\frac{1}{25} e^{\Delta F_{P,i}} + 1}\right), & \text{wenn } F_{P,i}(\mathbf{q}) \leq F_{P,i}^{(\text{soll})}, \end{cases} \quad (6.12)$$

mit  $\Delta F_{P,i} = F_{P,i}(\mathbf{q}) - F_{P,i}^{(\text{soll})}$  bestrafen. Entsprechende Belohnungsanteile werden für alle drei Getriebeeinheiten der 3DSP berechnet und anschließend durch

$$r = \sum_{i=1}^3 r_{\text{pos},i} + r_{F,i} \quad (6.13)$$

<sup>9</sup>Die Normalisierung von Eingangsgrößen für NN ist in der Fachliteratur üblich. Systematische Untersuchungen der Effekte der Normalisierung auf die Performanz und das Konvergenzverhalten von NN, die in industriellen Applikationen zum Einsatz kommen, sind beispielsweise [SS97] zu entnehmen.

---

aggregiert, was auf die skalare Gesamtbelohnung  $r$  führt.<sup>10</sup>

Im ersten Schritt der Hyperparameteroptimierung werden die parametrisierten Bewertungsfunktionen und Entscheidungsstrategien untersucht. Im Rahmen der vorliegenden Arbeit wird dazu ausschließlich auf NN zurückgegriffen, die über zahlreiche Hyperparameter verfügen, die in Kombination mit algorithmenspezifischen Hyperparametern und in Anbetracht langer Simulationszeiten nicht vollfaktoriell getestet werden können. Aus diesem wird der Ansatz verfolgt, auf den Voruntersuchungen von Rojahn [S11] aufzubauen und vielversprechende Netztopologien mit entsprechenden Hyperparametern (Aktivierungsfunktionen, Anzahl versteckter Schichten, Anzahl Neuronen) zu untersuchen. Anschließend werden Modifikationen vorgenommen, woraus die in Anhang A.18 dargestellten NN für die Aktions- und Zustands-Bewertungs-Funktionen (siehe A.31) sowie deterministischen bzw. stochastischen Entscheidungsstrategien (siehe A.32) hervorgehen.

## 6.4. Performanzvergleich anhand Beispielprozessen

Im Folgenden werden die Performanzen der MPC und ausgewählten AC-Algorithmen anhand der Bewegungspfade zweier Massivumformprozesse miteinander verglichen.

### 6.4.1. Stauchen

Der erste Massivumformprozess ist der bereits in Kapitel 4.2 experimentell durchgeführte Stauchprozess. Abbildung 6.7 zeigt das Zusammenwirken von Werkzeug und Bauteil sowie dazugehörige Spannungsverläufe. Charakteristisch für das Stauchen von Werkstücken ist der vollflächige Kontakt zwischen Stempel und Bauteil. Im Vergleich zu inkrementellen Massivumformprozessen erfordert dies signifikant höhere Stauchkräfte.

---

<sup>10</sup>An dieser Stelle sei angemerkt, dass Positionsabweichungen der Stoßellager und nicht der Stoßelpose als Zustände und Grundlage zur Berechnung der Belohnungsfunktion herangezogen werden. Dies bietet den Vorteil, dass kinematische Zusammenhänge des Teilsystems Stoßel nicht durch den Algorithmus erlernt werden müssen, wodurch die Komplexität der Lernaufgabe eingegrenzt wird. Die Transformation der Soll-Größen für die Stoßelpose  $\mathbf{x}_{st}^{(soll)}$  in Soll-Größen für die Stoßellager  $\mathbf{R}^{(soll)}$  erfolgt über die in Kapitel 4.3.1 hergeleitete, approximierte IK des Teilsystem Stoßels. Die Berechnung der aktuellen Stoßelpositionen  $\mathbf{R}^{(ist)}$  erfolgt über ein vorwärtskinematisches Modell basierend auf den aktuellen Antriebsstellungen  $\mathbf{q}$ . Stoßellagergeschwindigkeiten  $\mathbf{R}$  werden über ein differentielles kinematisches Modell basierend auf den Antriebsgeschwindigkeiten  $\dot{\mathbf{q}}$  berechnet.

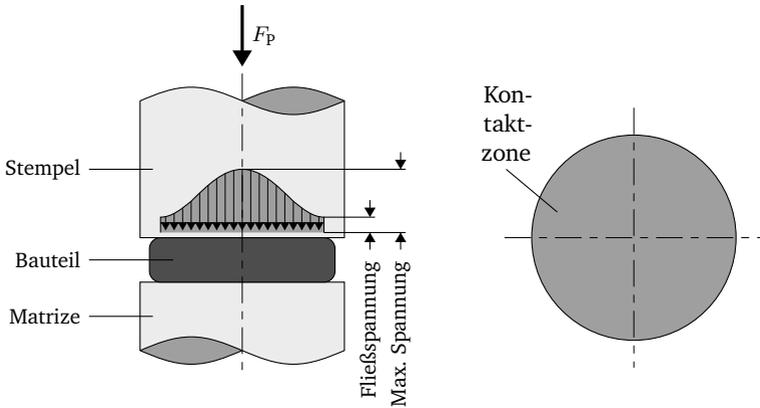


Abbildung 6.7.: Schematische Darstellung eines Stauchprozesses in Anlehnung an [DB10]

Abbildung 6.8 stellt die Sollgrößen für die Anwendung der vorgestellten Regelansätze dar. Es ist ersichtlich, dass innerhalb der 7.5 s langen Prozessdauer etwa 60 mm Stößeltranslation erforderlich ist und im Zeitintervall zwischen 5 und 6 s Prozesskräfte  $F_{p,ges}^{(soll)}$  von bis zu 1150 kN (380 kN pro Getriebeeinheit) aufgebracht werden müssen. Während des gesamten Prozesses sind keine Stößelkippungen erwünscht, sodass  $\theta_x^{(soll)} = \theta_y^{(soll)} = 0^\circ$  gilt. Dies stellt die Übertragbarkeit der Ergebnisse auf redundante Servopressen mit ausschließlich einem Stößelfreiheitsgrad sicher.

Abbildung 6.9 stellt die Ergebnisse der Anwendung unterschiedlicher AC-Algorithmen

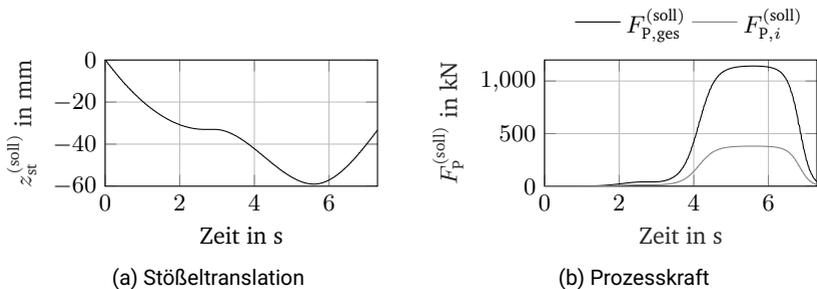
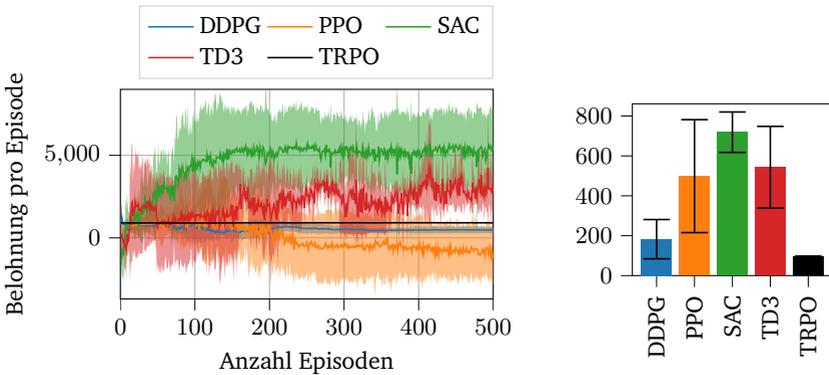


Abbildung 6.8.: Sollgrößen im Stauchprozess



(a) Durchschnittliche erzielte kumulierte Belohnung pro Episode (b) Durchschnittliche Anzahl an Episodenschritten

Abbildung 6.9.: Performanzvergleich angewandter AC-Algorithmen bei modellfreier Regelung der 3DSP in einem Stauchprozess

auf den Stauchprozess dar. Dabei zeigt Abbildung 6.9a die von den Algorithmen erzielten Belohnungen pro Episode über der Trainingsdauer und 6.9b die durchschnittliche Länge der Episoden (Anzahl durchgeführter Schritte), die sich aus dem Erreichen einer der Endzustände (Spindelantriebe verlassen Prozessfenster oder Beendigung der Trajektorie nach 7.5 s) ergibt. Dargestellt sind Mittelwerte von 15 Trainingsdurchläufen mit jeweils 500 Episoden pro Algorithmus, woraus sich entsprechende Mittelwerte und Streuungen berechnen lassen. Transparent hinterlegte Bereiche in Abbildung 6.9a stellen 95%-Konfidenzintervalle dar, Fehlerbalken in 6.9b die jeweilige Standardabweichung.<sup>11</sup>

Abbildung 6.9a macht deutlich, dass das Konvergenzverhalten stark vom angewandten Algorithmus abhängt. Während TRPO, DDPG und PPO kein konvergierendes Verhalten zeigen, führt die Anwendung von komplexeren Algorithmen<sup>12</sup> auf weitaus größere Belohnungswerte. Die durchschnittlichen Belohnungswerte pro Episode beider Algorithmen verlaufen zu Beginn des Trainings ähnlich, wobei mit zunehmender Trainingsdauer der SAC-Algorithmus seine Überlegenheit unter Beweis

<sup>11</sup>Jeweilige Hyperparameterkombinationen und Netztopologien aller Algorithmen sind Anhang A.18 beigefügt.

<sup>12</sup>Sowohl TD3 als auch SAC greifen auf mehrere Bewertungsfunktionen zurück und stellen Weiterentwicklungen der anderen Algorithmen dar.

---

stellt.<sup>13</sup> Wegen dessen Performanz und geringerer Sensitivität gegenüber suboptimal gewählten Hyperparametern werden im Folgenden ausschließlich Hyperparameter des SAC-Algorithmus optimiert und korrespondierende Ergebnisse vorgestellt. Dazu wird eine Hyperparameteroptimierung der in Tabelle A.19 festgehaltenen und für am relevantesten befundenen Hyperparameter vorgenommen, wobei die Hyperparameterkombinationen jeweils über 500 Episoden trainiert werden. Die kumulierte Episodenbelohnung der besten Episode innerhalb der Hyperparameteroptimierung beträgt 7223.6 und wird nachfolgend für Demonstrationszwecke genutzt.<sup>14</sup> Zur Anwendung der MPC werden die Einträge der Gewichtungsmatrizen ebenfalls einer umfassenden Grid Search unterzogen und die vielversprechendsten Ergebnisse nachfolgend vorgestellt.

Abbildung 6.10 vergleicht die aus den beiden Regelansätzen resultierenden Antriebsgeschwindigkeiten der Spindeln (oben) und Exzenter (unten)<sup>15</sup>. Es zeigt sich, dass die Berücksichtigung von Geschwindigkeiten und Stellgrößen in der Kostenfunktion der MPC zu erheblich gleichmäßigeren Antriebsbewegungen führt. Zu Prozessbeginn gibt die MPC vergleichsweise hohe Geschwindigkeitswerte für alle Antriebe aus, die der Eliminierung einer zu Prozessbeginn vorliegenden Regelabweichung dienen. Im Zeitintervall  $3.5 < t < 5.5$  s reagiert die MPC auf hohe Kraftanforderungen durch eine synchrone Verstellung der Spindel- und Exzenterantriebe. Nach  $t \approx 5.5$  s wechseln alle Antriebsgeschwindigkeiten ihr Vorzeichen, was im Rückhub des Stößels begründet liegt. Der SAC-Algorithmus wird im Gegensatz zur MPC nicht für hohe Antriebsgeschwindigkeiten bestraft, weswegen dessen Anwendung zu stark schwankenden Antriebsverläufen führt. Für die Exzenterantriebe ist ein nahezu synchrones Oszillieren der Geschwindigkeiten mit einer Amplitude von etwa 3.5 rad/s und Mittelwert 0 zu beobachten. Die Spindeln wechseln mehrfach vom positiven in den negativen Geschwindigkeitsbereich und vice versa. Die resultierenden

---

<sup>13</sup>Ähnliche Performanzverläufe für RL-Umgebungen mit vergleichbar hohen Dimensionalitäten von Aktions- und Zustandsräumen sind in der Literatur zu finden und bestätigen die Überlegenheit des SAC-Algorithmus. Dazu sei auf die Verläufe der Belohnungsfunktionen in [Haa18b] für die RL-Umgebungen *Half Cheetah* (6 Aktionen, 17 Zustände) & *Ant* (8 Aktionen, 27 Zustände) verwiesen.

<sup>14</sup>Den Hyperparameterkombinationen zugehörige Verläufe der kumulierten Belohnungswerte sind Abbildung A.33 zu entnehmen. Der in Abbildung A.33 schwarz abgebildete Graph führt nach 193 Episoden zum höchsten Belohnungswert von 7223.6. Da der Prozess eine Laufzeit von 7.5 s aufweist und demzufolge eine maximale Anzahl an 750 Zeitschritten pro Episode durchführbar sind, beträgt die maximal erreichbare, kumulierte Belohnung 7500 (gemäß Gleichungen 6.11-6.13 beträgt die maximale Belohnung pro Zeitschritt 10).

<sup>15</sup>Für die Exzentergeschwindigkeiten der MPC ist ausschließlich ein Graph dargestellt, da die Exzenter synchron verfahren werden und die Geschwindigkeitsverläufe aller drei Antriebe deckungsgleich sind.

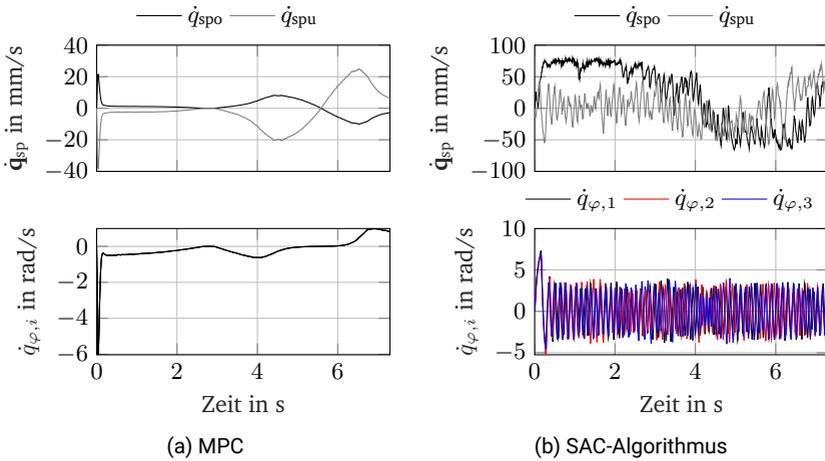


Abbildung 6.10.: Antriebsgeschwindigkeiten beider Regleransätze im Stauchprozess

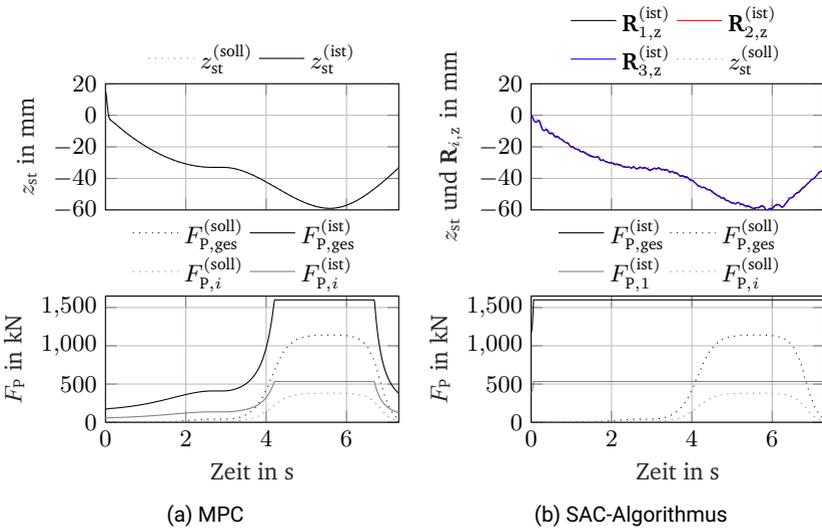


Abbildung 6.11.: Kraft- und Positionsabweichungen beider Regleransätze im Stauchprozess

Regelabweichungen beider Regleransätze sind in Abbildung 6.11 visualisiert.<sup>16</sup> Die MPC folgt der Führungsgröße für die Stößeltranslation nahezu ohne Abweichung, sodass im oberen Plot von Abbildung 6.11a kaum Unterschiede zwischen Soll- und Ist-Position zu erkennen sind. Die für  $t = 0$  vorliegende Regelabweichung wird in kürzester Zeit ausgeregelt, die synchronen Geschwindigkeiten der Exzenterantriebe verhindern eine Verkippung des Stößels. Die Regelabweichungen unter Anwendung des SAC-Algorithmus fallen ebenfalls sehr gering aus. Zwar führen die stark schwankenden Antriebsgeschwindigkeiten zu schwankenden Positionsverläufen der Stößellager, dennoch folgen diese der Soll-Größe  $z_{st}^{(soll)}$  mit hoher Genauigkeit. Dies ist besonders nennenswert, da der Algorithmus auf Basis eines modellfreien Ansatzes operiert, der keinerlei Kenntnisse über kinematische Beziehungen innerhalb der Presse besitzt. Weiterhin sind in Abbildung 6.11 (unten) die Verläufe der erforderlichen und bereitgestellten Presskraft dargestellt. Die MPC reagiert vor Erhöhung der erforderlichen Presskraft auf die Sollwertänderung und verstellt die Spindeln, sodass im Zeitintervall von  $4 < t < 7$  s hohe Presskräfte aufgebracht werden können. Der SAC-Algorithmus reagiert direkt zu Prozessbeginn auf hohe Prozesskräfte und stellt die Antriebe über die gesamte Prozessdauer so, dass hohe Kraftübertragungen zwischen Exzenterantrieben und Stößellager sichergestellt sind. Dies resultiert jedoch darin, dass die am Abtrieb resultierende Translationsbewegung maßgeblich von den Spindelantrieben induziert wird.

Tiefere Einblicke in das Verhalten der Regleransätze erlaubt Abbildung 6.12. Gezeigt werden in der Abbildung die zu Totpunktstellungen korrespondierenden Exzenterwinkel  $\varphi_{OT}$  (OT) und  $\varphi_{UT}$  (UT) sowie die aus den Regelungen resultierenden Ist-Verläufe der Exzenterwinkel  $\varphi_i^{(ist)}$ . Während die MPC die Nähe zum UT ausschließlich in den Zeitintervallen sucht, in denen hohe Presskräfte aufgebracht werden müssen ( $4 < t < 7$  s), oszillieren die aus dem SAC-Algorithmus hervorgehenden Exzenterwinkel über die gesamte Prozessdauer nahe am UT. Diese unterschiedlichen Verhaltensweisen erklären die in Abbildung 6.11 gezeigten Verläufe der bereitgestellten Kräfte. Darüber hinaus erklärt die nahe Totpunktpositionierung der Exzenterwinkel durch den SAC-Algorithmus und die damit einhergehende, niedrige

---

<sup>16</sup>Für die MPC ist die Stößeltranslation  $z_{st}^{(ist)}$  dargestellt, da die Exzenterantriebe synchron verfahren werden und keine Unterschiede bezüglich der vertikalen Positionen der Stößellager  $R_i^{(ist)}$  vorliegen (keine Stößelkipfung). Die leicht unterschiedlichen Exzentergeschwindigkeiten bei Anwendung des SAC-Algorithmus führen zu geringfügigen Positionsabweichungen der Stößellager, weswegen im oberen Plot von Abbildung 6.11b alle drei Stößellagerpositionen  $R_i^{(ist)}$  dargestellt werden.

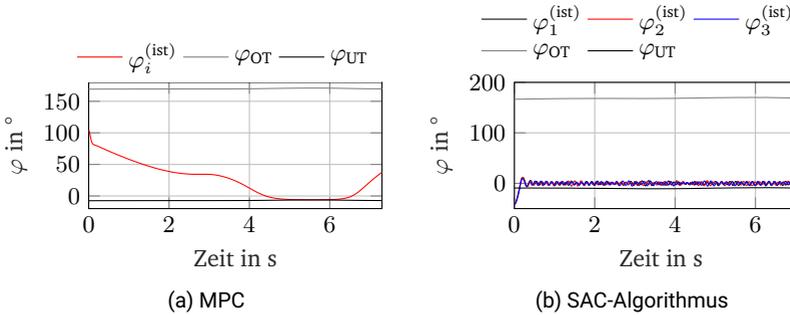


Abbildung 6.12.: Exzenterpositionen beider Regleransätze im Stauchprozess

Geschwindigkeitsübertragung von Exzenterantrieben auf Stößellager, weshalb die stark oszillierenden Exzentergeschwindigkeiten nur geringfügigen Einfluss auf die Positionsgenauigkeit des Stößels haben.

Weiterhin kann die Performanz beider Regleransätze im Hinblick auf Energieeffizienz miteinander verglichen werden. Dazu wird das von Hoppe entwickelte inverse Dynamikmodell [Hop21] genutzt und um das Teilsystem Spindel<sup>17</sup> erweitert. Das Modell basiert auf dem in Gleichung 2.15 vorgestellten Modellierungsansatz und ermöglicht eine Berechnung der aufzubringenden Antriebsdrehmomente unter Kenntnis vorgegebener Antriebsbewegungsprofile. Dabei finden Coriolis-, Zentrifugal-, Gravitations-, Massenträgheits- (White-Box-Modellierungen) und Reibkräfte (Gray-Box-Modellierung) Berücksichtigung. Um eine bessere Vergleichbarkeit der Regleransätze zu gewährleisten, werden Einflüsse der Prozesskraft, die bei beiden Ansätzen ähnliche Auswirkungen auf das kumulierte Drehmoment haben, nicht berücksichtigt.

Abbildung 6.13 stellt die kumulierten Antriebsdrehmomente  $\Sigma M_q = \sum_{i=1}^5 |M_{q_i}|$  für beide Regleransätze vergleichend dar. Es ist ersichtlich, dass eine Anwendung der MPC infolge der initial bestehenden Regelabweichung in hohen Drehmomenten resultiert. Dabei wird ein kumuliertes Drehmoment von etwa 35 kNm erforderlich. Nachdem die Regelabweichung eliminiert ist und die Anwendung der MPC auf glatte Bewegungsverläufe führt, überschreitet das kumulierte Drehmoment über die gesamte Prozessdauer 10 kNm nicht. Dagegen führen die stark oszillationsbehafteten Antriebsbewegungen unter Anwendung des SAC-Algorithmus auf ein deutlich

<sup>17</sup>Siehe Abbildung 4.3a für eine Untergliederung der Pressenkinematik in unterschiedliche Teilsysteme.

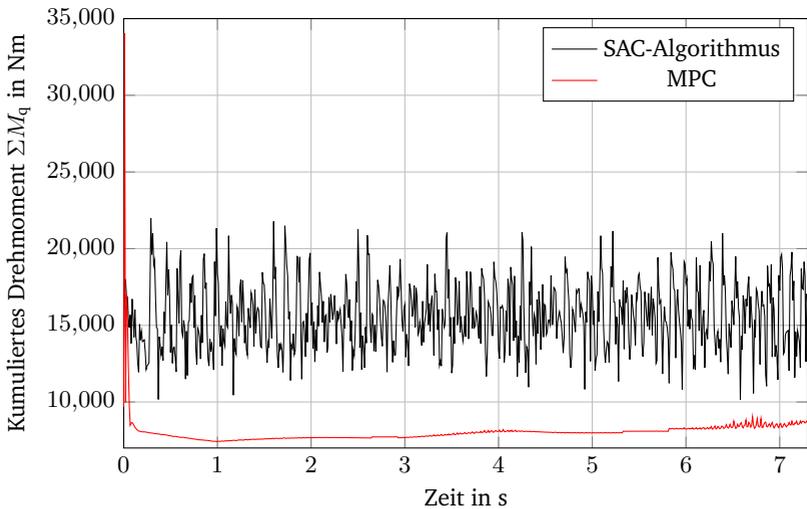


Abbildung 6.13.: Vergleich der kumulierten Antriebsdrehmomente unter Anwendung beider Regleransätze im Stauchprozess

höheres Drehmomentenniveau. Die starken Oszillationen spiegeln sich ebenfalls in den Antriebsdrehmomenten wider. Das durchschnittliche Drehmoment beträgt etwa 15 kNm und ist demnach doppelt so hoch wie das unter Anwendung der MPC. Das starke Rauschen der kumulierten Drehmomente geht mit Drehmomentenspitzen von über 20 kNm einher. Dies lässt darauf schließen, dass die durch die MPC generierten Antriebstrajektorien deutlich energieeffizienter sind.

### 6.4.2. Taumelschmieden

Als zweites Demonstrationsbeispiel dient ein Taumelschmiedeprozess, bei dem neben der Stoßeltranslation ebenfalls ein spiraler Verlauf der Stoßelklippfreiheitsgrade gewünscht ist. Eine experimentelle Realisierung des Bewegungspfades auf der 3DSP ist in Anhang A.5 zu finden, die Erstellung des spiralen Bewegungspfades beruht auf Formeln aus [Sam13; HZH16]. Experimentelle Untersuchungen zum Taumelschmieden und deren regelungstechnischen Herausforderungen finden sich in der Literatur und greifen auf Hexapoden [Hes07] oder hydraulische Pressen mit Schwenkwellen

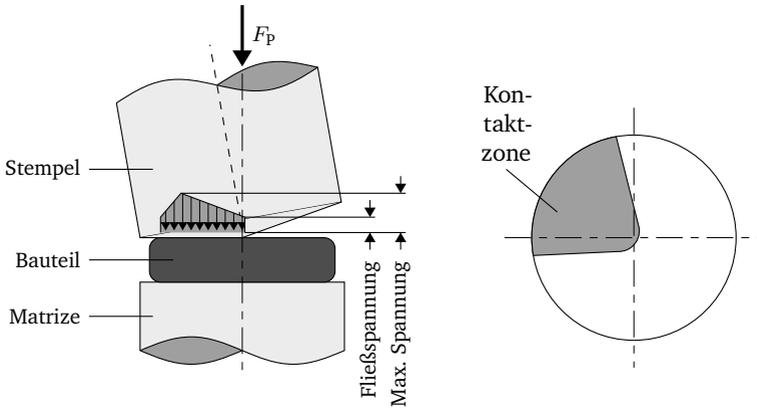


Abbildung 6.14.: Schematische Darstellung eines Taumelschmiedeprozesses in Anlehnung an [DB10]

[Hua22] zur Realisierung der erforderlichen Bewegungsprofile zurück. Abbildung 6.14 zeigt das Zusammenwirken von Werkzeug und Bauteil beim Taumelschmieden, wobei im Gegensatz zum Stauchprozess nun lokaler Werkzeug-Bauteil-Kontakt vorliegt, was sich in weitaus geringeren Prozesskräften widerspiegelt. Die Sollgrößen der Simulation sind in Abbildung 6.15 abgebildet. Die Stößeltranslation ergibt sich analog zum Stauchprozess, die erforderliche Prozesskraft wird im Vergleich zum Stauchprozess aufgrund kleinerer Kontaktflächen halbiert. Infolge der spiralen Bewegungsbahn ergibt sich nun ein oszillierender Sollgrößenverlauf für die Stößelkippfreiheitsgrade, bei dem beide Stößelkippfreiheitsgrade auf einen Grad Verkipfung auf- und anschließend wieder abschwngen. Die Prozessdauer wird auf 5 s reduziert.

Die Hyperparameteroptimierung des SAC-Algorithmus erfolgt analog zum Stauchprozess.<sup>18</sup> Auch für die MPC wird eine Hyperparameteroptimierung vorgenommen, die besten Ergebnisse beider Ansätze werden im Folgenden vorgestellt.

Abbildung 6.16 stellt die Geschwindigkeitsverläufe der Antriebe für beide Regleransätze dar. Erneut ist zu sehen, dass die MPC zu erheblich glatteren Geschwindigkeitsverläufen führt und die aus dem SAC-Algorithmus resultierenden Verläufe

<sup>18</sup>Ergebnisse der Hyperparameteroptimierung für den Taumelschmiedeprozess sind analog zum Stauchprozess aus Kapitel 6.4.1 in Anhang A.18 (Tabelle A.20) einsehbar.

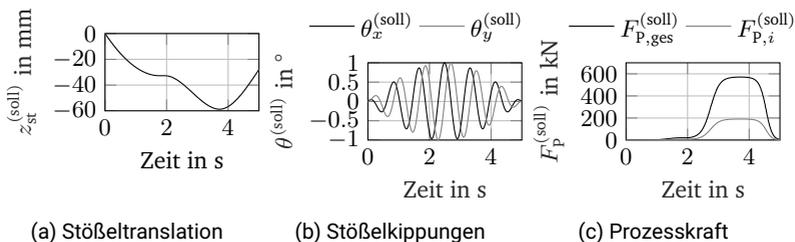


Abbildung 6.15.: Sollgrößen im Taumelschmiedeprozess

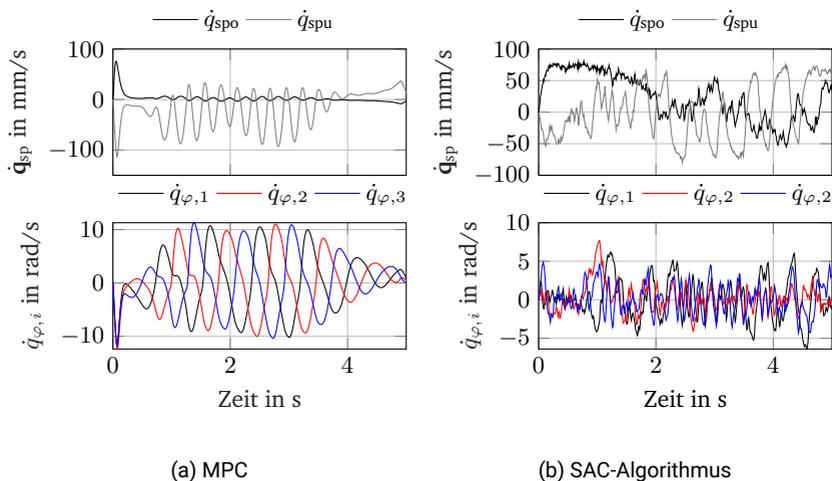


Abbildung 6.16.: Antriebsgeschwindigkeiten beider Regleransätze im Taumelschmiedeprozess

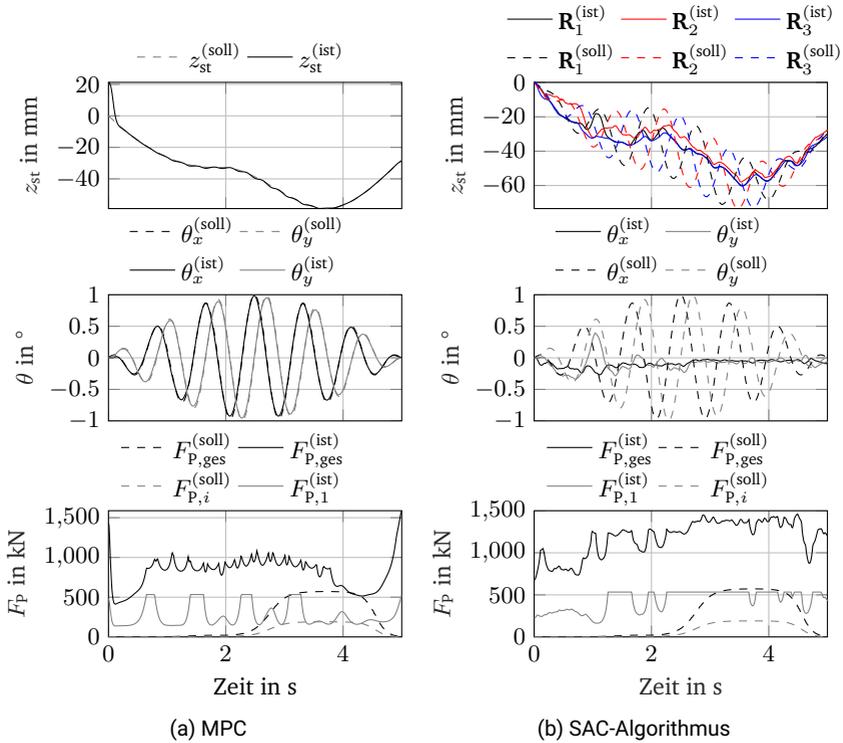


Abbildung 6.17.: Kraft- und Posenausweichungen beider Regleransätze im Taumelstriedeprozess

deutlich ruckbehafteter sind. Die MPC führt auf oszillationsähnliche Geschwindigkeitsverläufe für alle Exzenterantriebe und den unteren Spindeltrieb, ähnliche Tendenzen sind ebenfalls für den SAC-Algorithmus erkennbar. Die MPC geht mit phasenversetzten Geschwindigkeitsverläufen der Exzenterantriebe einher, die für die Realisierung der Taumelbewegung des Stößels erforderlich sind, wohingegen ein phasenversetztes Betreiben der Exzenterantriebe bei der Anwendung des SAC-Algorithmus nicht erkennbar ist. Die Auswirkungen der Antriebsgeschwindigkeitsverläufe auf die Regelgüte der Stößelpose als auch auf die bereitgestellte Presskraft sind in Abbildung 6.17 visualisiert. Für die MPC werden die drei Stößelfreiheitsgrade dargestellt, wohingegen für den SAC-Algorithmus die Positionen der Stößellager

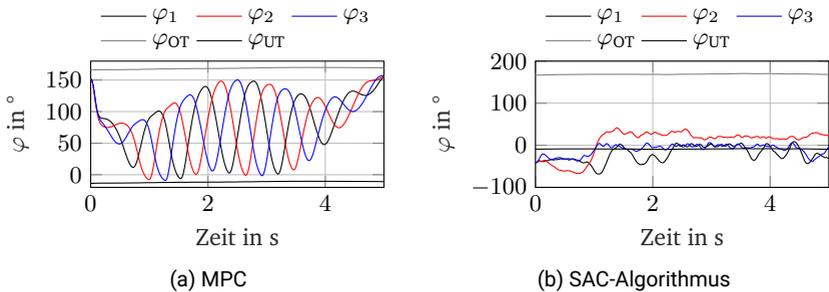


Abbildung 6.18.: Exzenterpositionen beider Regleransätze im Taumelschmiedeprozess

$\mathbf{R}_i$  als auch die Stößelkippfreiheitsgrade abgebildet werden. Die MPC führt trotz initialer Abweichung des translatorischen Freiheitsgrades ( $\Delta z_{st}|_{t=0}$ ) zu einer hohen Regelgüte, sowohl Ist-Größen der Stößeltranslation als auch der -verkipfung folgen den Sollgrößen ohne nennenswerte Abweichungen. Gleichzeitig führt eine Verkipfung des Stößels zwangsläufig dazu, dass mindestens eine der parallelkinematisch angeordneten Getriebeeinheiten nicht in unmittelbarer Nähe zu einer Totpunktstellung operieren kann und somit Positionen angefahren werden müssen, die mit geringen Presskräften einhergehen. Eine simultane Stößelkipfung bei gleichzeitiger Bereitstellung hoher Presskräfte an jedem Stößellager bedarf unterschiedlichen Positionierungen der Rotationspunkte  $\mathbf{B}_{0,i}$  für jede Getriebeeinheit, was durch die parallelkinematische Maschinentopologie im Teilsystem Spindel (siehe dazu Abbildung 4.3) nicht realisierbar ist. Demzufolge unterschreiten sowohl die Gesamtpresskraft  $F_{P,ges}^{(ist)}$  als auch die für das erste Stößellager bereitgestellte Presskraft  $F_{P,1}^{(ist)}$  die zugehörigen Soll-Kräfte kurzzeitig, was die Realisierbarkeit des Prozesses aufgrund der Möglichkeit einer temporären Überschreitung des Motornendrehmomentes jedoch nicht gefährdet. Im Gegensatz zur MPC führt die Anwendung des SAC-Algorithmus auf deutlich höhere Regelabweichungen. Anhand der Ist- und Soll-Verläufe der Stößellager  $\mathbf{R}_i$  ist ersichtlich, dass für den Taumelschmiedeprozess erforderliche, phasenversetzte Positionsszillationen nicht realisiert werden. Zwar unterscheiden sich die Bewegungen der Stößellager voneinander, jedoch nähern sich deren Ist-Positionen dem Mittelwert der oszillierenden Sollwertvorgabe an. Dies hat zur Folge, dass kaum Stößelkippen erzielt werden und der maximale

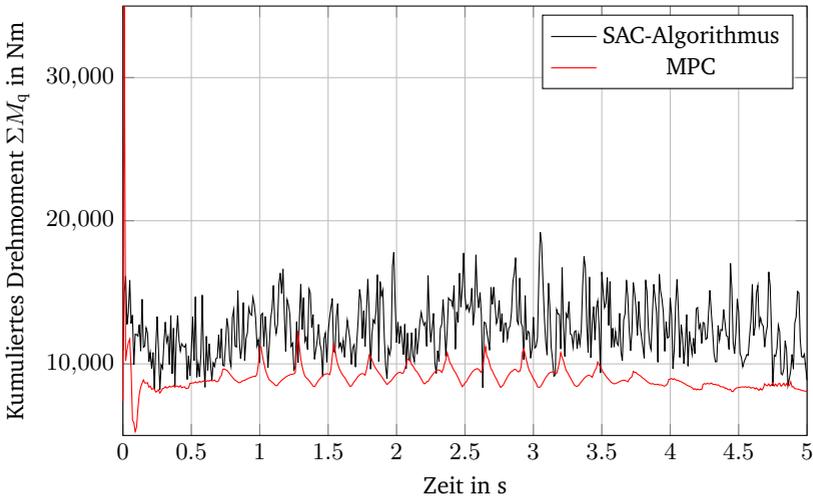


Abbildung 6.19.: Vergleich der kumulierten Antriebsdrehmomente unter Anwendung beider Regleransätze im Taumelschmiedeprozess

Verkippwinkel lediglich  $0.4^\circ$  beträgt. Betrachtet man die bereitgestellte Presskraft des SAC-Algorithmus, ist ersichtlich, dass diese über die gesamte Prozesskraft bereitgestellt wird. Dies ist wiederum erklärbar anhand von Abbildung 6.18, die die Exzenterwinkel und dazugehörige Totpunktstellungen unter Anwendung von MPC und dem SAC-Algorithmus abbildet. Während die MPC die gewünschten, phasenversetzten Antriebsbewegungen realisiert und stets kurz vor Erreichen des UT eine Geschwindigkeitsumkehr vollzieht, platziert der SAC-Algorithmus die Exzenterantriebe stets nah am UT. Dies geht zwar mit einer hohen Kraftbereitstellung über die gesamte Prozessdauer einher, steht jedoch einer genauen Stößelposenregelung bei geforderten Stößelkippen entgegen.

Ein erneuter Vergleich der kumulierten Antriebsdrehmomente bestätigt die Ergebnisse aus dem Stauchprozess. Abbildung 6.19 stellt die kumulierten Antriebsdrehmomente beider Regler aus dem Taumelschmiedeprozess dar. Erneut ist zu sehen, dass die MPC zur schnellen Eliminierung der anfänglichen Regelabweichung kurzzeitig hohe Antriebsdrehmomente erfordert, jedoch über die restliche Prozessdauer vergleichbar geringe Drehmomente aufzubringen sind. Wiederum führt die Anwendung des SAC-Algorithmus infolge höherer Geschwindigkeiten und Beschleunigungen

---

auf ein höheres Drehmomentenniveau. Während die zyklischen Abtriebsbewegungen unter Anwendung der MPC ebenfalls auf zyklische Verläufe des kumulierten Drehmomentes führen, oszilliert das kumulierte Drehmoment unter Anwendung des SAC-Algorithmus stark und erreicht Spitzenwerte von knapp 20 kNm. Dies ist insbesondere in Anbetracht der Tatsache bemerkenswert, dass die Anwendung des SAC-Algorithmus zu höheren Regelabweichungen und schwächer ausgeprägten Stößelbewegungen führt, wohingegen die Abtriebsbewegung beim Einsatz der MPC dem Verlauf der Soll-Stößelpose nahezu fehlerfrei folgt.

## 6.5. Zwischenfazit

Im vorangegangenen Kapitel werden mit der MPC und RL zwei simulationsgestützte Ansätze zur Findung optimaler Antriebstrajektorien für redundante Mehrpunkt-Servopressen vorgestellt und miteinander verglichen. Redundante Servopressen zeichnen sich durch die Möglichkeit aus, während des Hubes die Lagen der Totpunkte zu verstellen, wodurch Einfluss auf die Geschwindigkeits- und Kraftübersetzung zwischen Servoantrieben und Stößeldruckpunkten genommen werden kann. Eine hohe Manipulierbarkeit der Position des Stößeldruckpunktes (und damit eine hohe Geschwindigkeitsübersetzung) und eine hohe Kraftübersetzung sind jedoch substitutionale Anforderungen, die durch eine intelligente Platzierung der redundanten Antriebsfreiheitsgrade in Abhängigkeit des vorgegebenen Kraftprofils eingestellt werden müssen.

Die MPC greift dabei auf kinematische Modelle der Presse zurück, die vor der Findung von optimalen Antriebstrajektorien unweigerlich vorliegen müssen. Bestrafungen von Positionsabweichungen der Stößelpose, Unterschreitungen der notwendigen Prozesskraft sowie betragsmäßig hohen Stellgrößen führen auf Antriebstrajektorien, die sowohl die notwendigen Prozesskräfte bereitstellen als auch zu geringen Abweichungen der Stößelpose führen. Die Bestrafung hoher Stellgrößen resultiert in nahezu oszillationsfreien Antriebsbewegungen mit geringem Energiebedarf, weswegen die Eignung von MPC zur Findung optimaler Antriebstrajektorien unter Beweis gestellt wird.

Vorteilhaft bei der Anwendung von modellfreien RL-Algorithmen ist der Verzicht auf jegliche Modellbildungen, sodass den Algorithmen die Aufgabe zugesprochen

---

wird, die Dynamik des Antriebsübertragungsverhaltens sowie kinematische Beziehungen innerhalb der Presse zu erlernen. Dies erschwert die Regelaufgabe für den Algorithmus ungemein, weswegen eine Vielzahl an Trainingsepisoden erforderlich ist, um Antriebstrajektorien zu generieren, die den Anforderungen nach Positionsgenauigkeit und hohen Kraftübertragungen gerecht werden. Der angewandte SAC-Algorithmus führt teilweise auf Antriebstrajektorien, die den genannten Anforderungen gerecht werden, führt jedoch aufgrund der fehlenden Bestrafung hoher Stellgrößen in der Belohnungsfunktion zu oszillationsbehafteten Antriebsbewegungen. Ansätze zur Berücksichtigung weiterer Optimierungsgrößen, wie etwa Reduktion der notwendigen Antriebsdrehmomente und -rucke (siehe dazu auch [S11]), verkomplizieren die Regelaufgabe immens und gefährden die Konvergenz des Algorithmus. Die Möglichkeit, Einfluss auf das Verhalten des Reglers (und damit auf die generierte Antriebstrajektorie) zu nehmen, ergibt sich durch unterschiedliche Gewichtungen der einzelnen Bestandteile der Belohnungsfunktion und wird in der Literatur in Anwendungen des autonomen Fahrens [Tan22], der Robotik [Xie19] und der Energieversorgung [Wei21] demonstriert. Multikriterielle Belohnungsfunktionen mit konträren oder gar substitutionalen Optimierungskriterien stellen die Algorithmen vor besonders hohe Herausforderungen. [Roi13] In Kombination mit dem dynamischen Antriebsübertragungsverhalten und der nichtlinearen Kinematik der 3DSP sowie zusätzlichen Anforderungen an energieeffiziente Antriebsbewegungen weist die Lernaufgabe offenbar eine zu hohe Komplexität auf, um mit den derzeitig verfügbaren AC-Algorithmen zufriedenstellend gelöst zu werden. Abhilfe könnte in Zukunft ein Multi-Agenten-Ansatz schaffen, bei dem jeder Antrieb als einzelner Agent modelliert wird und lediglich eine Unteraufgabe löst. So kann jedem Exzenterantrieb die Positionsregelung eines einzelnen Stoßelddruckpunktes und den Spindelantrieben die Bereitstellung der Presskraft als Regelungsaufgabe zugeordnet werden. Ähnliche Ansätze finden sich in der Literatur beispielsweise bei der Positionsregelung von Robotern mit serieller Kinematik. [PYL21]

---

## 7. Zusammenfassung und Ausblick

---

Umformtechnische Prozesse sind inhärent unsicherheitsbehaftet und bedürfen bei hohen Anforderungen an gleichbleibende Bauteilqualität einer Kompensation unsicherer Einflüsse. Die aus Halbzeugen, Werkzeugen, Maschinen und Umwelt induzierte Unsicherheit pflanzt sich in die Bauteileigenschaften fort und spiegelt sich in schwankenden Bauteileigenschaften wider. Redundante Mehrpunkt-Servopressen bieten die Flexibilität, durch frei programmierbare Antriebs- bzw. Abtriebspfade Bewegungen zu realisieren, die Einfluss auf Bauteileigenschaften nehmen und gleichzeitig prozessspezifischen Anforderungen nach variablen Geschwindigkeits- und Kraftübersetzungen gerecht werden. Die Ausschöpfung genannter Potenziale ist jedoch gekoppelt an den Entwurf und die Anwendung kaskadierter Eigenschaftsregelkreise, die auf performante Online-Maschinenregelungen als auch Offline-Produktregelungen zurückgreifen. Im Rahmen der vorliegenden Arbeit werden die Potenziale von KI-gestützten Modellbildungen entlang der gesamten Reglerkaskade demonstriert.

Auf invers-differentiellen Modellen beruhende Online-Maschinenregelungen von Mehrpunkt-Servopressen verfolgen das Ziel einer hochgenauen Regelung der Stößelpose. Durch Messung der Positionen aller Stößeldruckpunkte kann maschinenseitige Unsicherheit, die sich aus Fertigungsungenauigkeiten oder Einfederungen der Getriebeglieder ergibt, erfasst und kompensiert werden. Im Rahmen der Arbeit wird ein Ansatz vorgestellt, der auf Gain-Scheduling-Techniken zurückgreift und eine Adaption der Reglerübertragungsfunktion an linearisierte Arbeitspunkte ermöglicht. Dies geht mit erheblichen Genauigkeitssteigerungen der Regelung einher, die sich sowohl in genaueren Stößelposenverläufen als auch maßhaltigeren Bauteilgeometrien in inkrementellen Umformprozessen widerspiegeln. Überwachte Lernalgorithmen können dabei helfen, (invers-)kinematische Transformationen der Führungsgrößen zu berechnen, sodass anstelle der Stößelpose die vertikalen Positionen der Stößeldruckpunkte regelbar sind.

Interaktionsmöglichkeiten zwischen den nach dem Prozess gemessenen Bauteileigenschaften und der Online-Maschinenregelung werden durch den Offline-Produktregler geschaffen. Dazu kommen im Rahmen der Arbeit sowohl überwachte als auch bestärkende Lernverfahren zum Einsatz, die basierend auf Zusammenhängen zwi-

---

schen Parametern der Antriebspfade und resultierenden Bauteileigenschaften Modelle ableiten, die auf zukünftige Produktionsdurchläufe anwendbar sind. Unter der Voraussetzung, dass über die gewählten Parameter der Antriebspfade die entsprechenden Bauteileigenschaften manipulierbar sind, stellt sich heraus, dass sich ML-Algorithmen grundsätzlich zur Prädiktion optimierter Antriebspfadparameter eignen und eine Einstellung gewünschter Bauteileigenschaften mit hoher Güte ermöglichen. Wesentliche Probleme bei der Anwendung von ML-Algorithmen sind mangelnde Modelladaptivitäten und Dateneffizienzen, deren Auswirkungen auf die Modellperformanz durch kurzzyklische Aktualisierungen der Modelle (kontinuierliches Lernen) und synthetische Datenerzeugungen (bspw. FEM-Simulationen) zu begrenzen, jedoch nicht zu eliminieren sind. Insbesondere unbekannte Störungen, die nicht im für das Training des ML-Algorithmus genutzten Datensatz reflektiert sind, stellen wesentliche Herausforderungen für die Anwendung der Algorithmen dar, wobei explorierende Lernalgorithmen besser auf solche Störungen adaptieren können.

Speist der KI-gestützte Produktregler einen optimierten Abtriebspfad aus, gilt es diesen für redundante Mehrpunkt-Servopressen invers in optimierte Antriebspfade zu übersetzen. Dabei sind die durch den Prozess festgelegten Kraft- und Geschwindigkeitsanforderungen am Abtrieb in der Antriebspfadermittlung zu berücksichtigen, was im Rahmen der Arbeit anhand der Anwendung von modellprädiktiver Regelung und bestärkenden Lernalgorithmen demonstriert wird. Die modellprädiktive Regelung führt sowohl für eindimensionale als auch dreidimensionale Abtriebspfade zu vielversprechenden Optimierungsergebnissen, die die Realisierung besonders kraftintensiver Prozesse zulassen. Die Anwendung bestärkender Lernalgorithmen führt dagegen zwar auf nachvollziehbare Optimierungsergebnisse, jedoch ebenfalls auf hohe Positionsabweichungen mit stark oszillationsbehafteten Antriebsbewegungen, weswegen die Eignung bestärkender Lernalgorithmen für den genannten Anwendungsfall noch nicht unter Beweis gestellt werden kann.

Aus den Erkenntnissen der vorliegenden Arbeit können Implikationen für zukünftige Forschungsbemühungen abgeleitet werden. Besonders vielversprechend erscheint eine experimentelle Erprobung von bestärkenden Lernalgorithmen zur Regelung von Bauteileigenschaften in mehrstufigen Umformprozessen, bei denen Zustände aus Sensorsignalen vorangegangener Umformstufen extrahiert werden. Simulative Untersuchungen am Beispiel eines flexiblen Gesenkbiegeprozesses aus Kapitel 5.2 zeigen deutlich auf, dass bestärkende Lernalgorithmen Informationen über schwankende Halbzeugeigenschaften qualitätsfördernd verwerten können. In der Literatur sind eine Vielzahl an Untersuchungen zu finden, die Korrelationen zwischen sensorisch erfassten Signalen und Halbzeugschwankungen belegen [Hav18; Gro16; Sch22], weswegen davon ausgegangen wird, dass bestärkende Lernalgorithmen ebenso signalbasierte Informationen qualitätsfördernd verwerten. Besonders vorteilhaft dabei

---

ist, dass die in dieser Arbeit performantesten Algorithmen Off-Policy-Algorithmen darstellen und somit die Datenerzeugung nicht an die Anwendung der entsprechenden Entscheidungsstrategie gebunden ist. Liegen Anwendern demzufolge Datensätze vor, die sowohl Steuergrößen, Qualitätsdaten (Bauteileigenschaften) und Sensordaten den einzelnen Bauteilen zuordnen, können auf bestärkenden Lernalgorithmen beruhende Modelle entwickelt werden. Anschließend sind deren Aktionswahlen abgleichbar mit denen der bereits implementierten Regelungen, wodurch die Robustheit erprobt und damit die Vertrauenswürdigkeit bereits vor Einsatz des Modells im realen Prozess gesteigert werden kann.

Einen weiteren Forschungsansatz stellt die in Kapitel 6 vorgestellte Positionsregelung redundanter Mehrpunkt-Servopressen unter Nutzung bestärkender Lernalgorithmen dar. Zwar konnte in der vorliegenden Arbeit die Eignung der Algorithmen nicht final unter Beweis gestellt werden, jedoch existieren in der Literatur vielversprechende Multi-Agenten-Ansätze, die bereits auf Werkzeugmaschinen mit divergierenden Kinematiken erprobt worden sind. Bei der Anwendung eines Multi-Agenten-Ansatzes stellt jeder Pressenantrieb einen einzelnen Agenten dar, der unter Kenntnis relevanter Systemzustände eine untergeordnete Regelungsaufgabe erfüllen soll, wodurch die Komplexität der Regelung reduziert und das Gesamtsystem in Unterteile zerlegt wird. Besonders vorteilhaft bei der Anwendung von bestärkenden Lernalgorithmen ist, dass echtzeitliche Applikationen auf der Pressensteuerung problemlos möglich sind, da im Gegensatz zur modellprädiktiven Regelung während des Maschinenbetriebes keine Optimierungsprobleme gelöst werden müssen. Damit bieten bestärkende Lernalgorithmen das Potenzial, die in Kapitel 4 vorgestellten, auf kinematischen Modellen beruhenden Regelansätze zu substituieren. Voraussetzung dafür ist jedoch das Betreiben intensiver Forschungsbemühungen, um die Algorithmen für eine sichere und performante Positionsregelung zu qualifizieren.

---

## Literaturverzeichnis

---

### Wissenschaftliche Arbeiten mit Beteiligung des Verfassers

- [E1] P. Groche, A. Breunig, K. Chen, D. A. Molitor, J. Ha, B. L. Kinsey und Y. P. Korkolis. „Effectiveness of Different Closed-Loop Control Strategies for Deep Drawing on Single-Acting 3D Servo Presses“. In: *CIRP Annals* 71.1 (2022), S. 357–360. doi: 10.1016/j.cirp.2022.04.072.
- [E2] F. Hoppe, D. A. Molitor und P. Groche. „Non-linear Robust Closed-Loop Control of Presses with Geometric Singularities. In Chapter: Strategies for Mastering Uncertainty“. In: *Strategies for Mastering Uncertainty*. Springer, 2021, S. 397–402. doi: 10.1007/978-3-030-78354-96.
- [E3] A. Kokozinski, D. A. Molitor, C. Kubik und P. Groche. „Blechverarbeitung 4.0 - Steigerung der Produktivität in schnelllaufenden, mehrstufigen Blechumformprozessen durch intelligente Datenanalyse“. In: *EFB-Kolloquium Blechverarbeitung - Blechverarbeitung MORGEN unter den Aspekten Nachhaltigkeit + Digitalisierung*. Europäische Forschungsgesellschaft für Blechverarbeitung e.V., 2023.
- [E4] C. Kubik, D. A. Molitor, M. Rojahn und P. Groche. „Towards a Real-Time Tool State Detection in Sheet Metal Forming Processes Validated by Wear Classification during Blanking“. In: *IOP Conference Series: Materials Science and Engineering*. Bd. 1238. 1. IOP Publishing, 2022, S. 012067. doi: 10.1088/1757-899X/1238/1/012067.
- [E5] C. Kubik, M. Becker, D. A. Molitor und P. Groche. „Towards a Systematical Approach for Wear Detection in Sheet Metal Forming Using Machine Learning“. In: *Production Engineering* 17 (2023), S. 21–36. doi: 10.1007/s11740-022-01150-x.
- [E6] C. Kubik, D. A. Molitor, M. Becker und P. Groche. „Knowledge Discovery in Engineering Applications Using Machine Learning Techniques“. In: *Journal of Manufacturing Science and Engineering* 144.9 (2022), S. 091003. doi: 10.1115/1.4054158.

- 
- [E7] C. Kubik, D. A. Molitor, M. Rojahn und P. Groche. „Deep Learning-based Domain Adaptation for a generalized detection of wear phenomena during blanking“. In: 35 (2023), S. 904–914. doi: 10.1016/j.mfglet.2023.08.005.
- [E8] C. Kubik, D. A. Molitor, S. Varchmin, D. Leininger, J. Ohrenberg und P. Groche. „Image based Feature Extraction for Inline Quality Inspection and Wear Classification in High Speed Blanking Processes“. In: *The International Journal of Advanced Manufacturing Technology* (2023). doi: 10.1007/s00170-023-12653-x.
- [E9] D. A. Molitor, V. Arne, F. Hoppe und P. Groche. „Gain Scheduled Task Space Control of Multi DOF Machine Tools with Non-Linear Parallel Kinematics“. In: *Control Engineering Practice* 144 (2024), S. 105823. doi: 10.1016/j.conengprac.2023.105823.
- [E10] D. A. Molitor, C. Kubik, M. Knoll, M. Becker und P. Groche. „Ableitung eines Vorgehensmodells zur systematischen Wissensgenerierung aus Sensordaten: Zustandsbewertung produktionstechnischer Prozesse mittels maschineller Lernverfahren“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 116.5 (2021), S. 352–357. doi: 10.1515/zwf-2021-0066.
- [E11] D. A. Molitor, V. Arne, G. Noemark und P. Groche. „Inline Closed-Loop Control of Bending Angles with Machine Learning Supported Springback Compensation“. In: *International Journal of Material Forming* 17 (2024), S. 8. doi: 10.1007/s12289-023-01802-y.
- [E12] D. A. Molitor, V. Arne, D. Spies, F. Hoppe und P. Groche. „Task Space Control of Ram Poses of Multipoint Servo Presses“. In: *Journal of Process Control* 129 (2023), S. 103057. doi: 10.1016/j.jprocont.2023.103057.
- [E13] D. A. Molitor, C. Kubik, M. Becker, R. H. Hetfleisch, F. Lyu und P. Groche. „Towards High-Performance Deep Learning Models in Tool Wear Classification with Generative Adversarial Networks“. In: *Journal of Materials Processing Technology* 302 (2022), S. 117484. doi: 10.1016/j.jmatprotec.2021.117484.
- [E14] D. A. Molitor, C. Kubik, R. H. Hetfleisch und P. Groche. „Was Bauteile über den Verschleiß genutzter Stanzwerkzeuge verraten“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 116.12 (2021), S. 903–907. doi: 10.1515/zwf-2021-0163.
- [E15] D. A. Molitor, C. Kubik, R. H. Hetfleisch und P. Groche. „Workpiece Image-based Tool Wear Classification in Blanking Processes Using Deep Convolutional Neural Networks“. In: *Production Engineering* 16 (2022), S. 481–492. doi: 10.1007/s11740-022-01113-2.

- 
- [E16] C. Schlegel, D. A. Molitor, C. Kubik, D. Martin und P. Groche. „Tool Wear Segmentation in Blanking Processes with Fully Convolutional Networks based Digital Image Processing“. In: *Journal of Materials Processing Technology* 324 (2024), S. 118270. DOI: 10.1016/j.jmatprotec.2023.118270.
- [E17] D. Spies, D. A. Molitor, J. Damon, M. Knoll, S. Dietrich, P. Groche und V. Schulte. „Conception of a Multivariable Product Property Control for Punch-Hole-Rolling“. In: *ESAFORM 2023, Materials Research Proceedings*. 2023, S. 2081–2090. DOI: 10.21741/9781644902479-223.
- [E18] G. A. Staudter, T. Öztürk, D. M. Martin, J. Hartig, D. A. Molitor, F. Hoppe, R. Anderl, P. Groche, P. F. Pelz und M. Weigold. „An Approach for Mastering Data-Induced Conflicts in the Digital Twin Context“. In: *International Journal of Product Lifecycle Management* 13.1 (2021), S. 25–47. DOI: 10.1504/IJPLM.2021.115698.
- [E19] S. Volz, D. A. Molitor, J. Launhardt und P. Groche. „Maschinelles Lernen in der Tribologie - Entwicklung einer Methodik zur Ermittlung von Reibkoeffizienten in der Kaltmassivumformung“. In: *Werkstatttechnik Online* 112.10 (2022), S. 643–648. DOI: 10.37544/1436-4980-2022-10-13.

## Studentische Arbeiten mit Beteiligung des Verfassers

- [ES1] O. S. Ciupitu, E. Duygun, D. A. Molitor, G. Noemark, T. P. Rosswinkel und O.-E. Taskiran. *Knowledge Discovery in Databases durch die Nutzung von künstlicher Intelligenz in der Domäne Blechumformung*. Advanced Research Project. 2020.
- [ES2] D. A. Molitor. *Erfolgsfaktoren innovativer Forschungsprojekte - Eine empirische Untersuchung mit Implikationen zum Projektcontrolling sowie Simulation einer Positionsregelung am Beispiel der 3D-Servo-Press*. Masterthesis. 2020.

## Vom Verfasser betreute studentische Arbeiten

- [S1] E. Andreas. *Explainable AI (XAI) - Generierung von Systemwissen in Deep Learning Modellen zur Verschleißminimierung beim Stanzen*. Masterthesis. 2022.
- [S2] T. Bayer, A. M. Hayn, F. S. Kempf, D. S. Leininger, J. Ohrenberg und S. A. F. Schönhof. *Konstruktion zur Erfassung von Bilddaten und Implementierung eines Machine Learning Modells zur Bewertung des Werkzeugzustandes in Produktionsprozessen*. Advanced Design Project. 2021.

- 
- [S3] R. H. Hetfleisch. *Entwicklung eines bildverarbeitenden Deep Learning Modells zur Identifikation von Prozesszuständen beim Stanzen*. Masterthesis. 2021.
- [S4] J. Hofmann, F.-J. M. Jaklin, D. I. Miranda Silva und C.-V. N. Veitenheimer. *Entwicklung eines Deep Learning Modells zur Klassifikation fehlerhafter Bauteilzustände in mehrstufigen Blechumformprozessen basierend auf inline erfassten Bilddaten*. Advanced Design Project. 2023.
- [S5] Z. Hou. *Fully Convolutional Networks for Semantic Segmentation of Images in Blanking Processes*. Masterthesis. 2022.
- [S6] L. E. Klinar, F. S. Georgi, J. Dietz, J. Voges, A. Kohlsetter und C. Schlegel. *Semantisch, segmentierende Verschleißüberwachung von Stanzstempeln durch bildbasierte Anwendung von faltenden, neuronalen Netzen*. Advanced Design Project. 2022.
- [S7] R. Krämer. *KI-gestützte Trajektorienplanung in einem SPIF-Prozess auf einer 3D-Servo-Pressen*. Masterthesis. 2023.
- [S8] B. P. Li. *Model Predictive Closed-Loop Control Approaches for Optimized Manipulation of the Ram Pose of 3D Servo Presses*. Masterthesis. 2023.
- [S9] F. Lyu. *Maschinelles Lernen in der Umformtechnik - Steigerung von Modellperformanzen durch Data Augmentation*. Masterthesis. 2021.
- [S10] G. Noemark. *Nutzung maschineller Lernverfahren zur Prädiktion und Regelung rückgefederter Biegewinkel beim freien Biegen*. Masterthesis. 2022.
- [S11] M. Rojahn. *Bestärkendes Lernen zur optimierten Manipulation der Stoßelpose von 3D-Servo-Pressen*. Masterthesis. 2023.
- [S12] M. Sossenheimer. *Steigerung der Generalisierbarkeit von faltenden, neuronalen Netzen zur Prädiktion von Werkzeugverschleiß in Stanzprozessen*. Masterthesis. 2022.
- [S13] C. Tang. *Explainable-AI Techniques for Increasing the Explainability of Image- and Time Series-based Deep Learning Models in Blanking Processes*. Masterthesis. 2023.
- [S14] C.-V. N. Veitenheimer. *Regelung der Rückfederung eines Gesenkbiegeprozesses auf einer 3D-Servo-Pressen unter Nutzung maschineller Lernverfahren*. Masterthesis. 2023.

---

## Weitere Literaturangaben

- [Aba16] M. Abadi u. a. „Tensorflow: A System for Large-Scale Machine Learning“. In: *Osdi*. Bd. 16. 2016. Savannah, GA, USA. 2016, S. 265–283. doi: 10.48550/arXiv.1605.08695.
- [Ade21] A. A. Adediran, A. A. Akinwande, O. A. Balogun und B. J. Olorunfemi. „Optimization Studies of Stir Casting Parameters and Mechanical Properties of TiO<sub>2</sub> Reinforced Al 7075 Composite Using Response Surface Methodology“. In: *Scientific Reports* 11.1 (2021), S. 19860. doi: 10.1038/s41598-021-99168-1.
- [Ale72] J. M. Alexander. „On the Theory of Rolling“. In: *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences* 326.1567 (1972), S. 535–563. doi: 10.1098/rspa.1972.0025.
- [All16] J. Allwood, S. Duncan, J. Cao, P. Groche, G. Hirt, B. Kinsey, T. Kuboki, M. Liewald, A. Sterzing und A. Tekkaya. „Closed-Loop Control of Product Properties in Metal Forming“. In: *CIRP Annals* 65.2 (2016), S. 573–596. doi: 10.1016/j.cirp.2016.06.002.
- [All09] J. Allwood, O. Music, A. Raithathna und S. R. Duncan. „Closed-Loop Feedback Control of Product Properties in Flexible Metal Forming Processes with Mobile Tools“. In: *CIRP Annals* 58.1 (2009), S. 287–290. doi: 10.1016/j.cirp.2009.03.065.
- [AW05] M. Arentoft und T. Wanheim. „A New Approach to Determine Press Stiffness“. In: *CIRP Annals* 54.1 (2005), S. 265–268. doi: 10.1016/S0007-8506(07)60099-7.
- [APB18] M. Arnst, J.-P. Ponthot und R. Boman. „Comparison of Stochastic and Interval Methods for Uncertainty Quantification of Metal Forming Processes“. In: *Comptes Rendus Mécanique* 346.8 (2018), S. 634–646. doi: 10.1016/j.crme.2018.06.007.
- [ASH12] M. Asemabadi, M. Sedighi und M. Honarpisheh. „Investigation of Cold Rolling Influence on the Mechanical Properties of Explosive-Welded Al/Cu Bimetal“. In: *Materials Science and Engineering: A* 558 (2012), S. 144–149. doi: 10.1016/j.msea.2012.07.102.
- [Att08] A. Attanasio, E. Ceretti, C. Giardini und L. Mazzone. „Asymmetric Two Points Incremental Forming: Improving Surface Quality and Geometric Accuracy by Tool Path Optimization“. In: *Journal of Materials Processing Technology* 197.1-3 (2008), S. 59–67. doi: 10.1016/j.jmatprotec.2007.05.053.

- 
- [ACG06] A. Attanasio, E. Ceretti und C. Giardini. „Optimization of Tool Path in Two Points Incremental Forming“. In: *Journal of Materials Processing Technology* 177.1-3 (2006), S. 409–412. DOI: 10.1016/j.jmatprotec.2006.04.047.
- [Aur09] J. C. Aurich, D. Dornfeld, P. Arrazola, V. Franke, L. Leitz und S. Min. „Burrs — Analysis, Control and Removal“. In: *CIRP Annals* 58.2 (2009), S. 519–542. DOI: 10.1016/j.cirp.2009.09.004.
- [Avg07] N. Avgoustinov. *Modelling in Mechanical Engineering and Mechatronics: Towards Autonomous Intelligent Software Models*. Springer Science & Business Media, 2007. DOI: 10.1007/978-1-84628-909-5.
- [Bar20] M. Barandas, D. Folgado, L. Fernandes, S. Santos, M. Abreu, P. Bota, H. Liu, T. Schultz und H. Gamboa. „TSFEL: Time Series Feature Extraction Library“. In: *SoftwareX* 11 (2020), S. 100456. DOI: 10.1016/j.softx.2020.100456.
- [Bay10] N. Bay, A. Azushima, P. Groche, I. Ishibashi, M. Merklein, M. Morishita, T. Nakamura, S. Schmid und M. Yoshida. „Environmentally Benign Tribo-Systems for Metal Forming“. In: *CIRP Annals* 59.2 (2010), S. 760–780. DOI: 10.1016/j.cirp.2010.05.007.
- [BC01] T. Bedford und R. Cooke. „Different Types of Uncertainty“. In: *Probabilistic Risk Analysis: Foundations and Methods*, Cambridge University Press, United Kingdom (2001), S. 17–38.
- [Beh13] A. K. Behera, J. Verbert, B. Lauwers und J. R. Duflou. „Tool Path Compensation Strategies for Single Point Incremental Sheet Forming Using Multivariate Adaptive Regression Splines“. In: *Computer-Aided Design* 45.3 (2013), S. 575–590. DOI: 10.1016/j.cad.2012.10.045.
- [Beh08] B. Behrens, T. Matthias, M. Czora, J. Poelmeyer und M. Ahrens. „Improving the Accuracy of Numerical Investigations of Multi-Stage Sheet Metal Processes by Coupling a Process FE Analysis with the Machine Simulation“. In: *Proceedings of 1st International Conference on Process Machine Interaction, Hannover, Germany*. 2008, S. 133–138.
- [Beh07] B. Behrens, C. Brecher, M. Hork und M. Werbs. „New Standardized Procedure for the Measurement of the Static and Dynamic Properties of Forming Machines“. In: *Production Engineering* 1 (2007), S. 31–36. DOI: 10.1007/s11740-007-0005-0.

- 
- [Bel13] J. Belchior, M. Guillo, E. Courteille, P. Maurine, L. Leotoing und D. Guines. „Off-line Compensation of the Tool Path Deviations on Robotic Machining: Application to Incremental Sheet Forming“. In: *Robotics and Computer-Integrated Manufacturing* 29.4 (2013), S. 58–69. doi: 10.1016/j.rcim.2012.10.008.
- [BDD02] T. Bellemans, B. De Schutter und B. De Moor. „Models for Traffic Control“. In: *JOURNAL A* 43.3/4 (2002), S. 13–22.
- [Ber10] J. Berglund, C. A. Brown, B.-G. Rosen und N. Bay. „Milled Die Steel Surface Roughness Correlation with Steel Sheet Friction“. In: *CIRP Annals* 59.1 (2010), S. 577–580. doi: 10.1016/j.cirp.2010.03.140.
- [Bis06] C. M. Bishop. *Pattern Recognition and Machine Learning*. Bd. 4. 4. Springer, 2006.
- [Ble23] F. Bleicher, D. Biermann, W.-G. Drossel, H.-C. Moehring und Y. Altintas. „Sensor and Actuator Integrated Tooling Systems“. In: *CIRP Annals* (2023). doi: 10.1016/j.cirp.2023.05.009.
- [BMB23] BMBF. *Aktionsplan Künstliche Intelligenz des BMBF - Neue Herausforderungen chancenorientiert angehen*. [https://www.bmbf.de/bmbf/shareddocs/downloads/files/nationale\\_ki-strategie.pdf?\\_\\_blob=publicationFile&v=2](https://www.bmbf.de/bmbf/shareddocs/downloads/files/nationale_ki-strategie.pdf?__blob=publicationFile&v=2). zul. geprüft am 31.08.2023. 2023.
- [Bon09] T. Bonnemains, H. Chanal, B.-C. Bouzgarrou und P. Ray. „Stiffness Computation and Identification of Parallel Kinematic Machine Tools“. In: *Journal of Manufacturing Science and Engineering* 131.4 (2009). doi: 10.1115/1.3160328.
- [BHT15] T. van den Boogaard, J. Havinga und R. van Tijum. „Model-based Control of Strip Bending in Mass Production“. In: *CIRP Annals* 64.1 (2015), S. 297–300. doi: 10.1016/j.cirp.2015.04.092.
- [Box79] G. E. Box. „Robustness in the Strategy of Scientific Model Building“. In: *Robustness in Statistics*. Elsevier, 1979, S. 201–236. doi: 10.1016/B978-0-12-438150-6.50018-2.
- [BEW09] C. Brecher, M. Esser und S. Witt. „Interaction of Manufacturing Process and Machine Tool“. In: *CIRP Annals* 58.2 (2009), S. 588–607. doi: 10.1016/j.cirp.2009.09.005.
- [BLC20] D. Briesenick, M. Liewald und P. Cyron. „Potentials of an Adaptive Blank Positioning to Control Material and Process Fluctuations in Deep Drawing“. In: *IOP Conference Series: Materials Science and Engineering*. Bd. 967. 1. IOP Publishing. 2020, S. 012068. doi: 10.1088/1757-899X/967/1/012068.

- 
- [Bun23] Bundesregierung. *Strategie Künstliche Intelligenz der Bundesregierung*. [https://www.bmbf.de/SharedDocs/Downloads/de/2023/230823-executive-summary-ki-aktionsplan.pdf?\\_\\_blob=publicationFile&v=1](https://www.bmbf.de/SharedDocs/Downloads/de/2023/230823-executive-summary-ki-aktionsplan.pdf?__blob=publicationFile&v=1). zul. geprüft am 31.08.2023. 2023.
- [BC04] T. Buranathiti und J. Cao. „An Effective Analytical Model for Springback Prediction in Straight Flanging Processes“. In: *International Journal of Materials and Product Technology* 21.1-3 (2004), S. 137–153. doi: 10.1504/IJMPT.2004.004748.
- [Cao19] J. Cao, E. Brinksmeier, M. Fu, R. X. Gao, B. Liang, M. Merklein, M. Schmidt und J. Yanagimoto. „Manufacturing of Advanced Smart Tooling for Metal Forming“. In: *CIRP Annals* 68.2 (2019), S. 605–628. doi: 10.1016/j.cirp.2019.05.001.
- [Cha00] L. Chabbi, W. Lehnert, R. Kawalla und F. Lehnert. „Hot and Cold Forming Behaviour of Magnesium Alloys AZ31 and AZ61“. In: *Magnesium Alloys and their Applications* (2000), S. 621–627. doi: 10.1002/3527607552.ch98.
- [CCK22] K. Chen, A. J. Carter und Y. P. Korkolis. „Flange Wrinkling in Deep-Drawing: Experiments, Simulations and a Reduced-Order Model“. In: *Journal of Manufacturing and Materials Processing* 6.4 (2022), S. 76. doi: 10.3390/jmmp6040076.
- [CCL13] P.-Y. Cheng, P.-J. Chen und Y.-T. Lin. „Small Mechanical Press with Double-Axis Servo System for Forming of Small Metal Products“. In: *The International Journal of Advanced Manufacturing Technology* 68.9 (2013), S. 2371–2381. doi: 10.1007/s00170-013-4851-y.
- [Chi91] P. Chiacchio, S. Chiaverini, L. Sciavicco und B. Siciliano. „Global Task Space Manipulability Ellipsoids for Multiple-Arm Systems“. In: *IEEE Transactions on Robotics and Automation* 7.5 (1991), S. 678–685. doi: 10.1109/70.97880.
- [DR10] T. De Souza und B. Rolfe. „Characterising Material and Process Variation Effects on Springback Robustness for a Semi-Cylindrical Sheet Metal Forming Process“. In: *International Journal of Mechanical Sciences* 52.12 (2010), S. 1756–1766. doi: 10.1016/j.ijmecsci.2010.09.009.
- [Den22] J. Deng, S. Sierla, J. Sun und V. Vyatkin. „Reinforcement Learning for Industrial Process Control: A Case Study in Flatness Control in Steel Industry“. In: *Computers in Industry* 143 (2022), S. 103748. doi: 10.1016/j.compind.2022.103748.

- 
- [Den20] B. Denkena, E. Abele, C. Brecher, M.-A. Dittrich, S. Kara und M. Mori. „Energy Efficient Machine Tools“. In: *CIRP Annals* 69.2 (2020), S. 646–667. DOI: 10.1016/j.cirp.2020.05.008.
- [DIN23] DIN. *DIN EN ISO 80000-2: Größen und Einheiten - Teil 2: Mathematik*. Deutsches Institut für Normung e. V. Berlin, 2023.
- [DIN16] DIN. *Geometrische Produktspezifikation und -prüfung (GPS) - Annahme- und Bestätigungsprüfung für Koordinatenmesssysteme (KMS) - Teil 8: KMG mit optischen Abstandssensoren (ISO 10360-8:2013); Deutsche Fassung EN ISO 10360-8:2013*. Deutsches Institut für Normung e. V. 2016.
- [DL80] E. Doege und K. Lange. „Static and Dynamic Stiffness of Presses and some Effects on the Accuracy of Workpieces“. In: *CIRP Annals* 29.1 (1980), S. 167–171. DOI: 10.1016/S0007-8506(07)61316-X.
- [DB10] E. Doege und B. Behrens. *Handbuch Umformtechnik*. Springer Berlin Heidelberg, 2010. DOI: 10.1007/978-3-642-04249-2.
- [Doh15] K. Dohda, C. Boher, F. Rezai-Aria und N. Mahayotsanun. „Tribology in Metal Forming at Elevated Temperatures“. In: *Friction* 3 (2015), S. 1–27. DOI: 10.1007/s40544-015-0077-3.
- [Doh21] K. Dohda, M. Yamamoto, C. Hu, L. Dubar und K. F. Ehmann. „Galling Phenomena in Metal Forming“. In: *Friction* 9 (2021), S. 665–685. DOI: 10.1007/s40544-020-0430-z.
- [DLG20] J. Dornheim, N. Link und P. Gumbsch. „Model-Free Adaptive Optimal Control of Episodic Fixed-Horizon Manufacturing Processes Using Reinforcement Learning“. In: *International Journal of Control, Automation and Systems* 18 (2020), S. 1593–1604. DOI: 10.1007/s12555-019-0120-7.
- [Dor22] J. Dornheim, L. Morand, S. Zeitvogel, T. Iraki, N. Link und D. Helm. „Deep Reinforcement Learning Methods for Structure-Guided Processing Path Optimization“. In: *Journal of Intelligent Manufacturing* 33 (2022), S. 333–352. DOI: 10.1007/s10845-021-01805-z.
- [DL82] D. Dowson und B. Landau. „The Fréchet Distance between Multivariate Normal Distributions“. In: *Journal of multivariate analysis* 12.3 (1982), S. 450–455. DOI: 10.1016/0047-259X(82)90077-X.
- [DZH19] W.-G. Drossel, W. Zorn und L. Hamm. „Modular System to Measure and Control the Force Distribution in Deep Drawing Processes to Ensure Part Quality and Process Reliability“. In: *CIRP Annals* 68.1 (2019), S. 309–312. DOI: 10.1016/j.cirp.2019.04.061.

- 
- [Dul20] G. Dulac-Arnold, N. Levine, D. J. Mankowitz, J. Li, C. Paduraru, S. Goyal und T. Hester. „An Empirical Investigation of the Challenges of Real-World Reinforcement Learning“. In: *arXiv Preprint* (2020). doi: 10.48550/arXiv.2003.11881.
- [ES99] K. Elkins und R. Sturges. „Springback Analysis and Control in Small Radius Air Bending“. In: *Journal of Manufacturing Science and Engineering* 121.4 (1999), S. 679–688. doi: 10.1115/1.2833103.
- [End17] B. Endelt. „Design Strategy for Optimal Iterative Learning Control Applied on a Deep Drawing Process: Recognising that Stamping and Deep-Drawing Operations are Repetitive Processes — which Can Learn and Improve based on Process History“. In: *The International Journal of Advanced Manufacturing Technology* 88.1-4 (2017), S. 3–18. doi: 10.1007/s00170-016-8501-z.
- [ED10] B. Endelt und J. Danckert. „Iterative Learning and Feedback Control Applied on a Deep Drawing Process“. In: *International Journal of Material Forming* 3 (2010), S. 25–28. doi: 10.1007/s12289-010-0698-z.
- [End22] B. Endelt. „In-process Feedback Control of Tube Hydro-Forming Process“. In: *The International Journal of Advanced Manufacturing Technology* 119.11-12 (2022), S. 7723–7733. doi: 10.1007/s00170-022-08683-6.
- [FPS96] U. Fayyad, G. Piatetsky-Shapiro und P. Smyth. „From Data Mining to Knowledge Discovery in Databases“. In: *AI Magazine* 17.3 (1996), S. 37–37. doi: 10.1609/aimag.v17i3.1230.
- [Fei17] M. Feistle, I. Koslow, M. Krinninger, R. Golle und W. Volk. „Reduction of Burr Formation for Conventional Shear Cutting of Boron-Alloyed Sheets through Focused Heat Treatment“. In: *Procedia CIRP* 63 (2017), S. 493–498. doi: 10.1016/j.procir.2017.03.161.
- [Fio15] A. Fiorentino, E. Ceretti, G. C. Feriti und C. Giardini. „Improving Accuracy in Aluminum Incremental Sheet Forming of Complex Geometries Using Iterative Learning Control“. In: *Key Engineering Materials*. Bd. 651. Trans Tech Publ. 2015, S. 1096–1102. doi: 10.4028/www.scientific.net/KEM.651-653.1096.
- [Fio14] A. Fiorentino, G. Feriti, E. Ceretti, C. Giardini, C. Bort und P. Bosetti. „Development of Tool Path Correction Algorithm in Incremental Sheet Forming“. In: *Key Engineering Materials*. Bd. 622. Trans Tech Publ. 2014, S. 382–389. doi: 10.4028/www.scientific.net/KEM.622-623.382.

- 
- [FGR98] A. Forcellese, F. Gabrielli und R. Ruffini. „Effect of the Training Set Size on Springback Control by Neural Network in an Air Bending Process“. In: *Journal of Materials Processing Technology* 80 (1998), S. 493–500. doi: 10.1016/S0924-0136(98)00122-8.
- [Fu13] Z. Fu, J. Mo, F. Han und P. Gong. „Tool Path Correction Algorithm for Single-Point Incremental Forming of Sheet Metal“. In: *The International Journal of Advanced Manufacturing Technology* 64 (2013), S. 1239–1248. doi: 10.1007/s00170-012-4082-7.
- [FHM18] S. Fujimoto, H. Hoof und D. Meger. „Addressing Function Approximation Error in Actor-Critic Methods“. In: *International Conference on Machine Learning*. PMLR. 2018, S. 1587–1596. doi: 10.48550/arXiv.1802.09477.
- [Gao20] R. X. Gao, L. Wang, M. Helu und R. Teti. „Big Data Analytics for Smart Factories of the Future“. In: *CIRP Annals* 69.2 (2020), S. 668–692. doi: 10.1016/j.cirp.2020.05.002.
- [GPM89] C. E. Garcia, D. M. Prett und M. Morari. „Model Predictive Control: Theory and Practice — A Survey“. In: *Automatica* 25.3 (1989), S. 335–348. doi: 10.1016/0005-1098(89)90002-2.
- [AH15] K. Al-Ghamdi und G. Hussain. „The Pillowing Tendency of Materials in Single-Point Incremental Forming: Experimental and Finite Element Analyses“. In: *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture* 229.5 (2015), S. 744–753. doi: 10.1177/0954405414530906.
- [Gro15] P. Groche, S. Calmano, T. Felber und S. Schmitt. „Statistical Analysis of a Model based Product Property Control for Sheet Bending“. In: *Production Engineering* 9.1 (2015), S. 25–34. doi: 10.1007/s11740-014-0576-5.
- [Gro02] P. Groche, R. Huber, J. Doerr und D. Schmoeckel. „Hydromechanical Deep-Drawing of Aluminium-Alloys at Elevated Temperatures“. In: *CIRP Annals* 51.1 (2002), S. 215–218. doi: 10.1016/S0007-8506(07)61502-9.
- [Gro10] P. Groche, M. Scheitza, M. Kraft und S. Schmitt. „Increased Total Flexibility by 3D Servo Presses“. In: *CIRP Annals* 59.1 (2010), S. 267–270. doi: 10.1016/j.cirp.2010.03.013.
- [GBH08] P. Groche, P. Beiter und M. Henkelmann. „Prediction and Inline Compensation of Springback in Roll Forming of High and Ultra-High Strength Steels“. In: *Production Engineering* 2.4 (2008), S. 401–407. doi: 10.1007/s11740-008-0131-3.

- 
- [Gro07] P. Groche, D. Fritsche, E. Tekkaya, J. Allwood, G. Hirt und R. Neugebauer. „Incremental Bulk Metal Forming“. In: *CIRP Annals* 56.2 (2007), S. 635–656. doi: 10.1016/j.cirp.2007.10.006.
- [Gro16] P. Groche, F. Hoppe, D. Hesse und S. Calmano. „Blanking-Bending Process Chain with Disturbance Feed-Forward and Closed-Loop Control“. In: *Journal of Manufacturing Processes* 24 (2016), S. 62–70. doi: 10.1016/j.jmapro.2016.07.005.
- [GHS17] P. Groche, F. Hoppe und J. Sinz. „Stiffness of Multipoint Servo Presses: Mechanics vs. Control“. In: *CIRP Annals* 66.1 (2017), S. 373–376. doi: 10.1016/j.cirp.2017.04.053.
- [Gro18] P. Groche, P. Kramer, N. Bay, P. Christiansen, L. Dubar, K. Hayakawa, C. Hu, K. Kitamura und P. Moreau. „Friction Coefficients in Cold Forging: A Global Perspective“. In: *CIRP Annals* 67.1 (2018), S. 261–264. doi: 10.1016/j.cirp.2018.04.106.
- [GSG20] P. Groche, J. Sinz und T. Germann. „Efficient Validation of Novel Machine Elements for Capital Goods“. In: *CIRP Annals* 69.1 (2020), S. 125–128. doi: 10.1016/j.cirp.2020.03.004.
- [GRO08] K. GROßMANN, H. Wiemer, A. Hardtmann und L. Penter. „The Advanced Forming Process Model including the Elastic Effects of the Forming Press and Tool“. In: *Archives of Civil and Mechanical Engineering* 8.3 (2008), S. 41–54. doi: 10.1016/S1644-9665(12)60162-9.
- [Gun19] D. Gunning, M. Stefik, J. Choi, T. Miller, S. Stumpf und G.-Z. Yang. „XAI—Explainable Artificial Intelligence“. In: *Science Robotics* 4.37 (2019), eaay7120. doi: 10.1126/scirobotics.aay7120.
- [Gur77] A. L. Gurson. „Continuum Theory of Ductile Rupture by Void Nucleation and Growth: Part I—Yield Criteria and Flow Rules for Porous Ductile Media“. In: *Journal of Engineering Materials and Technology* 99.1 (1977), S. 2–15. doi: 10.1115/1.3443401.
- [GPP15] P. Gurusamy, S. B. Prabu und R. Paskaramoorthy. „Influence of Processing Temperatures on Mechanical Properties and Microstructure of Squeeze Cast Aluminum Alloy Composites“. In: *Materials and Manufacturing Processes* 30.3 (2015), S. 367–373. doi: 10.1080/10426914.2014.973587.
- [Haa18a] T. Haarnoja, A. Zhou, P. Abbeel und S. Levine. „Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor“. In: *International Conference on Machine Learning*. PMLR, 2018, S. 1861–1870. doi: 10.48550/arXiv.1801.01290.

- 
- [Haa18b] T. Haarnoja u. a. „Soft Actor-Critic Algorithms and Applications“. In: *arXiv PrePrint* (2018). DOI: 10.48550/arXiv.1812.05905.
- [HSW20] M. Hallmann, B. Schleich und S. Wartzack. „From Tolerance Allocation to Tolerance-Cost Optimization: A Comprehensive Literature Review“. In: *The International Journal of Advanced Manufacturing Technology* 107.11-12 (2020), S. 4859–4912. DOI: 10.1007/s00170-020-05254-5.
- [HZH16] X. Han, X. Zhang und L. Hua. „Calculation Method for Rocking Die Motion Track in Cold Orbital Forging“. In: *Journal of Manufacturing Science and Engineering* 138.1 (2016), S. 014501. DOI: 10.1115/1.4030855.
- [Han21] B. Hansen, P. Wagner, S. Purr und M. Merklein. „Investigations of Batch Fluctuation regarding Tribological Conditions in Series Production of Car Body Parts“. In: *International Journal of Material Forming* (2021), S. 1–14. DOI: 10.1007/s12289-020-01600-w.
- [HD11a] W. Hao und S. Duncan. „Constrained Model Predictive Control of an Incremental Sheet Forming Process“. In: *2011 IEEE International Conference on Control Applications (CCA)*. IEEE. 2011, S. 1288–1293. DOI: 10.1109/CCA.2011.6044466.
- [HD11b] W. Hao und S. Duncan. „Optimization of Tool Trajectory for Incremental Sheet Forming Using Closed Loop Control“. In: *2011 IEEE International Conference on Automation Science and Engineering*. IEEE. 2011, S. 779–784. DOI: 10.1109/CASE.2011.6042410.
- [Har20] C. R. Harris u. a. „Array Programming with NumPy“. In: *Nature* 585.7825 (2020), S. 357–362. DOI: 10.1038/s41586-020-2649-2.
- [HS18] V. L. Hattalli und S. R. Srivatsa. „Sheet Metal Forming Processes - Recent Technological Advances“. In: *Materials Today: Proceedings* 5.1 (2018), S. 2564–2574. DOI: 10.1016/j.matpr.2017.11.040.
- [Hav18] J. Havinga, T. v. d. Boogaard, F. Dallinger und P. Hora. „Feedforward Control of Sheet Bending based on Force Measurements“. In: *Journal of Manufacturing Processes* 31 (2018), S. 260–272. DOI: 10.1016/j.jmapro.2017.10.011.
- [HV17] J. Havinga und T. Van Den Boogaard. „Estimating Product-to-Product Variations in Metal Forming Using Force Measurements“. In: *AIP Conference Proceedings*. Bd. 1896. 1. AIP Publishing LLC. 2017, S. 070002. DOI: 10.1063/1.5008077.

- 
- [Hei18] J. Heingärtner, D. Bonfanti, D. Harsch, F. Dietrich und P. Hora. „Implementation of a Tribology-based Process Control System for Deep Drawing Processes“. In: *IOP Conference Series: Materials Science and Engineering*. Bd. 418. 1. IOP Publishing. 2018, S. 012112. doi: 10.1088/1757-899X/418/1/012112.
- [HLS09] C. Held, M. Liewald und M. Sindel. „Untersuchungen zum Einfluss werkstofflicher Schwankungen innerhalb eines Coils auf die Umformbarkeit“. In: *WT Werkstattstechnik Online* 99 (2009), S. 732–739.
- [HSK16] M. Herrmann, C. Schenck und B. Kuhfuss. „Dry Rotary Swaging with Structured Tools“. In: *Procedia CIRP* 40 (2016), S. 653–658. doi: 10.1016/j.procir.2016.01.150.
- [HHG17] D. Hesse, F. Hoppe und P. Groche. „Controlling Product Stiffness by an Incremental Sheet Metal Forming Process“. In: *Procedia Manufacturing* 10 (2017), S. 276–285. doi: 10.1016/j.promfg.2017.07.058.
- [Hes07] J. Hesselbach, B. Behrens, F. Dietrich, S. Rathmann und J. Poelmeyer. „Flexible Forming with Hexapods“. In: *Production Engineering* 1.4 (2007), S. 429–436. doi: 10.1007/s11740-007-0063-3.
- [Hir04] G. Hirt, J. Ames, M. Bambach und R. Kopp. „Forming Strategies and Process Modelling for CNC Incremental Sheet Forming“. In: *CIRP Annals* 53.1 (2004), S. 203–206. doi: 10.1016/S0007-8506(07)60679-9.
- [Hom23] W. Homberg u. a. „Softsensors: Key Component of Property Control in Forming Technology“. In: *Production Engineering* (2023). doi: 10.1007/s11740-023-01227-1.
- [Hop21] F. Hoppe. *Modellbasierte Regelung der Stößelbewegung von Servopressen*. Shaker, 2021.
- [Hop18] F. Hoppe, M. Knoll, B. Götz, M. Schaeffner und P. Groche. „Reducing Uncertainty in Shunt Damping by Model-Predictive Product Stiffness Control in a Single Point Incremental Forming Process“. In: *Applied Mechanics and Materials* 885 (2018), S. 35–47. doi: 10.4028/www.scientific.net/AMM.885.35.
- [HPG19] F. Hoppe, C. Pihan und P. Groche. „Closed-Loop Control of Eccentric Presses based on Inverse Kinematic Models“. In: *Procedia Manufacturing* 29 (2019), S. 240–247. doi: 10.1016/j.promfg.2019.02.132.

- 
- [Hor11] P. Hora, J. Heingärtner, N. Manopulo, L. Tong, D. Hortig, A. Neumann und K. Roll. „On the Way from an Ideal Virtual Process to the Modelling of the Real Stochastic“. In: *Forming Technology Forum 2011, Proceedings*. 2011.
- [HYI12] T. Horiuchi, S. Yoshihara und Y. Iriyama. „Dry Deep Drawability of A5052 Aluminum Alloy Sheet with DLC-Coating“. In: *Wear* 286 (2012), S. 79–83. doi: 10.1016/j.wear.2011.07.005.
- [HSV12] Z. Hu, A. Schubnov und F. Vollertsen. „Tribological Behaviour of DLC-Films and their Application in Micro Deep Drawing“. In: *Journal of Materials Processing Technology* 212.3 (2012), S. 647–652. doi: 10.1016/j.jmatprotec.2011.10.012.
- [Hua22] L. Hua, M. Chen, X. Han, X. Zhang, F. Zheng und W. Zhuang. „Research on the Vibration Model and Vibration Performance of Cold Orbital Forging Machines“. In: *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture* 236.6-7 (2022), S. 828–843. doi: 10.1177/095444054211045011.
- [Hua21] X. Hua, G. Wang, J. Xu und K. Chen. „Reinforcement Learning-based Collision-Free Path Planner for Redundant Robot in Narrow Duct“. In: *Journal of Intelligent Manufacturing* 32 (2021), S. 471–482. doi: 10.1007/s10845-020-01582-1.
- [Hub19] S. Huber, H. Wiemer, D. Schneider und S. Ihlenfeldt. „DMME: Data Mining Methodology for Engineering Applications - A Holistic Extension to the CRISP-DM Model“. In: *Procedia CIRP* 79 (2019), S. 403–408. doi: 10.1016/j.procir.2019.02.106.
- [IDD00] M. Inamdar, P. Date und U. Desai. „Studies on the Prediction of Springback in Air Vee Bending of Metallic Sheets Using an Artificial Neural Network“. In: *Journal of Materials Processing Technology* 108.1 (2000), S. 45–54. doi: 10.1016/S0924-0136(00)00588-4.
- [Ise05] R. Isermann. *Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*. Springer Science & Business Media, 2005. doi: 10.1007/3-540-30368-5.
- [Ism19] H. Ismail Fawaz, G. Forestier, J. Weber, L. Idoumghar und P.-A. Muller. „Deep Learning for Time Series Classification: A Review“. In: *Data mining and knowledge discovery* 33.4 (2019), S. 917–963. doi: 10.1007/s10618-019-00619-1.
- [JE00] M. Jahazi und B. Egbali. „The Influence of Hot Rolling Parameters on the Microstructure and Mechanical Properties of an Ultra-High Strength Steel“. In: *Journal of Materials Processing Technology* 103.2 (2000), S. 276–279. doi: 10.1016/S0924-0136(00)00474-X.

- 
- [Jan19] B. Jang, M. Kim, G. Harerimana und J. W. Kim. „Q-Learning Algorithms: A Comprehensive Classification and Applications“. In: *IEEE access* 7 (2019), S. 133653–133667. DOI: 10.1109/ACCESS.2019.2941229.
- [JA99] M. Jarrah und O. M. Al-Jarrah. „Position Control of a Robot Manipulator Using Continuous Gain Scheduling“. In: *Proceedings 1999 IEEE International Conference on Robotics and Automation (Cat. No. 99CH36288C)*. Bd. 1. IEEE. 1999, S. 170–175. DOI: 10.1109/ROBOT.1999.769957.
- [Jes05] J. Jeswiet, F. Micari, G. Hirt, A. Bramley, J. Duflou und J. Allwood. „Asymmetric Single Point Incremental Forming of Sheet Metal“. In: *CIRP Annals* 54.2 (2005), S. 88–114. DOI: 10.1016/S0007-8506(07)60021-3.
- [KGS09] P. Kadlec, B. Gabrys und S. Strandt. „Data-Driven Soft Sensors in the Process Industry“. In: *Computers & Chemical Engineering* 33.4 (2009), S. 795–814. DOI: 10.1016/j.compchemeng.2008.12.012.
- [Kar21] G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang und L. Yang. „Physics-Informed Machine Learning“. In: *Nature Reviews Physics* 3.6 (2021), S. 422–440. DOI: 10.1038/s42254-021-00314-5.
- [Ker23] L. Kersting, B. Arian, J. Roza Vasquez, A. Trächtler, W. Homberg und F. Walther. „Echtzeitfähige Modellierung eines innovativen Drückwalzprozesses für die eigenschaftsgeregelte Bauteilfertigung“. In: *at-Automatisierungstechnik* 71.1 (2023), S. 68–81. DOI: 10.1515/auto-2022-0106.
- [Ker22] L. Kersting, B. Arian, J. R. Vasquez, A. Trächtler, W. Homberg und F. Walther. „Innovative Online Measurement and Modelling Approach for Property-Controlled Flow Forming Processes“. In: *Key Engineering Materials*. Bd. 926. Trans Tech Publ. 2022, S. 862–874. DOI: 10.4028/p-yp2hj3.
- [Ker16] P. Kersting u. a. „Experimental and Numerical Analysis of Tribological Effective Surfaces for Forming Tools in Sheet-Bulk Metal Forming“. In: *Production Engineering* 10 (2016), S. 37–50. DOI: 10.1007/s11740-015-0651-6.
- [KK12] M. E. Khan und F. Khan. „A Comparative Study of White Box, Black Box and Grey Box Testing Techniques“. In: *International Journal of Advanced Computer Science and Applications* 3.6 (2012). DOI: 10.14569/IJACSA.2012.030603.

- 
- [KB14] D. P. Kingma und J. Ba. „Adam: A Method for Stochastic Optimization“. In: *arXiv preprint* (2014). doi: 10.48550/arXiv.1412.6980.
- [KW13] D. P. Kingma und M. Welling. „Auto-Encoding Variational Bayes“. In: *arXiv PrePrint* (2013). doi: 10.48550/arXiv.1312.6114.
- [Kir21] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj und D. J. Inman. „1D Convolutional Neural Networks and Applications: A Survey“. In: *Mechanical systems and signal processing* 151 (2021), S. 107398. doi: 10.1016/j.ymsp.2020.107398.
- [Kir18] S. Kiranyaz, A. Gastli, L. Ben-Brahim, N. Al-Emadi und M. Gabbouj. „Real-Time Fault Detection and Identification for MMC Using 1-D Convolutional Neural Networks“. In: *IEEE Transactions on Industrial Electronics* 66.11 (2018), S. 8760–8771. doi: 10.1109/TIE.2018.2833045.
- [Klo21] D. Kloeser, J. Martschin, T. Meurer und E. Tekkaya. „Reduced Order Modelling for Spatial-Temporal Temperature and Property Estimation in a Multi-Stage Hot Sheet Metal Forming Process“. In: *Advances in Industrial and Manufacturing Engineering* 3 (2021), S. 100055. doi: 10.1016/j.aime.2021.100055.
- [Kno20] M. Knoll, F. Mühl, P. Groche und V. Schulze. „Simulative Basic Investigation for a New Forming Process Punch-Hole-Rolling“. In: *Procedia Manufacturing* 50 (2020), S. 503–509. doi: 10.1016/j.promfg.2020.08.091.
- [KBP13] J. Kober, J. A. Bagnell und J. Peters. „Reinforcement Learning in Robotics: A Survey“. In: *The International Journal of Robotics Research* 32.11 (2013), S. 1238–1274. doi: 10.1177/0278364913495721.
- [KJ97] R. Kohavi und G. H. John. „Wrappers for feature subset selection“. In: *Artificial intelligence* 97.1-2 (1997), S. 273–324. doi: 10.1016/S0004-3702(97)00043-X.
- [Kot22] M. Kott. *Methodik zur Entwicklung eines Bedienerassistenzsystems für das Presswerk*. Shaker Verlag, 2022.
- [Kot20] M. Kott, C. Erz, J. Heingärtner und P. Groche. „Controllability of Temperature Induced Friction Effects during Deep Drawing of Car Body Parts with High Drawing Depths in Series Production“. In: *Procedia Manufacturing* 47 (2020), S. 553–560. doi: 10.1016/j.promfg.2020.04.166.

- 
- [Kri21] S. Kriechenbauer, P. Müller, R. Mauermann und W.-G. Drossel. „Evolutionary Optimization of Deep-Drawing Processes on Servo Screw Presses with Freely Programmable Force and Motion Functions“. In: *Procedia CIRP* 104 (2021), S. 1482–1487. doi: 10.1016/j.procir.2021.11.250.
- [KSH17] A. Krizhevsky, I. Sutskever und G. E. Hinton. „Imagenet Classification with Deep Convolutional Neural Networks“. In: *Communications of the ACM* 60.6 (2017), S. 84–90. doi: 10.1145/3065386.
- [Kro08] T. Kroiss, R. Völkl, U. Engel und M. Geiger. „Modeling of Process-Tool-Machine Interactions in Cold Forging“. In: *Proc. 1st Int. Conf. on PMI, Hannover, Germany*. 2008, S. 125–132.
- [Krü20] J. Krüger, J. Fleischer, J. Franke und P. Groche. *KI in der Produktion - Künstliche Intelligenz erschließen für Unternehmen*. [https://wgp.de/wp-content/uploads/20191107-WGP-Standpunkt\\_KI.pdf](https://wgp.de/wp-content/uploads/20191107-WGP-Standpunkt_KI.pdf). zul. geprüft am 31.08.2023. 2020.
- [Krü17] J. Krüger, L. Wang, A. Verl, T. Bauernhansl, E. Carpanzano, S. Makris, J. Fleischer, G. Reinhart, J. Franke und S. Pellegrinelli. „Innovative Control of Assembly Systems and Lines“. In: *CIRP Annals* 66.2 (2017), S. 707–730. doi: 10.1016/j.cirp.2017.05.010.
- [KHG21] C. Kubik, J. Hohmann und P. Groche. „Exploitation of Force Displacement Curves in Blanking — Feature Engineering Beyond Defect Detection“. In: *The International Journal of Advanced Manufacturing Technology* 113 (2021), S. 261–278. doi: 10.1007/s00170-020-06450-z.
- [KOM11] K. Kubota, T. Ohba und S. Morito. „Frictional Properties of New Developed Cold Work Tool Steel for High Tensile Strength Steel Forming Die“. In: *Wear* 271.11-12 (2011), S. 2884–2889. doi: 10.1016/j.wear.2011.06.007.
- [KL51] S. Kullback und R. A. Leibler. „On Information and Sufficiency“. In: *The Annals of Mathematical Statistics* 22.1 (1951), S. 79–86.
- [Kum21] V. Kumar, D. Hoeller, B. Sundaralingam, J. Tremblay und S. Birchfield. „Joint Space Control via Deep Reinforcement Learning“. In: *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE. 2021, S. 3619–3626. doi: 10.1109/IROS51168.2021.9636477.
- [Kur21] R. Kurth, M. Bergmann, R. Tehel, M. Dix und M. Putz. „Cognitive Clamping Geometries for Monitoring Elastic Deformation in Forming Machines and Processes“. In: *CIRP Annals* 70.1 (2021), S. 235–238. doi: 10.1016/j.cirp.2021.04.001.

- 
- [Laf21] R. Lafarge, S. Hütter, M. Tulke, T. Halle und A. Brosius. „Data based Model Predictive Control for Ring Rolling“. In: *Production Engineering* 15.6 (2021), S. 821–831. doi: 10.1007/s11740-021-01063-1.
- [Lan85] K. Lange. „Handbook of Metal Forming“. In: *McGraw-Hill Book Company, 1985*, (1985), S. 1216.
- [LBH15] Y. LeCun, Y. Bengio und G. Hinton. „Deep Learning“. In: *nature* 521.7553 (2015), S. 436–444. doi: 10.1038/nature14539.
- [Li23b] C. Li, P. Zheng, Y. Yin, B. Wang und L. Wang. „Deep Reinforcement Learning in Smart Manufacturing: A Review and Prospects“. In: *CIRP Journal of Manufacturing Science and Technology* 40 (2023), S. 75–101. doi: 10.1016/j.cirpj.2022.11.003.
- [Li10] H. Li, X. Dong, Y. Shen, A. Diehl, H. Hagenah, U. Engel und M. Merklein. „Size Effect on Springback Behavior due to Plastic Strain Gradient Hardening in Microbending Process of Pure Aluminum Foils“. In: *Materials Science and Engineering: A* 527.16-17 (2010), S. 4497–4504. doi: 10.1016/j.msea.2010.03.105.
- [LA00] H. Li und S. Azarm. „Product Design Selection under Uncertainty and with Competitive Advantage“. In: *Journal of Mechanical Design* 122.4 (2000), S. 411–418. doi: 10.1115/1.1311788.
- [Li22] T.-C. Li, C.-C. Kuo, C.-Y. Yang, K.-W. Liu, P.-H. Li und B.-T. Lin. „Influence of Motion Curve Errors of Direct-Drive Servo Press on Stamping Properties“. In: *The International Journal of Advanced Manufacturing Technology* 120.7-8 (2022), S. 4461–4476. doi: 10.1007/s00170-022-09014-5.
- [LLD21] X. Li, H. Liu und M. Dong. „A General Framework of Motion Planning for Redundant Robot Manipulator based on Deep Reinforcement Learning“. In: *IEEE Transactions on Industrial Informatics* 18.8 (2021), S. 5253–5263. doi: 10.1109/TII.2021.3125447.
- [Lie77] A. Liegeois. „Automatic Supervisory Control of the Configuration and Behavior of Multibody Mechanisms“. In: *IEEE Transactions on Systems, Man, and Cybernetics* 7.12 (1977), S. 868–871. doi: 10.1109/SMC.1977.4309644.
- [Lil16] L. Liliana. „A New Model of Ishikawa Diagram for Quality Assessment“. In: *IOP Conference Series: Materials Science and Engineering*. Bd. 161. 1. IOP Publishing, 2016, S. 012099. doi: 10.1088/1757-899X/161/1/012099.
- [Lil15] T. P. Lillicrap, J. J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, D. Silver und D. Wierstra. „Continuous Control with Deep Reinforcement Learning“. In: *arXiv PrePrint* (2015). doi: 10.48550/arXiv.1509.02971.

- 
- [Lin91] J. Lin. „Divergence Measures based on the Shannon Entropy“. In: *IEEE Transactions on Information theory* 37.1 (1991), S. 145–151. DOI: 10.1109/18.61115.
- [Liu21] S. Liu, Y. Xia, Z. Shi, H. Yu, Z. Li und J. Lin. „Deep Learning in Sheet Metal Bending with a Novel Theory-Guided Deep Neural Network“. In: *IEEE/CAA Journal of Automatica Sinica* 8.3 (2021), S. 565–581. DOI: 10.1109/JAS.2021.1003871.
- [Liu07] W. Liu, Q. Liu, F. Ruan, Z. Liang und H. Qiu. „Springback Prediction for Sheet Metal Forming based on GA-ANN Technology“. In: *Journal of Materials Processing Technology* 187 (2007), S. 227–231. DOI: 10.1016/j.jmatprotec.2006.11.087.
- [Löf16] M. Löffler u. a. „Tribological Measures for Controlling Material Flow in Sheet-Bulk Metal Forming“. In: *Production Engineering* 10 (2016), S. 459–470. DOI: 10.1007/s11740-016-0695-2.
- [Lu13] B. Lu, J. Chen, H. Ou und J. Cao. „Feature-based Tool Path Generation Approach for Incremental Sheet Forming Process“. In: *Journal of Materials Processing Technology* 213.7 (2013), S. 1221–1233. DOI: 10.1016/j.jmatprotec.2013.01.023.
- [Lu16] H. Lu, M. Kearney, Y. Li, S. Liu, W. J. Daniel und P. A. Meehan. „Model Predictive Control of Incremental Sheet Forming for Geometric Accuracy Improvement“. In: *The International Journal of Advanced Manufacturing Technology* 82 (2016), S. 1781–1794. DOI: 10.1007/s00170-015-7431-5.
- [Lu17] H. Lu, M. Kearney, S. Liu, W. J. Daniel und P. A. Meehan. „Two-Directional Toolpath Correction in Single-Point Incremental Forming Using Model Predictive Control“. In: *The International Journal of Advanced Manufacturing Technology* 91 (2017), S. 91–106. DOI: 10.1007/s00170-016-9672-3.
- [Lun16] J. Lunze. *Regelungstechnik* 2. Bd. 9. Springer, 2016. DOI: 10.1007/978-3-662-52676-7.
- [MW21] J. Ma und T. Welo. „Analytical Springback Assessment in Flexible Stretch Bending of Complex Shapes“. In: *International Journal of Machine Tools and Manufacture* 160 (2021), S. 103653. DOI: 10.1016/j.ijmactools.2020.103653.
- [MK85] A. A. Maciejewski und C. A. Klein. „Obstacle Avoidance for Kinetically Redundant Manipulators in Dynamically Varying Environments“. In: *The International Journal of Robotics Research* 4.3 (1985), S. 109–117. DOI: 10.1177/027836498500400308.

- 
- [MY10] C. M. Mak und Y. Yun. „A Study of Power Transmissibility for the Vibration Isolation of Coherent Vibratory Machines on the Floor of a Building“. In: *Applied Acoustics* 71.4 (2010), S. 368–372. doi: 10.1016/j.apacoust.2009.09.006.
- [MRL21] A. Maldonado-Ramirez, R. Rios-Cabrera und I. Lopez-Juarez. „A Visual Path-Following Learning Approach for Industrial Robots using DRL“. In: *Robotics and Computer-Integrated Manufacturing* 71 (2021), S. 102130. doi: 10.1016/j.rcim.2021.102130.
- [MYY98] K. s. Manabe, M. Yang und S. Yoshihara. „Artificial Intelligence Identification of Process Parameters and Adaptive Control System for Deep-Drawing Process“. In: *Journal of Materials Processing Technology* 80 (1998), S. 421–426. doi: 10.1016/S0924-0136(98)00121-6.
- [MK67] Z. Marciniak und K. Kuczyński. „Limit Strains in the Processes of Stretch-Forming Sheet Metal“. In: *International journal of mechanical sciences* 9.9 (1967), S. 609–620. doi: 10.1016/0020-7403(67)90066-5.
- [Mar08] P. Martins, N. Bay, M. Skjødt und M. Silva. „Theory of Single Point Incremental Forming“. In: *CIRP Annals* 57.1 (2008), S. 247–252. doi: 10.1016/j.cirp.2008.03.047.
- [Mat23] M. -. Matlab. *Reinforcement Learning Toolbox - Design and train policies using reinforcement learning*. <https://de.mathworks.com/products/reinforcement-learning.html>. Online; zuletzt geprüft am 15. Juli 2023. 2023.
- [Mat22] M. -. Matlab. *Simulink PLC Coder - Erzeugung von strukturiertem Text und Kontaktplänen nach IEC 61131-3 für SPSen*. <https://de.mathworks.com/products/simulink-plc-coder.html>. Online; zuletzt geprüft am 13. Mai 2023. 2022.
- [Mat16] S. Matthias, A. Loderer, S. Koch, M. Gröne, M. Kästner, S. Hübner, R. Krimm, E. Reithmeier, T. Hausotte und B. Behrens. „Metrological Solutions for an Adapted Inspection of Parts and Rools of a Sheet-Bulk Metal Forming Process“. In: *Production Engineering* 10.1 (2016), S. 51–61. doi: 10.1007/s11740-015-0647-2.
- [May00] D. Q. Mayne, J. B. Rawlings, C. V. Rao und P. O. Scokaert. „Constrained Model Predictive Control: Stability and Optimality“. In: *Automatica* 36.6 (2000), S. 789–814. doi: 10.1016/S0005-1098(99)00214-9.
- [May12] J. Mayr u. a. „Thermal Issues in Machine Tools“. In: *CIRP Annals* 61.2 (2012), S. 771–791. doi: 10.1016/j.cirp.2012.05.008.

- 
- [MLG06] M. Merklein, J. Lechler und M. Geiger. „Characterisation of the Flow Properties of the Quenchenable Ultra High Strength Steel 22MnB5“. In: *CIRP Annals* 55.1 (2006), S. 229–232. DOI: 10.1016/S0007-8506(07)60404-1.
- [Meu17] A. Meurer u. a. „SymPy: symbolic computing in Python“. In: *PeerJ Computer Science* 3 (Jan. 2017), e103. DOI: 10.7717/peerj-cs.103.
- [Mia13] E.-M. Miao, Y.-Y. Gong, P.-C. Niu, C.-Z. Ji und H.-D. Chen. „Robustness of Thermal Error Compensation Modeling Models of CNC Machine Tools“. In: *The International Journal of Advanced Manufacturing Technology* 69 (2013), S. 2593–2603. DOI: 10.1007/s00170-013-5229-x.
- [MAF07] F. Micari, G. Ambrogio und L. Filice. „Shape and Dimensional Accuracy in Single Point Incremental Forming: State of the Art and Future Trends“. In: *Journal of Materials Processing Technology* 191.1-3 (2007), S. 390–395. DOI: 10.1016/j.jmatprotec.2007.03.066.
- [Möh20] H.-C. Möhring, P. Wiederkehr, K. Erkorkmaz und Y. Kakinuma. „Self-Optimizing Machining Systems“. In: *CIRP Annals* 69.2 (2020), S. 740–763. DOI: 10.1016/j.cirp.2020.05.007.
- [MMM13] K.-I. Mori, T. Maeno und K. Mongkolkaji. „Tailored Die Quenching of Steel Parts Having Strength Distribution Using Bypass Resistance Heating in Hot Stamping“. In: *Journal of Materials Processing Technology* 213.3 (2013), S. 508–514. DOI: 10.1016/j.jmatprotec.2012.10.005.
- [Mor17] K.-i. Mori, P. Bariani, B. Behrens, A. Brosius, S. Bruschi, T. Maeno, M. Merklein und J. Yanagimoto. „Hot Stamping of Ultra-High Strength Steel Parts“. In: *CIRP Annals* 66.2 (2017), S. 755–777. DOI: 10.1016/j.cirp.2017.05.007.
- [Mor18] E. Morse, J.-Y. Dantan, N. Anwer, R. Söderberg, G. Moroni, A. Qureshi, X. Jiang und L. Mathieu. „Tolerancing: Managing Uncertainty from Conceptual Design to Final Product“. In: *CIRP Annals* 67.2 (2018), S. 695–717. DOI: 10.1016/j.cirp.2018.05.009.
- [Moz22] M. Mozaffar, S. Liao, X. Xie, S. Saha, C. Park, J. Cao, W. K. Liu und Z. Gan. „Mechanistic Artificial Intelligence (Mechanistic-AI) for Modeling, Design, and Control of Advanced Manufacturing Processes: Current State and Perspectives“. In: *Journal of Materials Processing Technology* 302 (2022), S. 117485. DOI: 10.1016/j.jmatprotec.2021.117485.

- 
- [Müh21] F. Mühl, M. Knoll, M. Khabou, S. Dietrich, P. Groche und V. Schulze. „Soft Sensor Approach based on Magnetic Barkhausen Noise by Means of the Forming Process Punch-Hole-Rolling“. In: *Advances in Industrial and Manufacturing Engineering 2* (2021), S. 100039. doi: 10.1016/j.aime.2021.100039.
- [NH86] Y. Nakamura und H. Hanafusa. „Inverse Kinematic Solutions with Singularity Robustness for Robot Manipulator Control“. In: *Journal of Dynamic Systems* 108.3 (1986), S. 163–171. doi: 10.1115/1.3143764.
- [Neu06a] R. Neugebauer, T. Altan, M. Geiger, M. Kleiner und A. Sterzing. „Sheet Metal Forming at Elevated Temperatures“. In: *CIRP Annals* 55.2 (2006), S. 793–816. doi: 10.1016/j.cirp.2006.10.008.
- [NDW07] R. Neugebauer, B. Denkena und K. Wegener. „Mechatronic Systems for Machine Tools“. In: *CIRP Annals* 56.2 (2007), S. 657–686. doi: 10.1016/j.cirp.2007.10.007.
- [Neu06b] R. Neugebauer, M. Hoffmann, H.-J. Roscher, S. Scheffler und K. Wolf. „Control of Sheet-Metal Forming Processes with Piezoactuators in Smart Structures“. In: *Smart Structures and Materials 2006: Industrial and Commercial Applications of Smart Structures Technologies*. Bd. 6171. SPIE. 2006, S. 116–124. doi: 10.1117/12.657387.
- [NAR20] D. Nicolis, F. Allevi und P. Rocco. „Operational Space Model Predictive Sliding Mode Control for Redundant Manipulators“. In: *IEEE Transactions on Robotics* 36.4 (2020), S. 1348–1355. doi: 10.1109/TRO.2020.2974092.
- [Ohl11] M. Ohlrich. „Predicting Transmission of Structure-Borne Sound Power from Machines by Including Terminal Cross-Coupling“. In: *Journal of Sound and Vibration* 330.21 (2011), S. 5058–5076. doi: 10.1016/j.jsv.2011.05.014.
- [Osa11] K. Osakada, K. Mori, T. Altan und P. Groche. „Mechanical Servo Press Technology for Metal Forming“. In: *CIRP Annals* 60.2 (2011), S. 651–672. doi: 10.1016/j.cirp.2011.05.007.
- [PD12] Z. Pandilov und V. Dukovski. „Parallel Kinematics Machine Tools: Overview - from History to the Future“. In: *Annals of the Faculty of Engineering Hunedoara* 10.2 (2012), S. 111.
- [PP02] L. Papeleux und J.-P. Ponthot. „Finite Element Simulation of Spring-back in Sheet Metal Forming“. In: *Journal of Materials Processing Technology* 125 (2002), S. 785–791. doi: 10.1016/S0924-0136(02)00393-X.

- 
- [Par19] G. I. Parisi, R. Kemker, J. L. Part, C. Kanan und S. Wermter. „Continual Lifelong Learning with Neural Networks: A Review“. In: *Neural networks* 113 (2019), S. 54–71. DOI: 10.1016/j.neunet.2019.01.012.
- [Pas17] A. Paszke, S. Gross, S. Chintala, G. Chanan, E. Yang, Z. DeVito, Z. Lin, A. Desmaison, L. Antiga und A. Lerer. „Automatic Differentiation in Pytorch“. In: (2017).
- [PHP12] L. Pelcastre, J. Hardell und B. Prakash. „Influence of Tool Steel Surface Topography on Galling during Hot Forming of Al-Si Coated Ultra High-Strength Steels“. In: *Nordic Symposium on Tribology: 12/06/2012-15/06/2012*. Department of Geography, Norwegian University of Science und Technology. 2012.
- [Pel21a] P. F. Pelz, P. Groche, M. E. Pfetsch und M. Schaeffner. *Mastering Uncertainty in Mechanical Engineering*. Springer Nature, 2021. DOI: 10.1007/978-3-030-78354-9.
- [Pel21b] P. F. Pelz, M. E. Pfetsch, S. Kersting, M. Kohler, A. Matei, T. Melz, R. Platz, M. Schaeffner und S. Ulbrich. „Types of Uncertainty“. In: *Mastering Uncertainty in Mechanical Engineering*. Springer International Publishing Cham, 2021, S. 25–42. DOI: 10.1007/978-3-030-78354-9\_2.
- [Pel21c] P. F. Pelz u. a. „Our Specific Approach on Mastering Uncertainty“. In: *Mastering Uncertainty in Mechanical Engineering* (2021), S. 43–111. DOI: 10.1007/978-3-030-78354-9\_3.
- [PYL21] A. Perrusquía, W. Yu und X. Li. „Multi-Agent Reinforcement Learning for Redundant Robot Control in Task-Space“. In: *International Journal of Machine Learning and Cybernetics* 12 (2021), S. 231–241. DOI: 10.1007/s13042-020-01167-7.
- [PS06] J. Peters und S. Schaal. „Policy Gradient Methods for Robotics“. In: *2006 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE. 2006, S. 2219–2225. DOI: 10.1109/IROS.2006.282564.
- [PAD14] J. A. Polyblank, J. Allwood und S. R. Duncan. „Closed-Loop Control of Product Properties in Metal Forming: A Review and Prospectus“. In: *Journal of Materials Processing Technology* 214.11 (2014), S. 2333–2348. DOI: 10.1016/j.jmatprotec.2014.04.014.
- [Pri00] G. Pritschow. „Parallel Kinematic Machines (PKM) - Limitations and New Solutions“. In: *CIRP Annals* 49.1 (2000), S. 275–280. DOI: 10.1016/S0007-8506(07)62945-X.

- 
- [QB03] S. J. Qin und T. A. Badgwell. „A Survey of Industrial Model Predictive Control Technology“. In: *Control engineering practice* 11.7 (2003), S. 733–764. DOI: 10.1016/S0967-0661(02)00186-7.
- [Rad19] A. Radford, J. Wu, R. Child, D. Luan, D. Amodei und I. Sutskever. „Language Models are Unsupervised Multitask Learners“. In: *OpenAI blog* 1.8 (2019), S. 9.
- [Raf21] A. Raffin, A. Hill, A. Gleave, A. Kanervisto, M. Ernestus und N. Dormann. „Stable-Baselines3: Reliable Reinforcement Learning Implementations“. In: *The Journal of Machine Learning Research* 22.1 (2021), S. 12348–12355.
- [RX06] K. Rao und C. Xie. „A Comparative Study on the Performance of Boric Acid with Several Conventional Lubricants in Metal Forming Processes“. In: *Tribology International* 39.7 (2006), S. 663–668. DOI: 10.1016/j.triboint.2005.05.004.
- [Rau09] M. Rauch, J.-Y. Hascoet, J.-C. Hamann und Y. Plenel. „Tool Path Programming Optimization for Incremental Sheet Forming Applications“. In: *Computer-Aided Design* 41.12 (2009), S. 877–885. DOI: 10.1016/j.cad.2009.06.006.
- [Rei21] N. Reinisch, F. Rudolph, S. Günther, D. Bailly und G. Hirt. „Successful Pass Schedule Design in Open-Die Forging Using Double Deep Q-Learning“. In: *Processes* 9.7 (2021), S. 1084. DOI: 10.3390/pr9071084.
- [Roi13] D. M. Roijers, P. Vamplew, S. Whiteson und R. Dazeley. „A Survey of Multi-Objective Sequential Decision-Making“. In: *Journal of Artificial Intelligence Research* 48 (2013), S. 67–113. DOI: 10.1613/jair.3987.
- [RHB23] M. Ryser, P. Hora und M. Bambach. „Algorithmic Determination of Measurement Locations for Surface Point Markers in Sheet Metal Forming and Application in Inverse Modelling - A Numerical and Experimental Study“. In: *Journal of Materials Processing Technology* 312 (2023), S. 117848. DOI: 10.1016/j.jmatprotec.2022.117848.
- [Sam13] G. Samolyk. „Investigation of the Cold Orbital Forging Process of an AlMgSi Alloy Bevel Gear“. In: *Journal of Materials Processing Technology* 213.10 (2013), S. 1692–1702. DOI: 10.1016/j.jmatprotec.2013.03.027.
- [Sch10] M. Scheitzka. *Konzeption eines flexiblen 3D-Servo-Pressensystems und repräsentative Basisanwendungen*. Shaker, 2010.

- 
- [Sch22] A. Schenek, M. Görz, M. Liewald und K. R. Riedmüller. „Data-Driven Derivation of Sheet Metal Properties Gained from Punching Forces Using an Artificial Neural Network“. In: *Key Engineering Materials*. Bd. 926. Trans Tech Publ. 2022, S. 2174–2182. doi: 10.4028/p-41602a.
- [Sch15] J. Schulman, S. Levine, P. Abbeel, M. Jordan und P. Moritz. „Trust Region Policy Optimization“. In: *International Conference on Machine Learning*. PMLR. 2015, S. 1889–1897. doi: 10.48550/arXiv.1502.05477.
- [Sch17] J. Schulman, F. Wolski, P. Dhariwal, A. Radford und O. Klimov. „Proximal Policy Optimization Algorithms“. In: *arXiv preprint arXiv:1707.06347* (2017). doi: 10.48550/arXiv.1707.06347.
- [Sch08] H. Schwenke, W. Knapp, H. Haitjema, A. Weckenmann, R. Schmitt und F. Delbressine. „Geometric Error Measurement and Compensation of Machines — An Update“. In: *CIRP Annals* 57.2 (2008), S. 660–675. doi: 10.1016/j.cirp.2008.09.008.
- [Sch21] M. Schwenzer, M. Ay, T. Bergs und D. Abel. „Review on Model Predictive Control: An Engineering Perspective“. In: *The International Journal of Advanced Manufacturing Technology* 117.5-6 (2021), S. 1327–1349. doi: 10.1007/s00170-021-07682-3.
- [She18] J. Shen, Y. Qu, W. Zhang und Y. Yu. „Wasserstein Distance Guided Representation Learning for Domain Adaptation“. In: *Proceedings of the AAAI Conference on Artificial Intelligence*. Bd. 32. 1. 2018. doi: 10.1609/aaai.v32i1.11784.
- [She22] Y. Shen, Q. Jia, Z. Huang, R. Wang, J. Fei und G. Chen. „Reinforcement Learning-based Reactive Obstacle Avoidance Method for Redundant Manipulators“. In: *Entropy* 24.2 (2022), S. 279. doi: 10.3390/e24020279.
- [Sic90] B. Siciliano. „Kinematic Control of Redundant Robot Manipulators: A Tutorial“. In: *Journal of intelligent and robotic systems* 3 (1990), S. 201–212. doi: 10.1007/BF00126069.
- [SS94] K. Siegert und D. Schmoeckel. „Compensation of Tilting and Horizontal Displacement of Upper Die, Relative to the Lower Die, at out-of-Center Forming Load by a Closed-Loop Control System“. In: *CIRP Annals* 43.1 (1994), S. 267–270. doi: 10.1016/S0007-8506(07)62210-0.
- [SGB21] E. Simonetto, A. Ghiotti und S. Bruschi. „In-Process Measurement of Springback in Tube Rotary Draw Bending“. In: *The International Journal of Advanced Manufacturing Technology* 112 (2021), S. 2485–2496. doi: 10.1007/s00170-020-06453-w.

- 
- [SMB19] R. D. Singh, A. Mittal und R. K. Bhatia. „3D Convolutional Neural Network for Object Recognition: a Review“. In: *Multimedia Tools and Applications* 78 (2019), S. 15951–15995. DOI: 10.1007/s11042-018-6912-6.
- [SKG19] J. Sinz, M. Knoll und P. Groche. „Operational Effects on the Stiffness of Combined Roller and Plain Bearings“. In: *Procedia Manufacturing* 41 (2019), S. 650–657. DOI: 10.1016/j.promfg.2019.09.054.
- [SS97] J. Sola und J. Sevilla. „Importance of Input Data Normalization for the Application of Neural Networks to Complex Industrial Problems“. In: *IEEE Transactions on Nuclear Science* 44.3 (1997), S. 1464–1468. DOI: 10.1109/23.589532.
- [SP87] Y. K. Son und C. S. Park. „Economic Measure of Productivity, Quality and Flexibility in Advanced Manufacturing Systems“. In: *Journal of Manufacturing Systems* 6.3 (1987), S. 193–207. DOI: 10.1016/0278-6125(87)90018-5.
- [Sri03] V. Srinivasan. „An Integrated View of Geometrical Product Specification and Verification“. In: *Geometric Product Specification and Verification: Integration of Functionality: Selected Conference Papers of the 7th CIRP International Seminar on Computer-Aided Tolerancing, held at the École Normale Supérieure de Cachan, France, 24–25 April 2001*. Springer. 2003, S. 1–11. DOI: 10.1007/978-94-017-1691-8\_1.
- [Sri07] V. Srinivasan. „Computational Metrology for the Design and Manufacture of Product Geometry: A Classification and Synthesis“. In: *Journal of Computing and Information Science in Engineering* 7.1 (2007), S. 3–9. DOI: 10.1115/1.2424246.
- [Ste17] P. Stein, W. Franke, F. Hoppe, D. Hesse, K. Mill und P. Groche. „Control of Anisotropic Shape Deviation in Single Point Incremental Forming of Paperboard“. In: *AIP Conference Proceedings*. 2017, S. 080007. DOI: 10.1063/1.5008087.
- [SM15] J. Steiner und M. Merklein. „Investigation of Influencing Parameters for Tribological Conditions in Dry Forming Processes“. In: *Acta Metallurgica Sinica (English Letters)* 28 (2015), S. 1435–1441. DOI: 10.1007/s40195-015-0343-4.
- [SMG12] M. A. Stephens, C. Manzie und M. C. Good. „Model Predictive Control for Reference Tracking on an Industrial Machine Tool Servo Drive“. In: *IEEE Transactions on Industrial Informatics* 9.2 (2012), S. 808–816. DOI: 10.1109/TII.2012.2223222.
- [Sto16] D. D. Stoerkle, P. Seim, L. Thyssen und B. Kuhlenkoetter. „Machine Learning in Incremental Sheet Forming“. In: *Proceedings of ISR 2016: 47th International Symposium on Robotics*. VDE. 2016, S. 1–7.

- 
- [SR75] S. Stören und J. Rice. „Localized Necking in Thin Sheets“. In: *Journal of the Mechanics and Physics of Solids* 23.6 (1975), S. 421–441. DOI: LocalizedNeckinginThinSheets.
- [SB18] R. S. Sutton und A. G. Barto. *Reinforcement Learning: An Introduction*. Second. The MIT Press, 2018.
- [Sze10] C. Szepesvári. *Algorithms for Reinforcement Learning*. Springer Cham, 2010. DOI: 10.1007/978-3-031-01551-9.
- [Tan22] X. Tang, B. Huang, T. Liu und X. Lin. „Highway Decision-Making and Motion Planning for Autonomous Driving via Soft Actor-Critic“. In: *IEEE Transactions on Vehicular Technology* 71.5 (2022), S. 4706–4717. DOI: 10.1109/TVT.2022.3151651.
- [Tao18] F. Tao, J. Cheng, Q. Qi, M. Zhang, H. Zhang und F. Sui. „Digital Twin-Driven Product Design, Manufacturing and Service with Big Data“. In: *The International Journal of Advanced Manufacturing Technology* 94 (2018), S. 3563–3576. DOI: 10.1007/s00170-017-0233-1.
- [TC18] T. Taylor und A. Clough. „Critical Review of Automotive Hot-Stamped Sheet Steel from an Industrial Perspective“. In: *Materials Science and Technology* 34.7 (2018), S. 809–861. DOI: 10.1080/02670836.2018.1425239.
- [TPB20] R. Tehel, T. Päßler und M. Bergmann. „Effective FE Models for Simulating the Elasto-Mechanical Characteristics of Forming Machines“. In: *The International Journal of Advanced Manufacturing Technology* 106.7-8 (2020), S. 3505–3514. DOI: 10.1007/s00170-019-04832-6.
- [Tek15] A. Tekkaya u. a. „Metal Forming beyond Shaping: Predicting and Setting Product Properties“. In: *CIRP Annals* 64.2 (2015), S. 629–653. DOI: 10.1016/j.cirp.2015.05.001.
- [Ten17] J. Tenner, K. Andreas, A. Radius und M. Merklein. „Numerical and Experimental Investigation of Dry Deep Drawing of Aluminum Alloys with Conventional and Coated Tool Surfaces“. In: *Procedia Engineering* 207 (2017), S. 2245–2250. DOI: 10.1016/j.proeng.2017.10.989.
- [Tet22] R. Teti, D. Mourtzis, D. D’Addona und A. Caggiano. „Process Monitoring of Machining“. In: *CIRP Annals* 71.2 (2022), S. 529–552. DOI: 10.1016/j.cirp.2022.05.009.
- [Thi21] S. Thiery, M. Zein El Abdine, J. Heger und N. Ben Khalifa. „Closed-Loop Control of Product Geometry by Using an Artificial Neural Network in Incremental Sheet Forming with Active Medium“. In: *International Journal of Material Forming* 14 (2021), S. 1319–1335. DOI: 10.1007/s12289-020-01598-1.

- 
- [Thu03] D. P. Thunnissen. „Uncertainty Classification for the Design and Development of Complex Systems“. In: *3rd Annual Predictive Methods Conference*. Bd. 16. Newport Beach CA. 2003.
- [TN84] V. Tvergaard und A. Needleman. „Analysis of the Cup-Cone Fracture in a Round Tensile Bar“. In: *Acta Metallurgica* 32.1 (1984), S. 157–169. DOI: 10.1016/0001-6160(84)90213-X.
- [Unt19] M. Unterberg, P. Niemiets, D. Trauth, K. Wehrle und T. Bergs. „In-Situ Material Classification in Sheet-Metal Blanking Using Deep Convolutional Neural Networks“. In: *Production Engineering* 13 (2019), S. 743–749. DOI: 10.1007/s11740-019-00928-w.
- [Vas17] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser und I. Polosukhin. „Attention is All You Need“. In: *Advances in Neural Information Processing Systems* 30 (2017). DOI: 10.48550/arXiv.1706.03762.
- [Vel22] D. Vela, A. Sharp, R. Zhang, T. Nguyen, A. Hoang und O. S. Pinykh. „Temporal Quality Degradation in AI Models“. In: *Scientific Reports* 12.1 (2022), S. 11654. DOI: 10.1038/s41598-022-15245-z.
- [Ver19] A. Verl, A. Valente, S. Melkote, C. Brecher, E. Ozturk und L. T. Tunc. „Robots in Machining“. In: *CIRP Annals* 68.2 (2019), S. 799–822. DOI: 10.1016/j.cirp.2019.05.009.
- [VKC03] V. Viswanathan, B. Kinsey und J. Cao. „Experimental Implementation of Neural Network Springback Control for Sheet Metal Forming“. In: *Journal of Engineering Materials and Technology* 125.2 (2003), S. 141–147. DOI: 10.1115/1.1555652.
- [Vol19] W. Volk, P. Groche, A. Brosius, A. Ghiotti, B. L. Kinsey, M. Liewald, L. Madej, J. Min und J. Yanagimoto. „Models and Modelling for Process Limits in Metal Forming“. In: *CIRP Annals* 68.2 (2019), S. 775–798. DOI: 10.1016/j.cirp.2019.05.007.
- [VK84] M. Vukobratovic und M. Kirčanski. „A Dynamic Approach to Nominal Trajectory Synthesis for Redundant Manipulators“. In: *IEEE Transactions on Systems, Man, and Cybernetics* 4 (1984), S. 580–586. DOI: 10.1109/TSMC.1984.6313329.
- [WSW14] M. Walter, M. Storch und S. Wartzack. „On Uncertainties in Simulations in Engineering Design: A Statistical Tolerance Analysis Application“. In: *Simulation* 90.5 (2014), S. 547–559. DOI: 10.1177/0037549714529834.
- [Wam86] C. W. Wampler. „Manipulator Inverse Kinematic Solutions based on Vector Formulations and Damped Least-Squares Methods“. In: *IEEE Transactions on Systems, Man, and Cybernetics* 16.1 (1986), S. 93–101. DOI: 10.1109/TSMC.1986.289285.

- 
- [WKA95] C.-T. Wang, G. Kinzel und T. Altan. „Failure and Wrinkling Criteria and Mathematical Modeling of Shrink and Stretch Flanging Operations in Sheet-Metal Forming“. In: *Journal of Materials Processing Technology* 53.3-4 (1995), S. 759–780. doi: 10.1016/0924-0136(94)01766-T.
- [WKA93] C. Wang, G. Kinzel und T. Altan. „Mathematical Modeling of Plane-Strain Bending of Sheet and Plate“. In: *Journal of Materials Processing Technology* 39.3-4 (1993), S. 279–304. doi: 10.1016/0924-0136(93)90164-2.
- [Wan08] J. Wang, S. Verma, R. Alexander und J.-T. Gau. „Springback Control of Sheet Metal Air Bending Process“. In: *Journal of Manufacturing Processes* 10.1 (2008), S. 21–27. doi: 10.1016/j.manpro.2007.09.001.
- [WD18] M. Wang und W. Deng. „Deep Visual Domain Adaptation: A Survey“. In: *Neurocomputing* 312 (2018), S. 135–153. doi: 10.1016/j.neucom.2018.05.083.
- [Wan19] Y. Wang, L. Li, N. W. Hartman und J. W. Sutherland. „Allocation of Assembly Tolerances to Minimize Costs“. In: *CIRP Annals* 68.1 (2019), S. 13–16. doi: 10.1016/j.cirp.2019.04.027.
- [WAN09] M. Wazed, S. Ahmed und Y. Nukman. „Uncertainty Factors in Real Manufacturing Environment“. In: *Australian Journal of Basic and Applied Sciences* 3.2 (2009), S. 342–351.
- [Wec95] M. Weck, P. McKeown, R. Bonse und U. Herbst. „Reduction and Compensation of Thermal Errors in Machine Tools“. In: *CIRP Annals* 44.2 (1995), S. 589–598. doi: 10.1016/S0007-8506(07)60506-X.
- [WS00] M. Weck und D. Staimer. „On the Accuracy of Parallel Kinematic Machine Tools: Design, Compensation and Calibration“. In: *2rd Chemnitz Parallel Kinematic Seminar, Chemnitz, Germany*. 2000, S. 73–84.
- [WS02] M. Weck und D. Staimer. „Parallel Kinematic Machine Tools - Current State and Future Potentials“. In: *CIRP Annals* 51.2 (2002), S. 671–683. doi: 10.1016/S0007-8506(07)61706-5.
- [Weg21] K. Wegener, F. Bleicher, U. Heisel, H.-W. Hoffmeister und H.-C. Moehring. „Noise and Vibrations in Machine Tools“. In: *CIRP Annals* 70.2 (2021), S. 611–633. doi: 10.1016/j.cirp.2021.05.010.
- [Weh18] M. Wehr, S. Stockert, D. Abel und G. Hirt. „Model Predictive Roll Gap Control in Cold Rolling with Piezoelectric Actuators“. In: *2018 IEEE Conference on Control Technology and Applications (CCTA)*. IEEE. 2018, S. 1377–1382. doi: 10.1109/CCTA.2018.8511333.

- 
- [Wei21] M. Weigold, H. Ranzau, S. Schaumann, T. Kohne, N. Panten und E. Abele. „Method for the Application of Deep Reinforcement Learning for Optimised Control of Industrial Energy Supply Systems by the Example of a Central Cooling System“. In: *CIRP Annals* 70.1 (2021), S. 17–20. doi: 10.1016/j.cirp.2021.03.021.
- [WXN94] C. Weimin, C. Xibin und G. Naiguang. „Analysis and Control of the Noise Produced by Presses during Stamping“. In: *Journal of Materials Processing Technology* 42.1 (1994), S. 87–94. doi: 10.1016/0924-0136(94)90077-9.
- [WKW16] K. Weiss, T. M. Khoshgoftaar und D. Wang. „A Survey of Transfer Learning“. In: *Journal of Big Data* 3.1 (2016), S. 1–40. doi: 10.1186/s40537-016-0043-6.
- [Whi69] D. E. Whitney. „Resolved Motion Rate Control of Manipulators and Human Prostheses“. In: *IEEE Transactions on Man-Machine Systems* 10.2 (1969), S. 47–53. doi: 10.1109/TMMS.1969.299896.
- [WH00] R. Wirth und J. Hipp. „CRISP-DM: Towards a Standard Process Model for Data Mining“. In: *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining*. Bd. 1. Manchester. 2000, S. 29–39.
- [Xie19] J. Xie, Z. Shao, Y. Li, Y. Guan und J. Tan. „Deep Reinforcement Learning with Optimized Reward Functions for Robotic Trajectory Planning“. In: *IEEE Access* 7 (2019), S. 105669–105679. doi: 10.1109/ACCESS.2019.2932257.
- [Yan18] D.-Y. Yang, M. Bambach, J. Cao, J. Duflou, P. Groche, T. Kuboki, A. Sterzing, A. E. Tekkaya und C. Lee. „Flexibility in Metal Forming“. In: *CIRP Annals* 67.2 (2018), S. 743–765. doi: 10.1016/j.cirp.2018.05.004.
- [YZD17] J. Yang, H.-T. Zhang und H. Ding. „Contouring Error Control of the Tool Center Point Function for Five-Axis Machine Tools based on Model Predictive Control“. In: *The International Journal of Advanced Manufacturing Technology* 88 (2017), S. 2909–2919. doi: 10.1007/s00170-016-8979-4.
- [Yin17] L. Ying, T. Gao, M. Dai und P. Hu. „Investigation of Interfacial Heat Transfer Mechanism for 7075-T6 Aluminum Alloy in HFQ Hot Forming Process“. In: *Applied Thermal Engineering* 118 (2017), S. 266–282. doi: 10.1016/j.applthermaleng.2017.02.107.
- [Yos85] T. Yoshikawa. „Manipulability of Robotic Mechanisms“. In: *The International Journal of Robotics Research* 4.2 (1985), S. 3–9. doi: 10.1177/027836498500400201.

- 
- [YGL22] R. Yuan, R. M. Gower und A. Lazaric. „A General Sample Complexity Analysis of Vanilla Policy Gradient“. In: *International Conference on Artificial Intelligence and Statistics*. PMLR. 2022, S. 3332–3380. doi: 10.48550/arXiv.2110.10117.
- [Zha21] J. Zhang, J. Kim, B. O’Donoghue und S. Boyd. „Sample Efficient Reinforcement Learning with REINFORCE“. In: *Proceedings of the AAAI Conference on Artificial Intelligence*. Bd. 35. 12. 2021, S. 10887–10895. doi: 10.1609/aaai.v35i12.17300.
- [Zha20] W. Zhao, J. P. Queralta, L. Qingqing und T. Westerlund. „Towards Closing the Sim-to-Real Gap in Collaborative Multi-Robot Deep Reinforcement Learning“. In: *2020 5th International Conference on Robotics and Automation Engineering (ICRAE)*. IEEE. 2020, S. 7–12. doi: 10.1109/ICRAE50850.2020.9310796.
- [ZQW20] W. Zhao, J. P. Queralta und T. Westerlund. „Sim-to-Real Transfer in Deep Reinforcement Learning for Robotics: A Survey“. In: *2020 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE. 2020, S. 737–744. doi: 10.1109/SSCI47803.2020.9308468.
- [Zhu23] Z. Zhu, K. Lin, A. K. Jain und J. Zhou. „Transfer Learning in Deep Reinforcement Learning: A Survey“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence (2023)*, S. 1–20. doi: 10.1109/TPAMI.2023.3292075.
- [ZBD10] B. D. Ziebart, J. A. Bagnell und A. K. Dey. „Modeling Interaction via the Principle of Maximum Causal Entropy“. In: *International Conference on Machine Learning*. 2010, S. 1255–1262.



## **A. Anhang**

## A.1. Kinematik und Kraftübersetzung des Prototypens der 3D-Servo-Presse

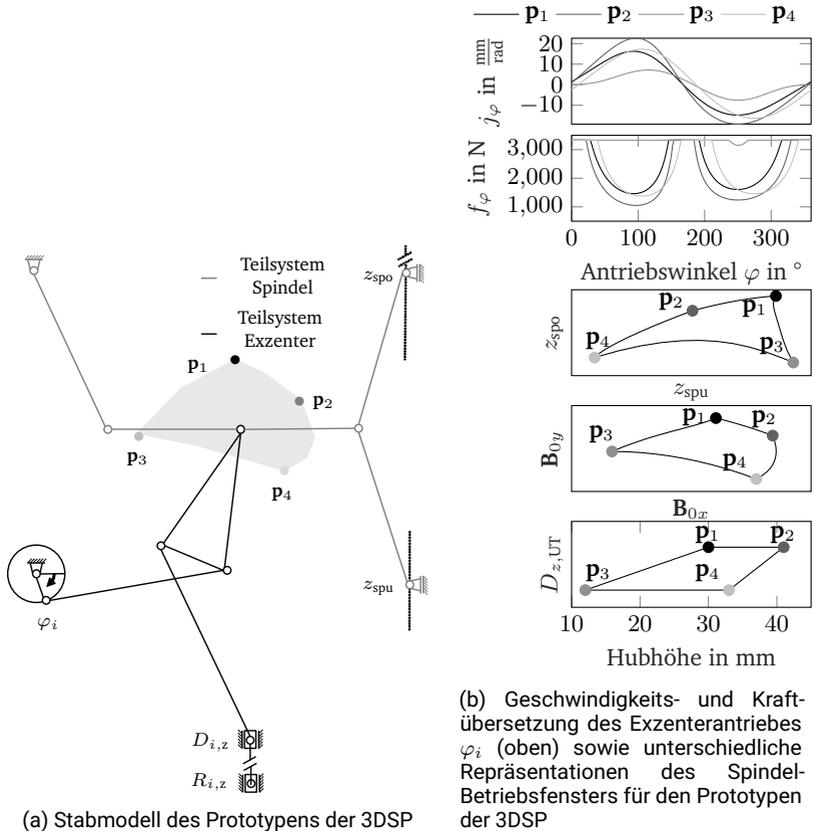


Abbildung A.1.: Kinematik und Kraftübersetzung des Prototypens der 3DSP

Im Vergleich zur Forschungsversion der 3DSP bietet der Prototyp lediglich moderate Presskräfte von 10 kN. Die kinematische Ausführung des Teilsystems Spindel (siehe Abbildung A.1) ist nach Erprobung des Prototypens aus Steifigkeitsgründen

---

modifiziert worden, um Biegebeanspruchungen aus dem Kniehebelgetriebe auf die Getriebebauteile des Teilsystems Spindel zu reduzieren. Die modifizierte Kinematik im Teilsystem Spindel führt auf unterschiedliche Spindel-Betriebsfenster und deren Transformationen in  $\mathbf{B}_0$  und Hubhöhen-Koordinaten. So ist in Abbildung A.1(b) ersichtlich, dass das Betriebsfenster bestehend aus UT  $D_{z,UT}$  und Hubhöhe nicht rechteckig, sondern ein konvexes Viereck darstellt. Die vier charakteristischen Eckpunkte des konvexen Vierecks  $\mathbf{p}_i$  begrenzen das Betriebsfenster. Dabei ist die Abhängigkeit der Geschwindigkeits- und Kraftübertragung von der eingestellten Hubhöhe erneut ersichtlich. Während  $\mathbf{p}_1$ ,  $\mathbf{p}_2$  und  $\mathbf{p}_4$  vergleichsweise hohe Hubhöhen von größer 30 mm und demzufolge hohe Geschwindigkeitsübersetzungen zwischen den Totpunkten bereitstellen, fällt die bereitgestellte Kraft  $f_{\varphi_i}$  zwischen den Totpunkten auf bis zu 1 kN pro Getriebe ab. Demgegenüber kann im Betriebspunkt  $\mathbf{p}_3$  über weite Teile des Antriebswinkels die maximale Presskraft pro Getriebe von  $f_{\varphi_i}^{\max} = 3.33$  kN bereitgestellt werden, wohingegen die Geschwindigkeitsübersetzung aufgrund geringer Hubhöhe erheblich niedriger als in den anderen eingezeichneten Betriebspunkten ist.

## A.2. Bestimmung der Antriebszeitkonstanten

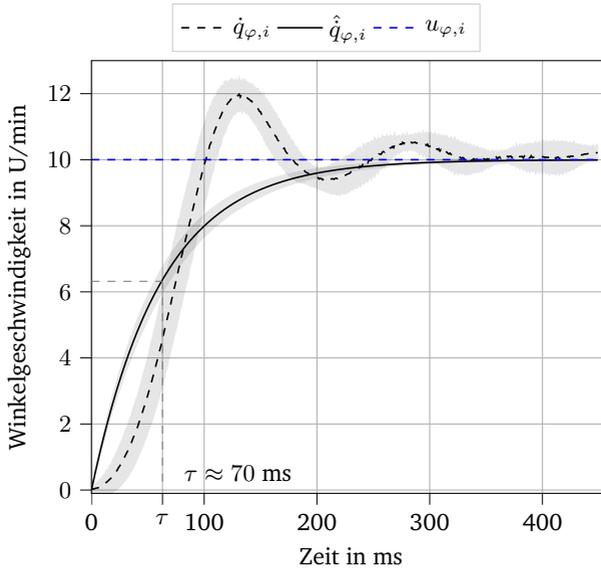


Abbildung A.2.: Sprungantworten der Exzenterantriebe zur Ermittlung der Zeitkonstanten  $\tau$  eines postulierten PT1-Übertragungsverhaltens basierend auf 15 Messungen (Mittelwerte und 95% Konfidenzintervalle für  $\dot{q}_{\varphi,i}$  und  $\hat{q}_{\varphi,i}$  dargestellt) [E12]

Zur Herleitung adaptiver Verstärkungsfaktoren für die Positionsregelung der 3DSP (siehe Kapitel 4.3) und für die simulativen Untersuchungen in Kapitel 6 ist eine Charakterisierung der Übertragungsverhalten der Antriebe notwendig. Dazu werden die exzentrischen Antriebe der 3DSP mit sprunghaften Geschwindigkeits-Sollgrößen  $u_{\varphi} = 10$  U/min beaufschlagt und die Sprungantworten  $\dot{q}_{\varphi}$  gemessen. Abbildung A.2 zeigt die Mittelwerte und 95% Konfidenzintervalle aus 15 Messungen an den drei unterschiedlichen Antriebseinheiten. Die Sprungantworten deuten aufgrund von Überschwingen und moderatem Gradienten zu Beginn der Sprungbeaufschlagung ( $\left. \frac{d\hat{q}_{\varphi,i}}{dt} \right|_{t=0} \approx 0$ ) auf ein PT2-Übertragungsverhalten hin, werden zum Zwecke der Reduktion von Modellkomplexität jedoch als PT1-Übertragungsverhalten angenommen. Die Schätzung entsprechender PT1-Sprungantworten  $\hat{q}_{\varphi}$  wird über einen

---

Least-Squares-Fit der Form

$$\min_{\tau} \sum_{t=1}^N \left( \underbrace{\dot{q}_{\varphi,i,t} - u_{\varphi,i} \cdot \left( 1 - \exp\left(\frac{-t}{\tau}\right)\right)}_{\hat{q}_{\varphi,i,t}} \right)^2 \quad (\text{A.1})$$

realisiert, was auf die in Abbildung A.2 dargestellte PT1-Sprungantwort führt. Grundlage des Fitting-Ansatzes sind die 15 durchgeführten Messungen mit einer Dauer von jeweils 450 ms und Abtastfrequenz von 1 kHz, woraus sich für  $N = 450$  ergibt. Aus der Sprungantwort lässt sich die Zeitkonstante an jenem Punkt ablesen, der 63,2% des Sprungeingangs ausmacht, was nach konservativer Schätzung auf  $\tau \approx 70$  ms führt.

---

### A.3. Weitere Messdaten aus geregelten Stauchprozessen bei außermittiger Kräfteinwirkung

Abbildung A.3 stellt Positionen der Stoßellager als auch Geschwindigkeitsstellgrößen sowie reale Geschwindigkeiten der Antriebe der 3DSP aus einem außermittigen Stauchversuch dar, der im Arbeitsraum geregelt wurde. Nach etwa 6 s kommt es zum Kontakt zwischen Stempel und Werkstück, woraufhin sich eine Regelabweichung für das am stärksten belastete Stoßellager  $R_{z,2}$  ergibt. Die Regelabweichung führt zu einer Erhöhung der Stellgröße für den entsprechenden Exzentermotor  $u_{\varphi,2}$  und führt dazu, dass die unterschiedlich hohen Regelabweichungen der Stoßellagerpositionen angeglichen werden. Während der Prozessdurchführung kommt es zu leichten Regelabweichungen, die in einem Schleppfehler begründet liegen. Ein interessanter Effekt kann zu Prozessende beobachtet werden ( $t \approx 18$  s). Der negative Kraftgradient, der in den Kraftverläufen aus Abbildung 4.6 zu beobachten ist, führt dazu, dass die Presseneinfederung abnimmt und es zu abrupt auftretenden Regelabweichungen der stark belasteten Stoßellager ( $R_{z,2}$  und  $R_{z,3}$ ) kommt. Die Regelung reagiert auf den Kraftabfall und damit einhergehende Regelabweichungen durch eine Erhöhung der Stellgrößen, wobei die Peaks der Stellgrößen mit der Kraftbelastung des jeweiligen Stoßellagers skalieren. Nach Beendigung des Prozesses verfährt der Stößel in die Ausgangsposition, weswegen es zu einer Vorzeichenumkehr der Geschwindigkeitsstellgrößen für die Exzenterantriebe kommt (Reversierbetrieb). Die Stellgrößen und realen Geschwindigkeiten der Spindeln sind in den beiden unteren Plots zu sehen. Die Spindeln regeln dabei die Totpunkte und verfahren demzufolge während der gesamten Prozessdauer. Da die Geschwindigkeiten der Spindeltriebe auf 200 mm/min begrenzt sind, das Regelgesetz jedoch höhere Stellgrößen für die untere Spindel ausgibt, kann die Ist-Geschwindigkeit der Stellgröße nicht über die gesamte Prozessdauer folgen.

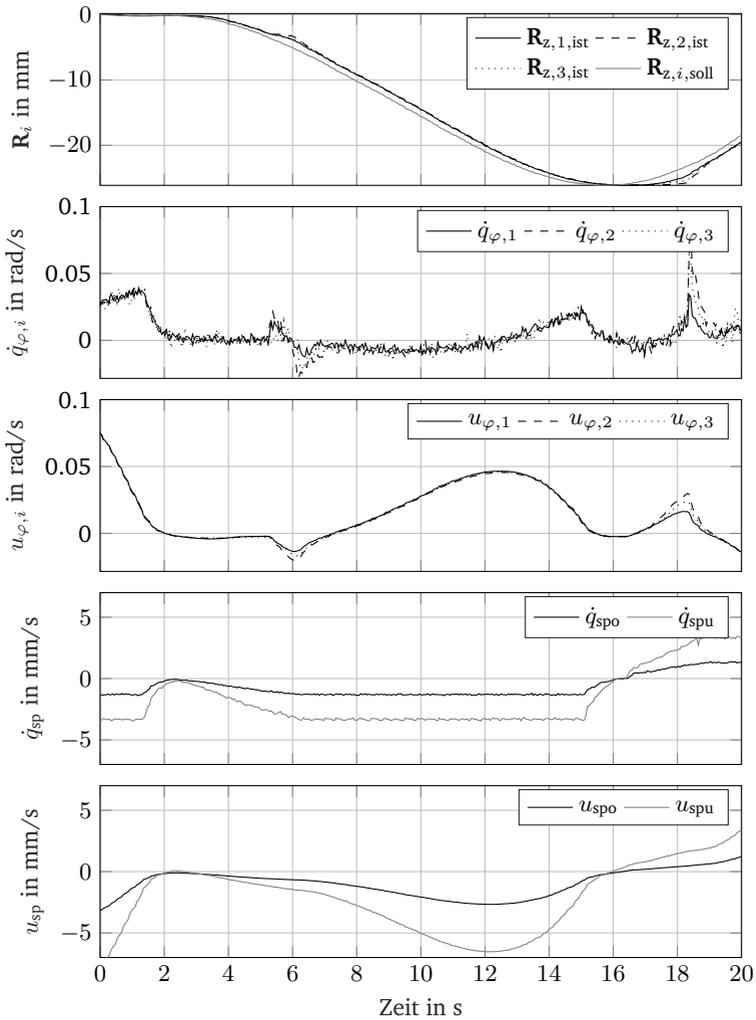


Abbildung A.3.: Soll- und Ist-Positionen der Stößellager  $R_{z,i}$  (oben) und dazugehörige Geschwindigkeitsstellgrößen  $u_i$  und Ist-Größen  $\dot{q}_i$  eines im Arbeitsraum geregelten Stauchprozesses bei außermittiger Krafteinwirkung (Werkzeugpositionierung gemäß Abbildung 4.5:  $b_1$ ) [E12]

## A.4. Simulativer Performanzvergleich der 3DSP-Positionsregelung mit konstanten und adaptiven Verstärkungsfaktoren

Abbildung A.4 gibt einen Überblick über die Performanzen der Regelungen mit konstantem und adaptivem Verstärkungsfaktor für eine oszillierende Sollwertvorgabe für Stoßeltranslation und -verkippungen. Insbesondere in den Regelabweichungen der Kippfreiheitsgrade wird ersichtlich, dass der adaptive Verstärkungsfaktor zu erheblich geringeren Regelabweichungen führt.

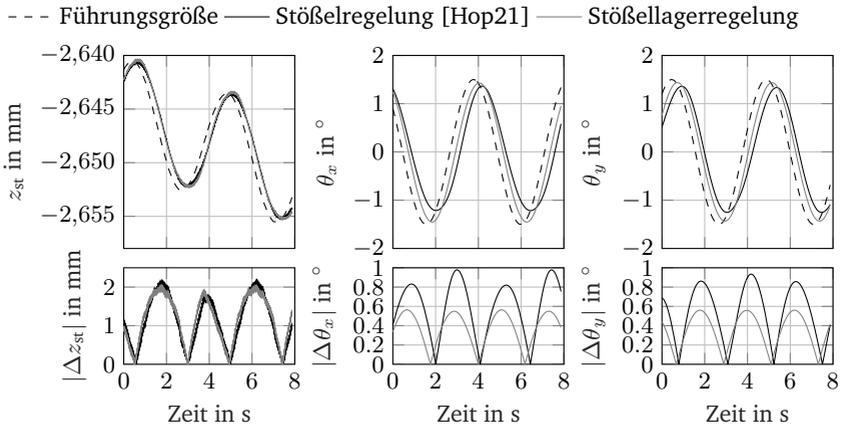


Abbildung A.4.: Simulatives Verhalten der Stoßelpose und deren Regelabweichung unter Nutzung der Stoßelposenregelung und adaptiven Stoßellagerregelung

## A.5. Performanzvergleich Positionsregelung am Beispiel einer Taumelschmiedebewegungsbahn

Die Regelgüte der in Tabelle 4.3 erfassten Regelgesetze wird ebenfalls durch ein experimentelles Abfahren eines dreidimensionalen Werkzeugpfades demonstriert. Als Grundlage wird eine spirale Bewegungsform des Stößels zur Realisierung eines Taumelschmiedeprozess herangezogen. Dabei wird innerhalb von 15 Sekunden ein translatorischer Weg in vertikale Richtung von 50 mm zurückgelegt und ein Auf- und Abschwingen beider Verkippfreiheitsgrade von 0° auf 2° und zurück auf 0° festgelegt. Für Erläuterungen und Berechnungen von Werkzeugpfaden beim Taumelschmieden sei auf [Sam13; HZH16] verwiesen.

Abbildung A.5 zeigt den Verlauf der Führungsgrößen und Regelgrößen aller drei Regelgesetze für die geregelten Stößelfreiheitsgrade. Dabei führt das adaptive Regelgesetz zu den geringsten Regelabweichungen und realisiert insbesondere hohe Stößelverkippen erheblich besser als die anderen beiden Regelgesetze. Dies steht im Einklang mit den simulativen Ergebnissen aus dem vorangegangenen Unterkapitel A.4. Die Dämpfung im robusten Regelgesetz führt dagegen dazu, dass hohe Verkippen signifikant schlechter eingeregelt werden als durch das ungedämpfte Regelgesetz. Dies ist dadurch zu erklären, dass mit einer erhöhten Verkippen mindestens eine Getriebeeinheit ihre Nähe zu den Totpunkten (und damit zur kinematischen Singularität) reduziert, wodurch der Einfluss der Dämpfung auf die Stellgrößengenerierung zunimmt.

Die Ausmaße der Schleppfehler der Kippfreiheitsgrade des Stößels sind in Abbildung A.6 ersichtlich. Die robuste Regelung unter Zuhilfenahme der inversen DLS-Jakobimatrix ruft eine maximale Stößelverkippen von etwas mehr als einem Grad hervor, wohingegen das adaptive Regelgesetz zu geringen Regelabweichungen führt und Stößelverkippen von bis zu 1.8° erreicht. Ein quantitativer Performanzvergleich der Regelgesetze ist Tabelle A.1 zu entnehmen und beinhaltet sowohl mittlere als auch maximale Regelabweichungen für die geregelten Stößelfreiheitsgrade.

Bezeichnung	$ \overline{\Delta z_{st}} $	$\max( \Delta z_{st} )$	$ \overline{\Delta \theta_x} $	$\max( \Delta \theta_x )$	$ \overline{\Delta \theta_y} $	$\max( \Delta \theta_y )$
Robust	0.83 mm	0.95 mm	0.62 °	1.56 °	0.62 °	1.55 °
Ungedämpft	0.83 mm	1.01 mm	0.44 °	1.09 °	0.44 °	1.09 °
Adaptiv	0.31 mm	0.44 mm	0.28 °	0.68 °	0.28 °	0.69 °

Tabelle A.1.: Mittlere ( $|\overline{\cdot}|$ ) und maximale Regelabweichung  $\max(|\cdot|)$  der geregelten Stößelfreiheitsgrade beim Taumelschmieden mit spiraler Bewegungsbahn [E9]

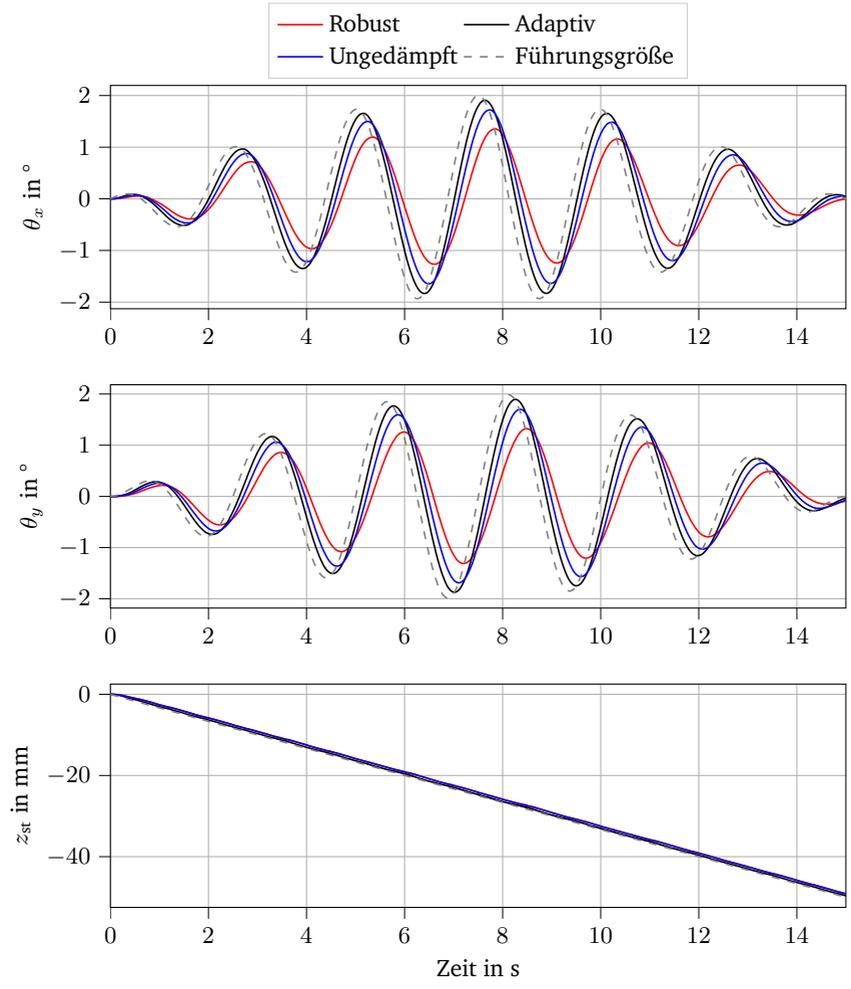


Abbildung A.5.: Zeitlicher Verlauf der Führungsgrößen der geregelten Stößelfreiheitsgrade und korrespondierende Regelgrößen für die in Tabelle 4.3 erfassten Regelgesetze [E9]

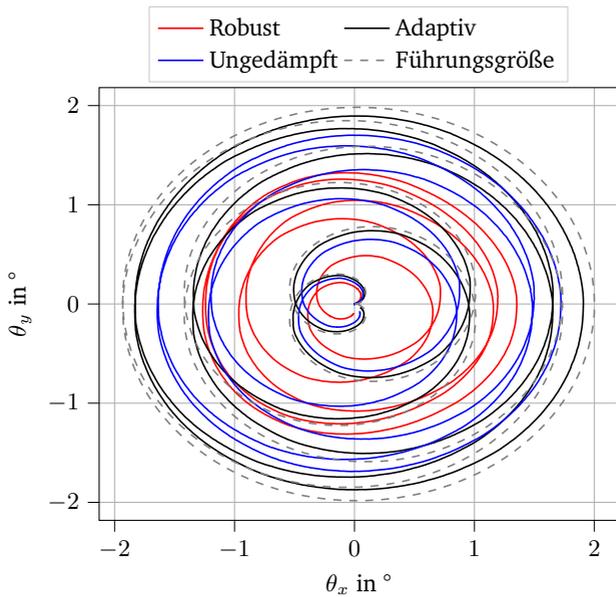


Abbildung A.6.: Führungsgrößen der Kippfreiheitsgrade des Stößels und korrespondierende Regelgrößen für die in Tabelle 4.3 erfassten Regelgesetze [E9]

---

## A.6. Optische Bauteilvermessung mittels Hexagon AB Absolute Arm

In Kapiteln 4.3.3 und 5.3 werden die Bauteilgeometrien aus inkrementellen Umformprozessen (Lochwalzen bzw. SPIF) über optische 3D-Messverfahren vermessen. Dabei kommt ein *Absolute Arm 8525-7* der Firma *Hexagon AB* zum Einsatz, der nach DIN EN ISO 10360-8 [DIN16] eine Scansystemgenauigkeit von  $47 \mu\text{m}$  aufweist. Der dazugehörige Absolute Scanner AS1 erfasst bis zu 1.2 Mio. Punkte pro Sekunde, verfügt über eine Laserlinienbreite von 150 mm und muss mit einer Entfernung von  $165 \pm 50 \text{ mm}$  vom Messobjekt betrieben werden.



Abbildung A.7.: Hexagon Absolute Arm 8525-7

---

## A.7. Bilder realer Bauteile aus dem Lochwalzprozess unter Anwendung unterschiedlicher Regelgesetze

Abbildung A.8 stellt die realen Bauteile mit einem großen Halbachsenradius von  $r_b$  dar, die durch die unterschiedlichen Regelgesetze gefertigt worden sind. Die Bilder korrespondieren zu den in Abbildung 4.15 unten rechts dargestellten Geometrien, die aus dem Ellipsen-Fitting hervorgehen.

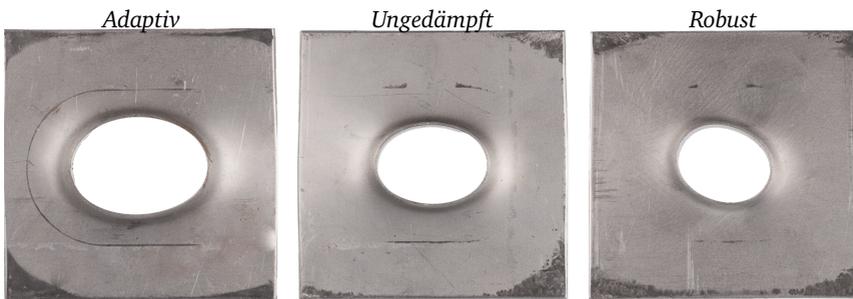


Abbildung A.8.: Vergleich der elliptischen Löcher der Lochwalzbauteile mit großem Halbachsenradius  $r_b = 20$  mm für die drei angewandten Regelgesetze [E9]

---

## A.8. Grundlagen des überwachten Lernens

Überwachte Lernalgorithmen können grundsätzlich in klassifizierende und regressive Ansätze unterteilt werden, die in gegebenen Trainingsdaten bestehend aus unabhängigen Eingangs- und abhängigen Ausgangsdaten Muster erkennen und Funktionen erlernen, die gegebene Eingangsdaten Ausgangsdaten zuordnen. Anspruch überwachter Lernetechniken ist es, funktionale Zusammenhänge zu identifizieren, deren Gültigkeit auch auf Datensätzen sichergestellt wird, die nicht zum Training des Modells herangezogen werden. Vielmehr bedarf es einer hohen Generalisierbarkeit erlangter Zusammenhänge, sodass Modellausgaben auch bei Einspeisung bislang unbekannter Eingangsdaten zu Ausgangsdaten führen, die dem wahren Wert entsprechen oder diesen mit möglichst geringen Abweichungen approximieren. Werden die Modelleingänge mit  $\mathbf{x}$  und Modellausgänge mit  $y$  bezeichnet, so gilt für regressive Algorithmen  $y_{\text{reg}} \in \mathbb{R}$  und für klassifizierende Algorithmen  $y_{\text{kla}} \in \mathcal{K}$ , wobei  $\mathcal{K}$  eine endliche Menge an vorab definierten Klassenobjekten darstellt. Eine holistische Vorstellung überwachter Lernetechniken ist an dieser Stelle weder zielführend noch möglich, weshalb in den folgenden Unterkapiteln die in der vorliegenden Arbeit angewandten Algorithmen adressiert werden. Die Untersuchungen in Kapitel 5 adressieren mit der Anwendung einer MLR, einem NN und einem CNN drei regressive Algorithmen, die im Folgenden näher vorgestellt werden.

### A.8.1. Multiple, lineare Regression

Die MLR ist der trivialste der genannten Algorithmen, da diese ausschließlich lineare Zusammenhänge residuenfrei erfassen kann. Die Schätzung der Ausgangsgröße erfolgt für  $m$  Eingangsgrößen über

$$\hat{y}(\mathbf{x}, \boldsymbol{\beta}) = \sum_{i=1}^m \beta_i \cdot x_i + \beta_0, \quad (\text{A.2})$$

wobei die  $m$  Regressionskoeffizienten  $\beta_i$  und die Regressionskonstante  $\beta_0$  über ein Minimierungsproblem der Kostenfunktion  $\mathcal{C}$

$$\min_{\beta_0, \beta_i} \mathcal{C}(\mathbf{x}, \boldsymbol{\beta}) = \min_{\beta_0, \beta_i} \sum_{j=1}^N (y_j - \hat{y}_j(\mathbf{x}, \boldsymbol{\beta}))^2 = \min_{\beta_0, \beta_i} \sum_{j=1}^N \left( y_j - \beta_0 + \sum_{i=1}^m \beta_i \cdot x_{ij} \right)^2 \quad (\text{A.3})$$

identifiziert werden. Dabei liegt der Optimierung ein Trainingsdatensatz mit  $N$  Datenpunkten bzw. Beobachtungen zugrunde, das nach dem Prinzip der kleinsten Fehlerquadrate optimiert wird. Die Findung optimaler Regressionsparameter erfolgt durch die Aufstellung partieller Ableitungen der Kostenfunktion nach allen

---

Parametern

$$\frac{\partial \mathcal{C}(\mathbf{x}, \boldsymbol{\beta})}{\beta_0} = \frac{\partial \mathcal{C}(\mathbf{x}, \boldsymbol{\beta})}{\beta_i} \stackrel{!}{=} 0, \quad (\text{A.4})$$

was auf ein konvexes und damit analytisch lösbares Optimierungsproblem führt, bei dem keine lokalen Minima oder Sattelpunkte vorliegen.

## A.8.2. Neuronale Netze

NN basieren auf einem ähnlichen Prinzip wie die MLR und optimieren eine Kostenfunktion meist auf dem Prinzip kleinster Fehlerquadrate. Dabei ergibt sich die Prädiktion eines NN ähnlich wie bei der MLR aus Gleichung A.2 zu

$$\hat{y}_j(\mathbf{x}, \mathbf{W}) = \sigma \left( \sum_{k=1}^M w_{jk}^{(2)} \cdot h \left( \sum_{i=1}^D w_{ki}^{(1)} \cdot x_i + w_{k0}^{(1)} \right) + w_{j0}^{(2)} \right) \quad (\text{A.5})$$

und ist abhängig von der Gewichtungsmatrix  $\mathbf{W}$  (mathematische Notation angelehnt an [Bis06]). Gleichung A.5 stellt die Prädiktion eines zweischichtigen NN dar, bei dem die Gewichtungen  $w_{kj}^{(2)}$  zur zweiten Schicht korrespondieren und  $j \in [1, M]$  die Anzahl der Eingangsgrößen und  $j \in [1, N]$  die Anzahl der Neuronen in der entsprechenden Schicht widerspiegeln. In der ersten Schicht ergeben sich die Aktivierungen gemäß

$$a_k = \sum_{i=1}^D w_{ki}^{(1)} \cdot x_i + w_{k0}^{(1)} \quad (\text{A.6})$$

als Linearkombinationen der  $D$  Eingangsgrößen  $x_i$  mit den Gewichtungen der ersten Schicht  $w_{ki}^{(1)}$  und den sogenannten Bias-Parametern  $w_{k0}^{(1)}$ , die als Äquivalent zu den Regressionskonstanten  $\beta_0$  bei der MLR angesehen werden können. Anschließend erfolgt eine Einspeisung der Ergebnisse der Linearkombination in eine nichtlineare Aktivierungsfunktion  $h(\cdot)$  gemäß

$$h(a_k) = h \left( \sum_{i=1}^D w_{ki}^{(1)} \cdot x_i + w_{k0}^{(1)} \right), \quad (\text{A.7})$$

was entscheidende Vorteile gegenüber der MLR birgt, da Nichtlinearitäten erheblich besser abgebildet werden können. Dabei stellen die Aktivierungsfunktionen einen Hyperparameter dar, den der Anwender entweder manuell wählen kann oder unter Anwendung von hyperparameteroptimierenden Algorithmen automatisiert festlegen kann. Abbildung A.9 stellt die gängigsten Vertreter nichtlinearer Aktivierungsfunktionen dar. Während Sigmoid- und Tangens-Hyperbolicus-Aktivierungsfunktionen oftmals in relativ kleinen Netztopologien mit geringen Anzahlen an Schichten zum Einsatz kommen, eignen sich Rectified Linear Unit (ReLU)-Aktivierungsfunktionen

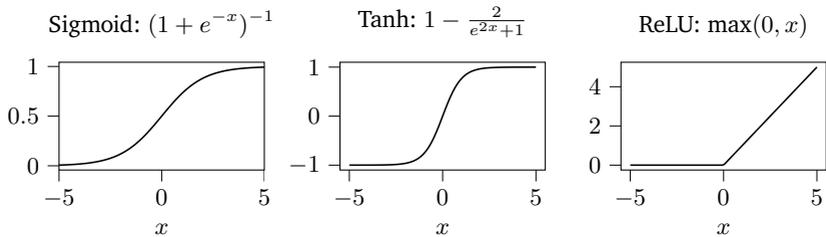


Abbildung A.9.: Gängige nichtlineare Aktivierungsfunktionen  $h(\cdot)$  bei der Anwendung neuronaler Netze

häufig zur Anwendung in tiefen Netzen bestehend aus einer Vielzahl an Neuronen und versteckten Schichten. Zuletzt werden die Ergebnisse der Linearkombinationen der zweiten (bzw. bei tieferen Netzen letzten) Schicht in eine Aktivierungsfunktion  $\sigma(\cdot)$  eingespeist, die bei Regressionsanwendungen oftmals linear gewählt wird. Ein entscheidender Unterschied zur MLR ist, dass die Kostenfunktion des NN

$$\min_{\mathbf{W}} \mathcal{C}(\mathbf{x}, \mathbf{W}) = \min_{\mathbf{W}} \sum_{j=1}^N (y_j - \hat{y}_j(\mathbf{x}, \mathbf{W}))^2 = \min_{\mathbf{W}} \sum_{j=1}^N \left( y_j - \sigma \left( \sum_{k=1}^M w_{jk}^{(2)} \cdot h \left( \sum_{i=1}^D w_{ki}^{(1)} \cdot x_i + w_{k0}^{(1)} \right) + w_{j0}^{(2)} \right) \right)^2 \quad (\text{A.8})$$

aufgrund induzierter Nichtlinearitäten nicht konvex ist und demzufolge ein nichtlineares Optimierungsproblem mit lokalen Minima und potenziellen Sattelpunkten vorliegt. Demzufolge ist die Anwendung nichtlinearer Optimierungsmethoden notwendig. Dazu wird die Kostenfunktion ähnlich wie bei der MLR in Formel A.4 nach den Gewichtungen des Netzes partiell abgeleitet und die Gewichtungen der Netze nach dem Konzept der Backpropagation mit

$$\Delta \mathbf{W} = -\eta \frac{\partial \mathcal{C}(\mathbf{x}, \mathbf{W})}{\partial \mathbf{W}} \quad (\text{A.9})$$

beaufschlagt, sodass für den  $m$ -ten Trainingsdurchlauf (Epoche)

$$\mathbf{W}_m = \mathbf{W}_{m-1} + \Delta \mathbf{W}_m \quad (\text{A.10})$$

gilt. Die Lernrate  $\eta$  ist dabei ebenfalls ein Hyperparameter, der optimiert oder manuell gewählt werden kann, jedoch von modernen Optimierungsalgorithmen wie ADAM [KB14] während des Trainings an das Lernverhalten des NN angepasst wird.

Abbildung A.10 vergleicht die Performanzen eines NN und einer LR. Ausgangspunkt

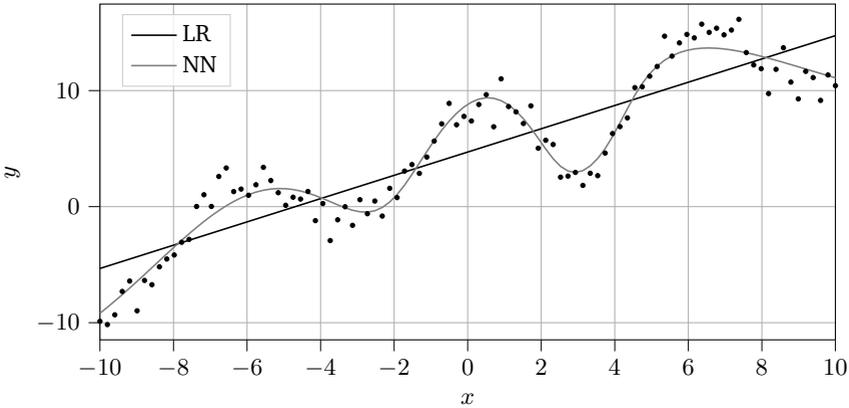


Abbildung A.10.: Leistungsvergleich eines NN und einer LR bei verrauschter, nichtlinearer Datengrundlage

beider Regressionen sind die als schwarze Kreise visualisierten Datenpunkte, die auf Basis der Funktion

$$y(x) = \underbrace{4 \cdot \cos(x)}_{\text{trigonometrischer Term}} + \underbrace{5 + x}_{\text{linearer Term}} + \underbrace{\epsilon}_{\text{Störterm}} \quad (\text{A.11})$$

bestimmt sind, wobei  $\epsilon \sim N(0, 1)$  einen standardnormalverteilten Störterm darstellt und  $x \in [-10, 10]$ . Damit bildet die Datengrundlage Unsicherheit in Form von Rauschen und Nichtlinearität in Form des trigonometrischen Terms ab. Das eingesetzte NN verfügt im vorgestellten Fall über zwei versteckte Schichten mit jeweils 30 Neuronen, nutzt Tangens-Hyperbolicus-Aktivierungsfunktionen und wird auf 80% der visualisierten Daten trainiert. Die LR erhält für Trainingszwecke alle visualisierten Datenpunkte. Evident ist, dass das NN die Periodizität der trigonometrischen Funktion erfasst und zu einer sinnvollen Approximation der Datengrundlage führt. Die LR kann aufgrund fehlender Freiheitsgrade lediglich eine lineare Approximation der Datengrundlage bereitstellen und lernt demzufolge lediglich den linearen Term aus Formel A.11, die Periodizität des trigonometrischen Terms ist nicht abbildbar. Demzufolge ist ein Einsatz von NN insbesondere bei stark nichtlinearen Datengrundlagen sinnvoll, da NN als universelle Funktionsapproximatoren beliebige Funktionen abbilden können.

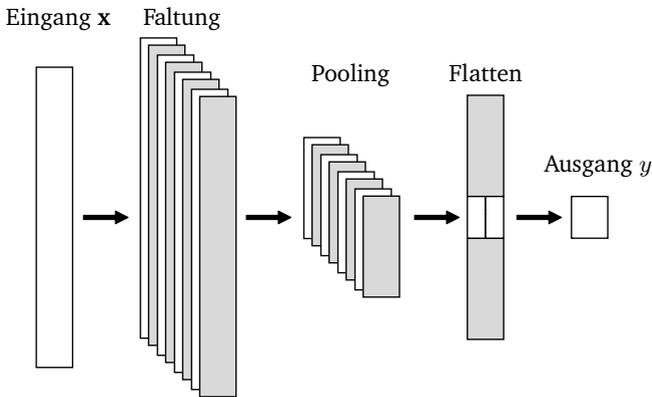


Abbildung A.11.: Aufbau eines 1D-CNN zur Verarbeitung von Zeitreihen

### A.8.3. Faltende, neuronale Netze

Einen Sonderfall eines neuronalen Netzes stellt das CNN dar. Der Durchbruch von CNN ist auf bildverarbeitende Anwendungen zurückzuführen [KSH17], die die Popularität der Algorithmen in den letzten Jahren rasant gefördert haben. CNN eignen sich insbesondere für hochdimensionale Daten und vereinen die Schritte der Datentransformation (Kennwertextraktion und -selektion) und Modellbildung. Charakteristisch für CNN sind meist alternierend angeordnete Faltungs- und Poolingschichten, die eine äußerst effiziente Dimensionalitätsreduktion der hochdimensionalen Eingangsdaten vornehmen. Mittlerweile werden CNN nicht mehr ausschließlich für bildverarbeitende Zwecke eingesetzt, sondern kommen ebenfalls in zeitreihengestützten Anwendungen [Kir21] oder auf Basis höherdimensionaler Datentypen [SMB19] zum Einsatz. Die Topologie eines zeitreihenverarbeitenden 1D-CNN ist Abbildung A.11 zu entnehmen. In der Faltungsschicht wird eine frei wählbare Anzahl an Kernels bzw. Filtern translatorisch über die Zeitreihe bewegt, welche über Gewichtungen verfügen und durch eine Faltung der Gewichtungen mit den Eingangsdaten unterschiedliche Kennwertkarten (engl.: Feature Maps) erzeugen. Abbildung A.12 visualisiert die vorwärtsgerichteten Informationsflüsse in den Faltungs- und Poolingschichten, anhand derer im Folgenden die mathematischen Operationen erklärt werden. Das  $k$ -te Neuron in der  $l$ -ten Schicht erhält als Eingang das Ergebnis der Faltung

$$f_k^{(l)} = b_k^{(l)} + \sum_{i=1}^{N_l-1} \text{Conv1D} \left( w_{ik}^{(l-1)}, s_i^{(l-1)} \right), \quad (\text{A.12})$$

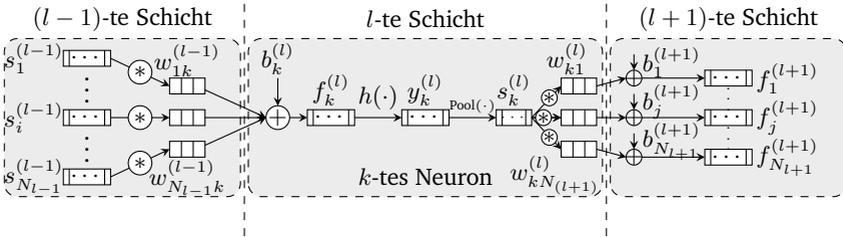


Abbildung A.12.: Funktionsweise kombinierter Faltungs- und Poolingschichten eines 1D-CNN in Anlehnung an [Kir18]

wobei  $b_k^{(l)}$  Bias-Parameter,  $w_{ik}^{(l-1)}$  die  $N_{l-1}$  Gewichtungen des Filters,  $s_i^{(l-1)}$  die  $N_{l-1}$  Ausgangsgrößen der vorgelagerten  $(l-1)$ -ten Schicht und  $\text{Conv1D}(\cdot)$  (in Abbildung A.12 als  $*$  dargestellt) einen Faltungsoperator darstellen. Im Neuron wird nun die nichtlineare Aktivierungsfunktion, oftmals ReLU (siehe Abbildung A.9), angewandt, was zu

$$y_k^{(l)} = h\left(f_k^{(l)}\right) \quad (\text{A.13})$$

führt. Jene Ausgaben  $y_k^{(l)}$  werden anschließend an die Poolingschicht übergeben und dort durch Max- oder Average-Pooling in der Dimensionalität reduziert, sodass

$$s_k^{(l)} = \text{Pool}\left(y_k^{(l)}\right) \quad (\text{A.14})$$

entsteht und  $\text{Pool}(\cdot)$  die entsprechende Poolingoperation darstellt. Diese Abfolge wird beliebig oft durchlaufen, bis die entstehenden Kennwertkarten die Flattenschicht erreichen und zurück zu einem eindimensionalen Vektor transformiert werden. Nach der Flattenschicht ist es möglich, eine normale Netztopologie gemäß Formel A.5 zwischen Modellausgang und Flattenschicht anzuordnen, oder den Kennwertvektor ohne Zwischenverarbeitung direkt in die Aktivierungsfunktion der letzten Netzschicht  $\sigma(\cdot)$  (siehe Formel A.5) zu speisen.

#### A.8.4. Bewertungsmetriken regressierender Lernalgorithmen

Sind die Regressionsalgorithmen trainiert, bedarf es gemäß des KDT-EA-Modells [E10; E6] einer Evaluierung der Ergebnisse. Dazu werden mit einem unabhängigen Testdatensatz, auf dessen Basis der Algorithmus nicht trainiert wurde, die Performanzen quantifiziert. Für regressierende Aufgaben stehen unterschiedliche

---

Fehlermetriken bereit. Die mittlere durchschnittliche Abweichung

$$x_{\text{MDA}} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (\text{A.15})$$

quantifiziert die durchschnittlichen Beträge der Abweichungen zwischen realen und prädizierten Werten, wohingegen die mittlere quadratische Abweichung

$$x_{\text{MQA}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (\text{A.16})$$

hohe Abweichungen durch eine Quadrierung stärker bestraft. Die Wurzel der mittleren quadratischen Abweichung

$$x_{\text{WMQA}} = \frac{1}{N} \sum_{i=1}^N \sqrt{(y_i - \hat{y}_i)^2} \quad (\text{A.17})$$

bietet den Vorteil, dass die Einheit des zu bewertenden Wertes beibehalten wird. Eine weitere gängige Fehlermetrik ist das Bestimmtheitsmaß einer Regression, das sich zu

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (\text{A.18})$$

ergibt und den Anteil der Varianz des realen Datensatzes quantifiziert, den das genutzte Regressionsmodell wiedergeben kann.

---

## A.9. Grundlagen des bestärkenden Lernens

RL-Algorithmen stellen eine Klasse von ML-Algorithmen dar, in denen ein Agent mit der Umwelt interagiert und Aktionen  $\mathbf{a}_t$  in einem Zustand  $\mathbf{s}_t$  zum Zeitpunkt  $t$  wählt (siehe Abbildung A.13). Die Aktionswahl hat Einfluss auf die Folgezustände der Umwelt  $\mathbf{s}_{t+1}$ , welche dem Agenten in Kombination mit einem zur Aktionswahl  $\mathbf{a}_t$  korrespondierenden Belohnungswert  $r_t$  zurückgemeldet werden. Übergeordnetes

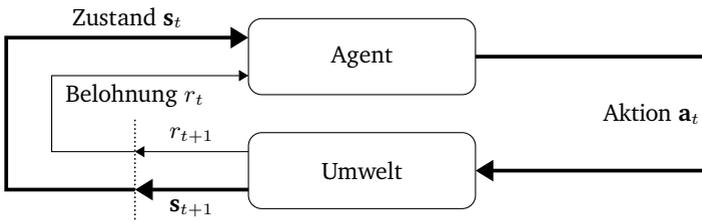


Abbildung A.13.: Interaktion von Agenten und Umwelt in Anlehnung an [SB18]

Ziel des Agenten ist die Maximierung der Summe an zukünftig zu erwartenden Belohnungen. Dabei kann dem Agenten ein Modell seiner Umwelt vorliegen (modellbasiertes Lernen) oder ihm die Dynamik der Umwelt vollständig unbekannt sein (modellfreies Lernen). Im Folgenden werden die Grundlagen von RL-Algorithmen erläutert, wobei ein Schwerpunkt auf modellfreien Algorithmen mit kontinuierlichen Zustands- und Aktionswahlen gelegt wird. Zuerst werden Grundlagen von Markov-Entscheidungsprozessen vorgestellt und Ansätze derer Lösungen dargelegt. Im weiteren Verlauf des Unterkapitels wird der Fokus auf die Funktionsweise von sogenannten AC-Algorithmen gelegt, die sich ausgezeichnet zur Manipulation von Prozessen und Maschinen eignen, da kontinuierliche Aktions- und Zustandsrepräsentationen ermöglicht werden. Das Kapitel schließt mit einer algorithmenspezifischen Vorstellung von SAC-Algorithmen ab, die für die vorliegende Arbeit von besonderer Relevanz sind.

### A.9.1. Markov-Entscheidungsprozesse und Lösungsansätze

Wesentlich für das Verständnis von RL sind Markov-Entscheidungsprozesse. In Markov-Entscheidungsprozessen ist eine Menge an Aktionen  $\mathbf{a} \in \mathbf{A}$  in unterschiedlichen Zuständen  $\mathbf{s} \in \mathbf{S}$  anwendbar. Die Wahl einer Aktion  $\mathbf{a}_t$  zum Zeitpunkt  $t$  im Zustand  $\mathbf{s}_t$  führt dazu, dass der Zustand  $\mathbf{s}_{t+1} = \mathbf{s}'$  zum Zeitpunkt  $t + 1$  von jener Wahl abhängig ist, wobei eine Zustandsübergangsfunktion  $\mathcal{P} : \mathbf{S} \times \mathbf{A} \times \mathbf{S} \rightarrow [0, 1]$  die entsprechenden Wahrscheinlichkeiten der Zustandsänderungen quantifiziert.

Die Wahrscheinlichkeit, mit der Zustand  $\mathbf{s}'$  durch das Ausführen von Aktion  $\mathbf{a}_t$  in Zustand  $\mathbf{s}_t$  erreicht wird, lässt sich als bedingte Wahrscheinlichkeit  $\Pr(\mathbf{s}'|\mathbf{s}_t, \mathbf{a}_t)$  ausdrücken und es wird ersichtlich, dass  $\mathbf{s}'$  ausschließlich von Aktionen und Zuständen des vorgelagerten Zeitschrittes abhängig ist. Damit ist eine vollständige Prozessbeschreibung durch ausschließliche Betrachtung der Informationen zum Zeitschritt  $t$  möglich, Zustands- und Aktionsausprägungen aus weiter vorgelagerten Prozessschritten bieten keinen zusätzlichen Informationsgehalt und werden nicht als Grundlage zur Aktionswahl herangezogen.

Zusätzlich ist eine Belohnungsfunktion  $\mathcal{R} : \mathbf{S} \times \mathbf{A} \times \mathbf{S} \rightarrow \mathbb{R}$  definiert, die die Güte der Zustandsübersetzung von  $\mathbf{s}_t$  in  $\mathbf{s}'$  unter Wahl von  $\mathbf{a}_t$  gemäß  $r(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}')$  als skalare Größe quantifiziert. Zentrales Ziel des Markov-Entscheidungsprozesses ist es nun, eine optimale Sequenz an Aktionen zu wählen, die die Summe der erhaltenen Belohnungen gemäß

$$\hat{r} = \sum_{k=t}^{\infty} \gamma^k r(\mathbf{s}_k, \mathbf{a}_k, \mathbf{s}_{k+1}) \quad (\text{A.19})$$

für einen unendlichen Zeithorizont oder

$$\hat{r} = \sum_{k=t}^{T-1} \gamma^k r(\mathbf{s}_k, \mathbf{a}_k, \mathbf{s}_{k+1}) \quad (\text{A.20})$$

für einen endlichen Horizont der Länge  $T$  maximiert. Dabei stellt  $\gamma \in [0, 1]$  einen Diskontierungsfaktor dar, der über die Gewichtung weiter in der Zukunft liegender Belohnungswerte entscheidet. Für  $\gamma = 0$  wird ausschließlich der Belohnungswert des betreffenden Zeitschrittes  $k$  berücksichtigt, wobei für  $\gamma = 1$  alle im betrachteten Zeithorizont erhaltenen Belohnungen mit gleicher Gewichtung eingehen. Somit sind alle Komponenten des Markov-Entscheidungsprozesses beschrieben, die in aggregierter Schreibweise als Tupel der Form  $(\mathbf{S}, \mathbf{A}, \mathcal{P}, \mathcal{R}, \gamma)$  zusammengefasst werden können.

Zur Maximierung der in Formeln A.19 und A.20 (diskontierten) Belohnungswerte wird eine Entscheidungsstrategie (engl.: Policy)  $\pi : \mathbf{A} \times \mathbf{S} \rightarrow [0, 1]$  definiert, die eine Wahrscheinlichkeitsverteilung darstellt und jeder Aktion  $\mathbf{a}_t$  im Zustand  $\mathbf{s}_t$  die Wahrscheinlichkeit  $\Pr(\mathbf{a}_t|\mathbf{s}_t)$  zuordnet, mit der die entsprechende Aktion gewählt wird. Unter Kenntnis einer bestimmten Entscheidungsstrategie  $\pi$  kann eine Zustands-Bewertungs-Funktion (engl.: State-Value Function)  $V_\pi : \mathbf{S} \rightarrow \mathbb{R}$  aufgestellt werden, die den Erwartungswert der diskontierten Belohnungswerte für einen bestimmten Zustand  $\mathbf{s}_t$  gemäß

$$V_\pi(\mathbf{s}_t) = \mathbb{E}_{\pi, \mathcal{P}} \left[ \sum_{k=t}^{T-1} \gamma^k r(\mathbf{s}_k, \mathbf{a}_k, \mathbf{s}_{k+1}) | \mathbf{s}_k \right] \quad (\text{A.21})$$

berechnet. Weiterhin existiert eine Aktions-Bewertungs-Funktion (engl. Action-Value Function)  $Q_\pi : \mathbf{A} \times \mathbf{S} \rightarrow \mathbb{R}$ , die den Erwartungswert der diskontierten Belohnungen

einer Aktions-Zustands-Kombination nach

$$Q_\pi(\mathbf{s}_t, \mathbf{a}_t) = \mathbb{E}_{\pi, \mathcal{P}} \left[ \sum_{k=t}^{T-1} \gamma^k r(\mathbf{s}_k, \mathbf{a}_k, \mathbf{s}_{k+1}) | \mathbf{s}_t, \mathbf{a}_t \right] \quad (\text{A.22})$$

bestimmt und im Gegensatz zur Zustands-Bewertungs-Funktion einen aktionsspezifischen, erwarteten Belohnungswert quantifiziert. Die Zustands-Bewertungs-Funktion kann anschließend zerlegt werden in den Erwartungswert der Belohnung zum Zeitpunkt  $t + 1$  und einen wiederum diskontierten Term mit allen darauffolgenden Belohnungswerten, woraus sich die rekursive Form

$$\begin{aligned} V_\pi(\mathbf{s}_t) &= \sum_{\mathbf{a}_t \in \mathbf{A}} \pi(\mathbf{s}_t, \mathbf{a}_t) \sum_{\mathbf{s}_{t+1} \in \mathbf{S}} \mathcal{P}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) [\mathcal{R}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) + \gamma V_\pi(\mathbf{s}_{t+1})] \\ &= \mathbb{E}_{\pi, \mathcal{P}} [\mathcal{R}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) + \gamma V_\pi(\mathbf{s}_{t+1})] \end{aligned} \quad (\text{A.23})$$

ergibt, die auch Bellman-Gleichung genannt wird. Das zentrale Ziel des Markov-Entscheidungsprozesses, das wie bereits beschrieben in der Findung einer optimalen Aktions-Sequenz liegt, kann nun erreicht werden, sofern eine optimale Entscheidungsstrategie  $\pi^*$  auffindbar ist. Diese ist gefunden, sofern  $\forall \mathbf{s} \in \mathbf{S}$

$$\pi^* = \arg \max_{\pi} V(\mathbf{s}) \quad (\text{A.24})$$

gilt. Für die zur optimalen Entscheidungsstrategie  $\pi^*$  korrespondierende Zustands-Bewertungs-Funktion  $V_{\pi^*}(\mathbf{s}) = V^*(\mathbf{s})$  gilt

$$V^*(\mathbf{s}) = \max_{\pi} V_\pi(\mathbf{s}). \quad (\text{A.25})$$

Unter der Annahme, dass die Menge wählbarer Aktionen endlich ist, existiert mindestens eine deterministische, optimale Entscheidungsstrategie  $\pi^*$ . Dazu wird die Bellman-Optimalitätsgleichung aufgestellt, die aus der rekursiven Schreibweise der Zustands-Bewertungs-Funktion aus Gleichung A.23 hervorgeht und auf

$$V^*(\mathbf{s}_t) = \max_{\mathbf{a}_t \in \mathbf{A}} \sum_{\mathbf{s}_{t+1} \in \mathbf{S}} \mathcal{P}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) [\mathcal{R}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) + \gamma V^*(\mathbf{s}_{t+1})] \quad (\text{A.26})$$

führt. Die optimale Entscheidungsstrategie entspricht gemäß Formel A.24 nun der Entscheidungsstrategie, bei der im Zustand  $\mathbf{s}_t$  die Aktion  $\mathbf{a}_t$  gewählt wird, die zur Maximierung der optimalen Zustands-Bewertungs-Funktion führt, wodurch

$$\pi^*(\mathbf{s}_t) = \arg \max_{\mathbf{a}_t \in \mathbf{A}} \sum_{\mathbf{s}_{t+1} \in \mathbf{S}} \mathcal{P}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) [\mathcal{R}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) + \gamma V^*(\mathbf{s}_{t+1})] \quad (\text{A.27})$$

gilt. Die rekursive Form der Aktions-Bewertungs-Funktion ergibt sich analog zu Formel A.23 zu

$$Q_\pi(\mathbf{s}_t, \mathbf{a}_t) = \mathbb{E}_{\pi, \mathcal{P}} [\mathcal{R}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) + \gamma Q_\pi(\mathbf{s}_{t+1}, \mathbf{a}_t + 1)], \quad (\text{A.28})$$

woraus deren Bellman-Optimalitätsgleichung

$$Q^*(\mathbf{s}_t, \mathbf{a}_t) = \mathbb{E}_{\pi, \mathcal{P}} \left[ \mathcal{R}(\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}) + \gamma \max_{\mathbf{a}_{t+1} \in A} Q^*(\mathbf{s}_{t+1}, \mathbf{a}_t + 1) \right] \quad (\text{A.29})$$

folgt. Auch aus dieser kann die optimale Entscheidungsstrategie

$$\pi^*(\mathbf{s}_t) = \arg \max_{\mathbf{a}_t \in A} Q^*(\mathbf{s}_t, \mathbf{a}_t) \quad (\text{A.30})$$

extrahiert werden. Lösungen der Bellman-Optimalitätsgleichungen sind insbesondere für hochdimensionale Zustandsräume aufgrund hoher Rechenzeiten und mangelnden Speicherkapazitäten nicht möglich, weswegen oftmals iterative Lösungsansätze aus der dynamischen Programmierung angewandt werden. Darunter fallen Methoden wie Value Iteration, Policy Iteration, SARSA oder Q-Learning (einen Überblick bietet [SB18]). Im Folgenden werden parametrisierbare Bewertungsfunktionen und Entscheidungsstrategien vorgestellt, die das Ziel verfolgen, eine optimale Aktionswahl durch gradientenbasierte Approximationen der Bewertungsfunktionen respektive Entscheidungsstrategien herbeizuführen.

## A.9.2. Parametrisierbare Bewertungsfunktionen und Entscheidungsstrategien

Im Weiteren werden parametrisierbare Entscheidungsstrategien  $\pi_\theta$  und Bewertungsfunktionen  $V_w(\mathbf{s}_t)$  respektive  $Q_w(\mathbf{s}_t, \mathbf{a}_t)$  eingeführt, die über Modellparameter  $\theta$  bzw.  $\mathbf{w}$  verfügen und als Freiheitsgrade zur Manipulation der Aktionswahl bzw. Zustandsschätzung dienen. Die Findung optimaler Entscheidungsstrategien durch die Bellman-Optimalitätsgleichung aus Formel A.27 ist ausschließlich für diskrete und (unter Berücksichtigung restriktierter Rechenkapazitäten) niedrigdimensionale Zustands- und Aktionsräume möglich. In der vorliegenden Arbeit kommen RL-Algorithmen zur Regelung von Prozessen und Maschinen zum Einsatz, weswegen kontinuierliche Aktions- und Zustandsräume passfähiger sind. Policy Gradient Methoden ermöglichen die Anpassung der Modellparameter von parametrisierten Entscheidungsstrategien, indem eine von den Modellparametern abhängige Zielfunktion  $\mathcal{J}_\theta$  aufgestellt wird und anschließend mittels Gradientenverfahren optimiert wird. Die grundsätzliche Update-Regel der Modellparameter ergibt sich dabei zu

$$\theta_{t+1} = \theta_t + \alpha \nabla_{\theta} \mathcal{J}_\theta \quad (\text{A.31})$$

und berechnet Modellparameter des  $(t + 1)$ -ten Zeitschrittes  $\theta_{t+1}$  unter Kenntnis alter Modellparameter sowie einer Lernrate  $\alpha > 0$  und den Gradienten der Zielfunktion  $\nabla_{\theta} \mathcal{J}_{\theta}$ , wobei der Nabla-Operator  $\nabla_{\theta}$  die partielle Gradientenberechnung in Bezug auf die Modellparameter symbolisiert. Eine triviale Form parametrisierbarer Entscheidungsstrategien sind Linearkombinationen von Zuständen und Gewichtungen

$$\mathbf{a} \sim \pi_{\theta}(\mathbf{a}|\mathbf{s}, \theta) = \mathbf{s}^* T \theta \tag{A.32}$$

mit  $\mathbf{s}^* = [1 \quad \mathbf{s}]^T$ . Große Popularität konnten RL-Algorithmen erlangen, als (tiefe) NN zur Approximation parametrisierter Entscheidungsstrategien und Bewertungsfunktionen genutzt wurden. Approximationen der Zustands- und Aktions-Bewertungs-Funktionen werden als wertebasiert (engl.: value-based) bezeichnet und finden sich in diversen Vertretern von Q-Learning-Algorithmen wieder [Jan19]. Auf Approximationen der Entscheidungsstrategie basierende Policy-Gradient-Algorithmen wie REINFORCE [Zha21] oder Vanilla Policy Gradient [YGL22] optimieren auf direktem Wege Modellparameter der Entscheidungsstrategie, eignen sich für kontinuierliche Aktionsräume und finden sich daher häufig in Robotik-Anwendungen wieder [PS06]. AC-Algorithmen kombinieren beide Ansätze miteinander, indem zwei parametrisierte Funktionen initiiert werden. Abbildung A.14 bildet die Architektur von AC-Algorithmen ab und zeigt, dass der Agent aus Abbildung A.13 in einen Actor und einen Critic unterteilt wird. Dabei dient der Actor der Initialisierung

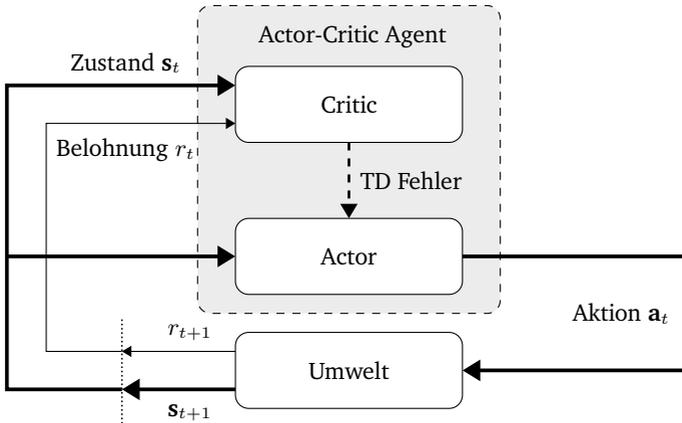


Abbildung A.14.: Übergeordnete Architektur von Actor-Critic-Algorithmen in Anlehnung an [Sze10]

und Optimierung einer parametrisierbaren Entscheidungsstrategie  $\pi_{\theta}(s_t)$  und wählt aus dieser Aktionen  $\mathbf{a}_t$ . Der Critic dient der Approximation einer parametrisierten

Zustands-Bewertungs-Funktion  $V_w(\mathbf{s}_t)$  und meldet dem Actor somit zurück, für wie gut er die Erreichung des Zustandes  $\mathbf{s}_t$  hält. Dazu wird der Temporale-Differenz (TD)-Fehler basierend auf Zustands-Bewertungs-Funktionen zweier aufeinanderfolgender Zustände berechnet, der sich zu

$$\delta_t = \underbrace{r_{t+1} + \gamma V(\mathbf{s}_{t+1})}_{\text{Erwartete Belohnung für } \mathbf{s}_{t+1}} - \underbrace{V(\mathbf{s}_t)}_{\text{Erwartete Belohnung für } \mathbf{s}_t} \quad (\text{A.33})$$

ergibt. Dabei setzt sich der TD-Fehler aus der Differenz der erwarteten Belohnungen zu den Zeitpunkten  $t + 1$  und  $t$  zusammen und stellt eine unverzerrte Schätzung der Vorteilsfunktion (engl.: Advantage Function)  $A_\pi(\mathbf{s}_t, \mathbf{a}_t) = Q_\pi(\mathbf{s}_t, \mathbf{a}_t) - V_\pi(\mathbf{s}_t)$  dar, sofern  $\mathbf{a}_t \sim \pi(\mathbf{a}_t|\mathbf{s}_t)$ . Ein Update der Bewertungsfunktion nach jedem Zeitschritt durch die TD-Methode wird TD(0) genannt, ein Update nach  $n$  Zeitschritten TD( $\lambda$ ) und für  $n \rightarrow \infty$  gehen TD-Methoden in Monte-Carlo-Methoden über (für tiefere Erklärungen sei auf [SB18] verwiesen). Der Informationsgehalt aus der erhaltenen Belohnung  $r_{t+1}$  kann anschließend genutzt werden, um die parametrisierte Zustands-Bewertungs-Funktion  $V_w(\mathbf{s}_t)$  anzupassen. Die Anpassung der Gewichtungen erfolgt analog zu Formel A.31 durch

$$\Delta \mathbf{w}_t = \alpha_w \delta_t \nabla_{\mathbf{w}} V_w(\mathbf{s}_t) \quad (\text{A.34})$$

mit der für die Gewichtungen  $\mathbf{w}$  vorgesehenen Lernrate  $\alpha_w$ . Bei AC-Algorithmen wird der TD-Fehler im Folgenden dazu genutzt, die Gewichtungen der parametrisierten Entscheidungsstrategie  $\pi_\theta$  anzupassen. Die Änderungen der Modellparameter in der Entscheidungsstrategie ergeben sich zu

$$\Delta \boldsymbol{\theta}_t = \alpha_\theta \delta_t \nabla_{\boldsymbol{\theta}} \ln \pi_\theta(\mathbf{a}_t|\mathbf{s}_t), \quad (\text{A.35})$$

deren Auswirkung bei Bedarf unter Einführung einer exponentiell abklingenden Diskontierung (siehe Zeile 10 und 11 in Algorithmus 1) beeinflusst werden kann. Algorithmus 1 veranschaulicht die grundsätzliche Funktionsweise von AC-Algorithmen als Pseudo-Code und ist angelehnt an [SB18], wobei in Kapitel A.9 eingeführte Notationen beibehalten werden. Die von AC-Architekturen durchlaufende Abfolge wird als Entscheidungsstrategie-Iteration (engl.: Policy Iteration) bezeichnet, da im ersten Schritt eine Bewertung der Entscheidungsstrategie (engl.: Policy Evaluation) durch Schätzung der Zustands-Bewertungs-Funktion erfolgt und basierend auf diesen Erkenntnissen (bzw. dem daraus hervorgehenden TD-Fehler) eine Verbesserung der Entscheidungsstrategie (engl.: Policy Improvement) angestrebt wird.

Basierend auf der geschilderten Grundform von AC-Agenten sind in den letzten Jahren unterschiedliche Algorithmen entwickelt wurden, deren gesonderte Vorstellungen den Rahmen dieses Unterkapitels zweifellos sprengen würde. Darunter fallen On-Policy-Algorithmen wie TRPO [Sch15] und dessen Modifizierung PPO [Sch17] als auch Off-Policy-Algorithmen wie DDPG [Lil15], dessen Modifizierung TD3 [FHM18] und SAC [Haa18a; Haa18b]. Letzterer spielt für die vorliegende

---

**Algorithm 1** Actor-Critic-Algorithmus in Anlehnung an [SB18]

---

**Require:** Differenzierbare Entscheidungsstrategie  $\pi(\mathbf{a}|\mathbf{s}, \boldsymbol{\theta})$

**Require:** Differenzierbare Zustands-Bewertungs-Funktion  $V(\mathbf{s}, \mathbf{w})$

**Require:** Lernrate für Actor  $\alpha_\theta > 0$  und Critic  $\alpha_w > 0$

```
1: Initialisiere Parameter der Entscheidungsstrategie  $\boldsymbol{\theta} \leftarrow \mathbf{0}$  und Zustands-
   Bewertungs-Funktion  $\mathbf{w} \leftarrow \mathbf{0}$ 
2: loop ▷ Endlose Schleife (für jede Episode)
3:   Initialisiere  $\mathbf{s}_0$  (erster Zustand der Episode)
4:    $i \leftarrow 1$ 
5:   while  $\mathbf{s}$  kein Endzustand do
6:      $\mathbf{a} \sim \pi(\mathbf{a}|\mathbf{s}, \boldsymbol{\theta})$  ▷ Wähle Aktion  $\mathbf{a}$  gemäß Entscheidungsstrategie
7:     Führe Aktion  $\mathbf{a}$  aus, beobachte  $\mathbf{s}'$ ,  $r$ 
8:      $\delta \leftarrow r + \gamma V(\mathbf{s}', \mathbf{w}) - V(\mathbf{s}, \mathbf{w})$  ▷ TD-Fehler gemäß Formel A.33
9:      $\mathbf{w} \leftarrow \mathbf{w} + \alpha_w \delta \nabla_{\mathbf{w}} V(\mathbf{s}, \mathbf{w})$  ▷ Update Parameter  $\mathbf{w}$  mit Formel A.34
10:     $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \alpha_\theta i \delta \nabla_{\boldsymbol{\theta}} \ln \pi(\mathbf{a}|\mathbf{s}, \boldsymbol{\theta})$  ▷ Update Parameter  $\boldsymbol{\theta}$  mit Formel A.35
11:     $i \leftarrow i\gamma$  ▷ Anpassung Diskontierungsfaktor
12:     $\mathbf{s} \leftarrow \mathbf{s}'$ 
13:  end while
14: end loop
```

---

Dissertation eine übergeordnete Rolle und wird daher ausführlicher behandelt.

### A.9.3. Soft-Actor-Critic

Hohe Performanzen von AC-Algorithmen bedürfen insbesondere bei hochdimensionalen Aktions- und Zustandsräumen enormer Datenmengen und sind hochsensitiv gegenüber suboptimal gewählter Hyperparameter. Aus diesem Grund stellen Haarnoja et al. einen SAC-Algorithmus vor, der sich durch höhere Dateneffizienz auszeichnet und auf dem Prinzip maximaler Entropie [ZBD10] beruht. Die übergeordnete Zielfunktion des Algorithmus liegt nicht mehr in der alleinigen Maximierung der erwarteten, diskontierten Belohnung, sondern wird über die erwartete Entropie der Entscheidungsstrategie

$$J(\pi_\theta) = \mathbb{E}_{(\mathbf{s}_t, \mathbf{a}_t) \sim \rho_\pi(\mathbf{s}_t)} \left[ \sum_{t=0}^{T-1} \gamma^t \mathcal{R}(\mathbf{s}_t, \mathbf{a}_t) + \alpha_{\mathcal{H}} \mathcal{H}(\pi(\cdot|\mathbf{s}_t)) \right] \quad (\text{A.36})$$

modifiziert, wobei  $\mathcal{H}(\cdot)$  die Entropie und  $\alpha_{\mathcal{H}}$  den zugehörigen Gewichtungsfaktor der Entropie darstellen. Somit wird neben den Belohnungswerten auch die Entropie der Entscheidungsstrategie maximiert, die ein Maß für die Unordnung darstellt und bei hoher Wahl von  $\alpha_{\mathcal{H}}$  den Algorithmus zu Explorationen anregt.

Im Gegensatz zur vorgestellten Architektur von AC-Algorithmen aus Abbildung A.14 verfügt die SAC-Architektur über mindestens zwei Critics, von denen eine die parametrisierte Zustands-Bewertungs-Funktion  $V_\psi(\mathbf{s}_t)$  und mindestens eine weitere die Aktions-Bewertungs-Funktion  $Q_{i,\theta}(\mathbf{s}_t, \mathbf{a}_t)$  darstellt. Die parametrisierte Entscheidungsstrategie wird durch  $\pi_\phi(\mathbf{s}_t)$  beschrieben.<sup>1</sup> Da es sich beim SAC um einen Off-Policy-Algorithmus handelt, wird anfangs ein Replay Buffer (Datenspeicher)  $\mathcal{D}$  initialisiert, in dem Informationen über Aktionen, Zustände und erlangte Belohnungswerte gespeichert werden.

Im ersten Schritt der Policy Iteration werden die Parameter der Bewertungsfunktionen angepasst. Für die Zustands-Bewertungs-Funktion erfolgt eine weiche Formulierung der Zustands-Bewertungs-Funktion<sup>2</sup>

$$V(\mathbf{s}_t) = \mathbb{E}_{\mathbf{a}_t \sim \pi} [Q(\mathbf{s}_t, \mathbf{a}_t) - \log \pi(\mathbf{a}_t | \mathbf{s}_t)], \quad (\text{A.37})$$

wobei der zweite Term der Entropiemaximierung der Entscheidungsstrategie  $\pi(\mathbf{a}_t | \mathbf{s}_t)$  Rechnung trägt. Die weiche Formulierung der Zustands-Bewertungs-Funktion wird anschließend genutzt, um eine Kostenfunktion  $J_V(\psi)$  aufzustellen, die die quadratischen Residuen zwischen weicher Zustands-Bewertungs-Funktion und parametrisierter Zustands-Bewertungs-Funktion gemäß

$$J_V(\psi) = \mathbb{E}_{\mathbf{s}_t \sim \mathcal{D}} \left[ \frac{1}{2} \left( V_\psi(\mathbf{s}_t) - \underbrace{\mathbb{E}_{\mathbf{a}_t \sim \pi_\phi} [Q_\theta(\mathbf{s}_t, \mathbf{a}_t) - \log \pi_\phi(\mathbf{a}_t | \mathbf{s}_t)]}_{\text{Weiche Formulierung gemäß A.37}} \right)^2 \right] \quad (\text{A.38})$$

quantifiziert. Die Parameteranpassung der Zustands-Bewertungs-Funktion erfolgt unter Schätzung der Gradienten der Kostenfunktion A.38 und führt auf

$$\hat{\nabla}_\psi J_V(\psi) = \nabla_\psi V_\psi(\mathbf{s}_t) (V_\psi(\mathbf{s}_t) - Q_\theta(\mathbf{s}_t, \mathbf{a}_t) + \log \pi_\phi(\mathbf{a}_t | \mathbf{s}_t)). \quad (\text{A.39})$$

Die Parameter der weichen Aktions-Bewertungs-Funktion  $\theta$  werden durch Minimierung der Kostenfunktion

$$J_Q(\theta) = \mathbb{E}_{(\mathbf{s}_t, \mathbf{a}_t) \sim \mathcal{D}} \left[ \frac{1}{2} (Q_\theta(\mathbf{s}_t, \mathbf{a}_t) - (r(\mathbf{s}_t, \mathbf{a}_t) + \gamma \mathbb{E}_{\mathbf{s}_{t+1} \sim p} [V_\psi(\mathbf{s}_{t+1})]))^2 \right] \quad (\text{A.40})$$

und anschließender Gradientenbildung

$$\hat{\nabla}_\theta J_Q(\theta) = \nabla_\theta Q_\theta(\mathbf{s}_t, \mathbf{a}_t) (Q_\theta(\mathbf{s}_t, \mathbf{a}_t) - r(\mathbf{s}_t, \mathbf{a}_t) - \gamma V_\psi^-(\mathbf{s}_{t+1})) \quad (\text{A.41})$$

<sup>1</sup>Die in diesem Unterkapitel genutzten Notationen orientieren sich an [Haa18a].

<sup>2</sup>Die Zustands-Bewertungs-Funktion wird an dieser Stelle weich genannt, da eine aus der optimalen Zustands-Bewertungs-Funktion extrahierte Entscheidungsstrategie neben der Maximierung erwarteter, diskontierter Belohnungswerte ebenfalls deren Entropie maximiert.

angepasst, wobei  $V_{\bar{\psi}}$  eine leicht modifizierte Zustands-Bewertungs-Funktion darstellt, deren Parameter  $\bar{\psi}$  über einen gleitenden Mittelwert ermittelt werden.

Zuletzt werden im Schritt Policy Improvement die Parameter  $\phi$  der Entscheidungsstrategie über Policy Gradient Methoden angepasst. Grundgedanke der Verbesserung der Entscheidungsstrategie ist die Minimierung der Kullback-Leibler-Divergenz<sup>3</sup> zwischen der Entscheidungsstrategie und der parametrisierten Aktions-Bewertungs-Funktion, die entsprechend normalisiert wird. Unter Anwendung des in [KW13] vorgestellten Reparametrisierungs-Tricks wird die Entscheidungsstrategie durch ein NN der Form

$$\mathbf{a}_t = f_\phi(\epsilon_t, \mathbf{s}_t) \tag{A.42}$$

dargestellt, wobei  $\epsilon_t \sim \mathcal{N}$  einen Rauschvektor repräsentiert. Dies birgt den Vorteil, dass die zur Optimierung der Entscheidungsstrategie vorgesehene Kostenfunktion

$$J_\pi(\phi) = \mathbb{E}_{\mathbf{s}_t \sim \mathcal{D}, \epsilon \sim \mathcal{N}} [\log \pi_\phi(f_\phi(\epsilon_t, \mathbf{s}_t) | \mathbf{s}_t) - Q_\theta(\mathbf{s}_t, f_\phi(\epsilon_t, \mathbf{s}_t))] \tag{A.43}$$

differenzierbar ist und sich deren Gradient zu

$$\hat{\nabla} J_\pi(\phi) = \nabla_\phi \log \pi_\phi(\mathbf{a}_t | \mathbf{s}_t) + (\nabla_{\mathbf{a}_t} \log \pi_\phi(\mathbf{a}_t | \mathbf{s}_t) - \nabla_{\mathbf{a}_t} Q(\mathbf{s}_t, \mathbf{a}_t)) \nabla_\phi f_\phi(\epsilon_t; \mathbf{s}_t) \tag{A.44}$$

ergibt. In der Praxis zeigt sich, dass die Aktions-Bewertungs-Funktion die Güte gewählter Aktionen tendenziell überbewertet, weswegen Haarnoja et al. zwei Aktions-Bewertungs-Funktionen initialisieren und die Bewertung der Entscheidungsstrategie und darauf basierende Gradientenschätzungen stets mit jener Aktions-Bewertungs-Funktion  $Q_{i,\theta}(\mathbf{s}_t, \mathbf{a}_t)$  ausführen, die den kleineren Wert ausgibt. [Haa18a] Algorithmus 2 fasst das vorgestellte Vorgehen als Pseudo-Code in Anlehnung an [Haa18a] zusammen.

---

<sup>3</sup>Eine Erklärung der Kullback-Leibler-Divergenz findet sich in Anhang A.12.

---

---

**Algorithm 2** Soft-Actor-Critic-Algorithmus in Anlehnung an [Haa18a]

---

1: Initialisiere die Parameter  $\theta, \psi, \bar{\psi}, \phi$ .  
2: **for** jede Episode **do**  
3:   **for** jeden Zeitschritt **do**  
4:      $\mathbf{a}_t \sim \pi_\phi(\mathbf{a}_t | \mathbf{s}_t)$     $\triangleright$  Wähle Aktion  $\mathbf{a}$  gemäß Entscheidungsstrategie  
5:     Führe Aktion  $\mathbf{a}$  aus, beobachte  $\mathbf{s}_{t+1}, r$   
6:      $\mathcal{D} \leftarrow \mathcal{D} \cup \{(\mathbf{s}_t, \mathbf{a}_t, r(\mathbf{s}_t, \mathbf{a}_t), \mathbf{s}_{t+1})\}$     $\triangleright$  Speichere gesammelte Daten im  
      Replay Buffer  $\mathcal{D}$   
7:   **end for**  
8:   **for** jedes Gradientenupdate **do**  
9:      $\psi \leftarrow \psi - \alpha_\psi \nabla_\psi J_V(\psi)$     $\triangleright$  Update Parameter  $\psi$  mit Formel A.39  
10:     $\theta_i \leftarrow \theta_i - \alpha_{\theta_i} \nabla_{\theta_i} J_Q(\theta_i)$  für  $i \in \{1, 2\}$     $\triangleright$  Update Parameter  $\theta_i$  mit  
      Formel A.41  
11:     $\phi \leftarrow \phi - \alpha_\phi \nabla_\phi J_\pi(\phi)$     $\triangleright$  Update Parameter  $\phi$  mit Formel A.44  
12:     $\bar{\psi} \leftarrow \tau \psi + (1 - \tau) \bar{\psi}$     $\triangleright$  Berechne gleitenden Mittelwert für  $V_{\bar{\psi}}$  aus  
      Formel A.41  
13:   **end for**  
14: **end for**

---

---

## A.10. Grundlagen der nichtlinearen, modellprädiktiven Regelung

MPC-Ansätze bauen auf dem Grundgedanken der optimalen Steuerung auf und tragen dem Umstand Rechnung, dass nicht nur der Verlauf der Regelgröße  $\mathbf{y} \in \mathbb{R}^m$  sondern ebenfalls jener der Stellgröße  $\mathbf{u} \in \mathbb{R}^n$  spezifizierte Güteanforderungen erfordern sollte. Dieser Umstand wird in optimalen Steuerungsansätzen Rechnung getragen, indem ein Gütefunktional  $\mathbb{J}$  definiert wird, das über die verfügbaren Stellgrößen minimiert werden soll. Mathematisch ausgedrückt ergibt sich das Gütefunktional im Anfangszustand  $\mathbf{x}_0$  zu

$$\mathbb{J}(\mathbf{x}_0, \mathbf{u}(t)) = \int_0^{t_e} \left( \mathbf{y}^T(t) \mathbf{Q}_y \mathbf{y}(t) + \mathbf{u}^T(t) \mathbf{R} \mathbf{u}(t) \right) dt + \mathbf{y}^T(t_e) \mathbf{S} \mathbf{y}(t_e), \quad (\text{A.45})$$

wobei die im Integral stehenden Summanden den Verlauf von Regelgröße  $\mathbf{y}(t)$  und Stellgröße  $\mathbf{u}(t)$  im optimierten Zeithorizont  $0 \leq t \leq t_e$  bestrafen und der außerhalb des Integrals stehende Term den zum Ende des Optimierungszeitraums erreichten Endwert der Regelgröße  $\mathbf{y}(t_e)$  besonders gewichtet. Die Gewichtungsmatrizen  $\mathbf{Q}_y \in \mathbb{R}^{m \times m}$ ,  $\mathbf{R} \in \mathbb{R}^{n \times n}$  und  $\mathbf{S} \in \mathbb{R}^{m \times m}$  sind symmetrisch, positiv (semi)definit und stellen Diagonalmatrizen dar, deren  $i$ -tes Hauptdiagonalelement den Einfluss der  $i$ -ten Stell- bzw. Regelgröße auf das Gütefunktional bestimmt. Die positive Definitheit der Gewichtungsmatrizen in Kombination mit einer quadratischen Multiplikation der zu optimierenden Größen führt zu nichtnegativen Summanden. Im Anschluss werden jene optimale Stellgrößen  $\mathbf{u}^*(t)$  gesucht, die das Gütefunktional gemäß

$$\min_{\mathbf{u}(t)} \mathbb{J}(\mathbf{x}_0, \mathbf{u}(t)) = \mathbb{J}(\mathbf{x}_0, \mathbf{u}^*(t)) \quad (\text{A.46})$$

minimieren. Vorteilhaft dabei ist, dass der Anwender die Hauptdiagonaleinträge der Gewichtungsmatrizen  $\mathbf{Q}_y$ ,  $\mathbf{R}$  und  $\mathbf{S}$  anwendungsspezifisch modifizieren kann und somit die Freiheit besitzt, höchstmögliche Regelgenauigkeit (durch hohe Hauptdiagonaleinträge in  $\mathbf{Q}_y$  und  $\mathbf{S}$ ) oder kleinstmögliche Stellgrößen (durch hohe Hauptdiagonaleinträge in  $\mathbf{R}$ ) zu priorisieren. Damit eignet sich die Formulierung solcher Gütefunktionale herausragend zur kontrolliert modifizierbaren Lösung von Zielkonflikten.

Wie in [Lun16] beschrieben, kann ein zeitinvarianter Regler abgeleitet werden, sofern ein unendlich langer Optimierungshorizont ( $t_e = \infty$ ) angenommen wird und der Optimierung ein lineares Zustandsraummodell eines nicht-sprungfähigen Systems der im Allgemeinen bekannten Form

$$\begin{aligned} \dot{\mathbf{x}}(t) &= \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) \quad \text{mit} \quad \mathbf{x}(0) = \mathbf{x}_0 \\ \mathbf{y}(t) &= \mathbf{C}\mathbf{x}(t) \end{aligned} \quad (\text{A.47})$$

zugrunde liegt. Dies führt auf linear-quadratische Regler, deren Anwendung ausschließlich auf lineare Regelstrecken möglich ist und die sich durch eine quadrati-

sche Formulierung des Gütefunktionals charakterisieren. Nachteile der praktischen Anwendung linear-quadratischer Regler sind mangelnde Möglichkeiten der Formulierung von Beschränkungen/Nebenbedingungen, in der Realwelt oftmals vorliegende Nichtlinearitäten und die Berücksichtigung von Performanzindikatoren, die weder Regel- noch Stellgrößen darstellen. [QB03] Genannte Nachteile können unter Inkaufnahme erhöhter Rechenzeiten durch Techniken der nichtlinearen MPC umgangen werden. Ähnlich wie bei linear-quadratischen Reglern erfolgt die Formulierung einer Kostenfunktion als Optimalsteuerproblem der Form

$$\begin{aligned}
 & \min_{\bar{\mathbf{u}}(\cdot)} \mathbb{J}(\bar{\mathbf{x}}(\cdot), \bar{\mathbf{u}}(\cdot)) \\
 \text{u.d.N. } & \dot{\bar{\mathbf{x}}}(\tau) = \mathbf{f}(\bar{\mathbf{x}}(\tau), \bar{\mathbf{u}}(\tau)), \quad \bar{\mathbf{x}}(t) = \mathbf{x}(t) \\
 & \bar{\mathbf{u}}(\tau) \in \mathcal{U}, \quad \tau \in [t, t + t_e] \\
 & \bar{\mathbf{x}}(\tau) \in \mathcal{X}, \quad \tau \in [t, t + t_e] \\
 & \bar{\mathbf{x}}(t + t_e) \in \mathcal{E}
 \end{aligned} \tag{A.48}$$

ähnlich wie Formel A.45, wobei  $(\bar{\cdot})$  im Folgenden reglerinterne Variablen beschreibt, die für den im Regler definierten Zeithorizont  $\tau \in [t, t + t_e]$  (modellbasiert) berechnet werden. Im Gegensatz zum Gütefunktional des linear-quadratischen Reglers aus A.45 ist das Gütefunktional der nichtlinearen MPC imstande, Beschränkungen für Stellgrößen  $\bar{\mathbf{u}}(\tau) \in \mathcal{U}$  und Zustandsgrößen  $\bar{\mathbf{x}}(\tau) \in \mathcal{X}$  einzuführen, gegen die keinesfalls verstoßen werden darf. Ein weiterer essenzieller Unterschied zum linear-quadratischen Regler ist, dass die meist als Zustandsraumdarstellung repräsentierte Funktion  $\dot{\bar{\mathbf{x}}}(\tau) = \mathbf{f}(\bar{\mathbf{x}}(\tau), \bar{\mathbf{u}}(\tau))$  nichtlinear sein kann, jedoch abhängig vom angewandten Optimierungsalgorithmus hinreichend häufig differenzierbar sein muss. Zusätzlich kann der Endzustand des Zeithorizontes beschränkt werden, sodass dieser in der Zustandsmenge  $\mathcal{E}$  liegt. Überführt man das definierte Gütefunktional in eine zeitdiskrete Darstellung, nimmt wie in A.45 eine quadratische Kostenfunktion an und setzt sich die Verfolgung einer vorgegebenen Trajektorie  $\mathbf{y}_{\text{soll}}$  als Ziel, kann sich das Gütefunktional zu

$$\min_{\mathbf{u}_k} \sum_{i=0}^{N-1} \underbrace{\left( \Delta \mathbf{y}_{i|k}^T \mathbf{Q}_y \Delta \mathbf{y}_{i|k} + \mathbf{u}_{i|k}^T \mathbf{R} \mathbf{u}_{i|k} \right)}_{\text{Lagrange-Term } L(\mathbf{x}, \mathbf{u})} + \underbrace{\Delta \mathbf{y}_{N|k}^T \mathbf{S} \Delta \mathbf{y}_{N|k}}_{\text{Mayer-Term } V(\mathbf{x})} \tag{A.49}$$

ergeben, wobei  $\Delta \mathbf{y}_{i|k} = \mathbf{y}_{\text{soll}, i|k} - \mathbf{y}_{\text{ist}, i|k}$  die Abweichungen der Regelgrößen quantifizieren. Der Lagrange-Term stellt dabei eine Summe über die  $N$  diskreten Abtastschritte des Prädiktionshorizontes dar, in der sowohl die Regelabweichungen als auch Stellgrößen Gegenstand der Optimierung sind. Der Mayer-Term versucht eine Übereinstimmung der Ist- und Soll-Trajektorie zum Ende des Prädiktionshorizontes herbeizuführen und kann entscheidend für die Stabilität des Reglers sein. [May00] Abbildung A.15 stellt schematisch den Verlauf von Soll- und Ist-Regelgrößen einer

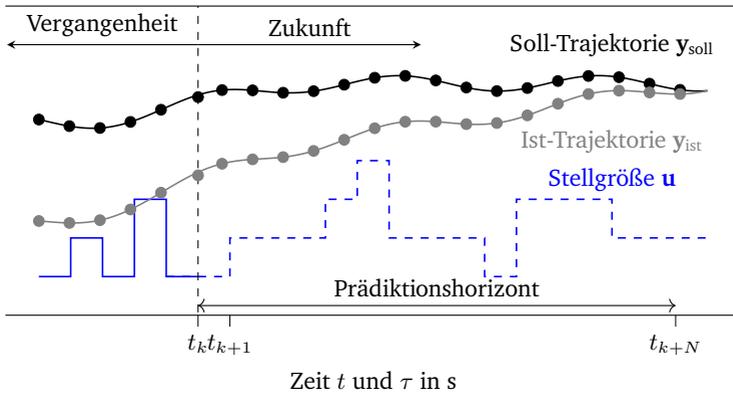


Abbildung A.15.: Funktionsprinzip der MPC mit Verlauf der Soll-, Ist- und Stellgrößen in Anlehnung an [GPM89]

MPC dar sowie den dazugehörigen Verlauf der Stellgröße  $\mathbf{u}$ . Analog zu Gleichung A.46 wird die optimale Stellgröße durch eine Optimierung des Gütefunctionals ermittelt, wobei sich bei MPC ein optimaler Stellgrößenverlauf  $\mathbf{u}_{k+i}^*$  für den gesamten Prädiktionshorizont ergibt. Ausschließlich  $\mathbf{u}_k^*$  wird dabei implementiert und an das Stellglied übermittelt, anschließend wird die Optimierung erneut vollzogen und  $\mathbf{u}_{k+i}^*$  ermittelt, wobei im  $(k+1)$ -ten Zeitschritt wiederum ausschließlich  $\mathbf{u}_{k+1}^*$  zur Regelung genutzt wird. Dieses Vorgehen verleiht der MPC einerseits einen präzidierenden Charakter und ermöglicht eine vorausschauende Stellgrößenermittlung. Gleichzeitig werden so die Modellunsicherheit, die bei der Prädiktion von weit in der Zukunft liegenden Zuständen enorme Einflüsse auf die Genauigkeit hat, beherrscht und Zustände innerhalb des gleitenden Prädiktionshorizontes mehrmals präzidiert.

## A.11. Zusätzliche Angaben zur Anwendung überwachter Lernalgorithmen auf Freibiegeprozesse

Tabelle A.2.: Übersicht der durch Bayes'sche Optimierung optimierten Hyperparameter und deren mögliche Ausprägungen

Hyperparameter	NN	CNN
Anzahl versteckte Schichten	1 – 5	0 – 5
Anzahl Neuronen in versteckten Schichten	10 – 100	10 – 100
Nutzung Batch Normalisierung	Ja/Nein	Ja/Nein
Nutzung Dropout ( $p = 0.1$ )	Ja/Nein	Ja/Nein
Aktivierungsfunktionen	ReLU/Linear Sigmoid/Tanh Softmax	ReLU
Anzahl Faltungsschichten	-	1 – 5
Pooling-Größe	-	2 – 10
Filter	-	16 – 256
Kernelgröße	-	5 – 20

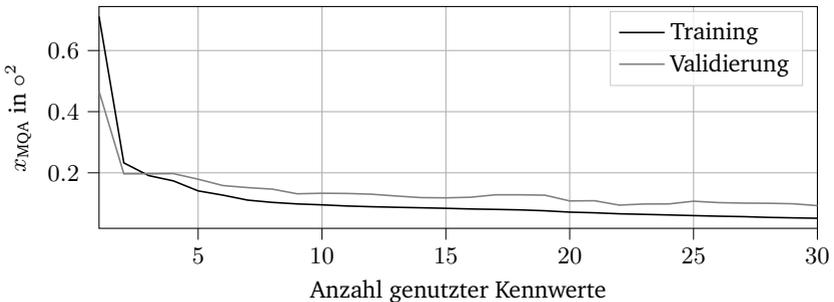


Abbildung A.16.: Abweichungen der mittleren quadratischen Biegewinkelabweichungen in Abhängigkeit der Anzahl an genutzten Kennwerten bei der Anwendung des vorwärtsgerichteten Wrapper-Algorithmus auf eine MLR (Kapitel 5.1.4)

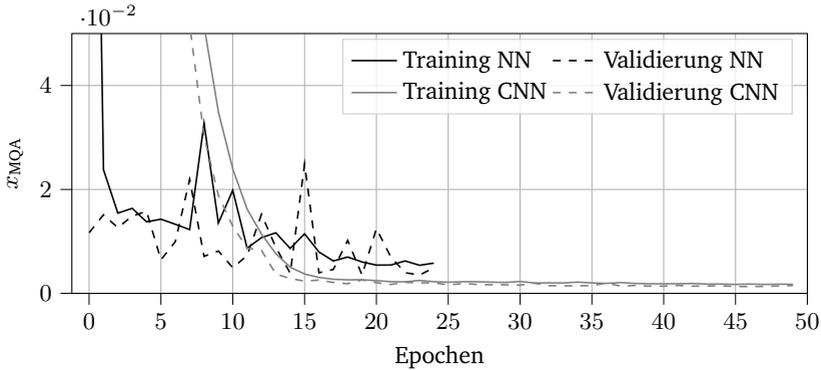


Abbildung A.17.: Verlustfunktionen entwickelter NN (Kapitel 5.1.4).  $x_{MQA}$  wird ohne Einheit angegeben, da zu präzisierende Biegewinkelwerte für Trainingszwecke auf einen Wertebereich zwischen 0 und 1 skaliert wurden und damit die Vergleichbarkeit zu mit Einheiten versehenen Werten nicht gegeben ist.

Tabelle A.3.: Durch Bayes'sche Optimierung optimierte Hyperparameter für CNN und NN (Kapitel 5.1.4)

Hyperparameter	NN	CNN
Anzahl versteckte Schichten	1	0
Anzahl Neuronen in versteckten Schichten	100	–
Nutzung Batch Normalisierung	Nein	Nein
Nutzung Dropout ( $p = 0.1$ )	Nein	Nein
Aktivierungsfunktionen	Tanh	ReLU
Anzahl Faltungsschichten	-	4
Pooling-Größe	-	{6; 6; 6; 6}
Filter	-	{16; 16; 16; 256}
Kernelgröße	-	{20; 20; 5; 5}

Tabelle A.4.: Durch Bayes'sche Optimierung optimierte Hyperparameter für CNN und NN (Kapitel 5.1.4)

Hyperparameter	NN	CNN
Anzahl versteckte Schichten	1	0
Anzahl Neuronen in versteckten Schichten	100	–
Nutzung Batch Normalisierung	Nein	Nein
Nutzung Dropout ( $p = 0.1$ )	Ja	Nein
Aktivierungsfunktionen	Tanh	ReLU
Anzahl Faltungsschichten	-	4
Pooling-Größe	-	{10; 10; 2; 4}
Filter	-	{256; 16; 16; 16}
Kernelgröße	-	{20; 5; 5; 5}

Tabelle A.5.:  $x_{MQA}$  in  $^{\circ}2$  auf Trainings- und Testdatensatz (Kapitel 5.1.4)

Datensatz	MLR	NN	CNN
Training	0,033	0,011	0,042
Test	0,049	0,167	0,046

Tabelle A.6.: Eingangsgrößen und entsprechende Unsicherheit zur analytischen Berechnung von Rückfederungen nach [BC04]

Eingangsgröße	$x_{i,DC01}$	$x_{i,AlMg3}$	$\delta x_i$
$E$ in $N/mm^2$	210000	70000	5000
$Y$ in $N/mm^2$	250	110	10
$t_b$ in mm	Siehe Versuche		0.1
$\nu$	0.29	0.3	0.02
$n$	0.22	0.19	0.02
$K$ in $N/mm^2$	657	390	20
$\alpha^{(be)}$ in $^{\circ}$	Siehe Versuche		0.4
$R$ (keine Verrundung)	0	0	0

---

## A.12. Metriken zur Bewertung der Ähnlichkeit beliebiger, diskreter Wahrscheinlichkeitsdichtefunktionen

In Kapitel 5.1.5 werden basierend auf den aufgenommenen Datensätzen geschätzte WDF für Rückfederungen aus den Versuchen, die dem Training überwachter Lernalgorithmen und deren Validierung dienen, einem Vergleich unterzogen. Abbildung 5.15 stellt WDF der unterschiedlichen Kombinationen aus Halbzeug und Blechdicke dar und lässt eine qualitative Evaluierung derer Ähnlichkeit zu. Um eine Quantifizierbarkeit der Abweichungen von WDF zu ermöglichen, werden mit der Kullback-Leibler-Divergenz [KL51] und der darauf basierenden Jensen-Shannon Divergenz [Lin91] zwei Metriken zur Bewertung der Ähnlichkeit zweier WDF genutzt. Die Berechnung der Kullback-Leibler-Divergenz erfolgt durch eine Diskretisierung der in Abbildung 5.15 visualisierten WDF in 100 äquidistante Abschnitte. Darauf basierend werden die 100 Wahrscheinlichkeiten  $p_i$  (Trainingsdatensatz) und  $q_i$  (Validierungsdatensatz) berechnet, mit der der jeweilige Biegewinkel innerhalb der Grenzen des  $i$ -ten Abschnitts liegt. Die Kullback-Leibler-Divergenz ergibt sich basierend aus diesen Werten durch

$$\mathbb{D}_{(\mathbf{p}||\mathbf{q})} = \sum_{i=1}^{100} p_i \cdot \log\left(\frac{p_i}{q_i}\right) \quad (\text{A.50})$$

und kann beliebige, positive Werte annehmen. Für kontinuierliche WDF ergibt sich analog dazu

$$\mathbb{D}_{(\mathbf{p}||\mathbf{q})} = \int_{-\infty}^{\infty} p(x) \cdot \log\frac{p(x)}{q(x)} dx. \quad (\text{A.51})$$

Wesentliche Nachteile der Kullback-Leibler-Divergenz sind deren Asymmetrie, da  $\mathbb{D}_{(\mathbf{p}||\mathbf{q})} \neq \mathbb{D}_{(\mathbf{q}||\mathbf{p})}$  gilt, und die mangelnde Vergleichbarkeit zu Kullback-Leibler-Divergenzwerten, die basierend auf anderen WDF berechnet worden sind. Beide Nachteile werden durch die Jensen-Shannon-Divergenz überwunden, indem der Mittelwert  $\mathbf{m}$  der Vektoren  $\mathbf{p}$  und  $\mathbf{q}$

$$\mathbf{m} = \frac{1}{2} \cdot (\mathbf{p} + \mathbf{q}) \quad (\text{A.52})$$

gebildet wird, welcher zur Berechnung zweier Kullback-Leibler-Divergenzen heran-gezogen wird und auf

$$\mathbb{J}_{(\mathbf{p}||\mathbf{q})} = \frac{1}{2} \cdot \mathbb{D}_{(\mathbf{p}||\mathbf{m})} + \frac{1}{2} \cdot \mathbb{D}_{(\mathbf{q}||\mathbf{m})} \quad (\text{A.53})$$

führt. Die Jensen-Shannon-Divergenz ist aufgrund  $\mathbb{J}_{(\mathbf{p}||\mathbf{q})} = \mathbb{J}_{(\mathbf{q}||\mathbf{p})}$  symmetrisch und es gilt  $\mathbb{J}_{(\mathbf{p}||\mathbf{q})} \in [0, 1]$ , wodurch eine Vergleichbarkeit zu anderen Jensen-Shannon-Divergenzwerten geschaffen wird. Eine Jensen-Shannon-Divergenz von 0 geht mit

---

identischen WDF einher, wohingegen ein Wert von 1 auf eine hohe Unterschiedlichkeit hinweist.

### A.13. Wasserstein-Distanz zur Bewertung der Ähnlichkeit multivariater Normalverteilungen

Die Wasserstein-Distanz, auch oftmals Fréchet-Distanz genannt [DL82], ist eine Metrik zur Quantifizierung der Abweichungen zweier multivariater, normalverteilter WDF. Für den vorliegenden Anwendungsfall, in dem die Unterschiedlichkeit der als Eingangsdaten genutzten Kraftsignale des Trainingsdatensatzes  $\mathbf{S}_K^{(\text{Tra})} \in \mathbb{R}^{363 \times 7307}$  und des Validierungsdatensatzes  $\mathbf{S}_K^{(\text{Val})} \in \mathbb{R}^{144 \times 7307}$  quantifiziert werden soll, werden die einzelnen Zeitschritte als normalverteilte Variablen angenommen. Dazu werden die Kraftsignale jeder Halbzeug-Blechdicken-Kombination  $\mathbf{S}_{K,ij}^{(k)} \in \mathbb{R}^{363 \times 7307}$  mit  $i \in [\text{AlMg3, DC01}]$ ,  $j \in [11, 52]$  mm und  $k \in [\text{Tra, Val}]$  herangezogen und die entsprechende multivariate WDF  $\mathbf{p}_{ij}^{(k)} \sim N\left(\boldsymbol{\mu}_{ij}^{(k)}, \boldsymbol{\Sigma}_{ij}^{(k)}\right)$  geschätzt, die durch den Vektor der Erwartungswerte  $\boldsymbol{\mu}_{ij}^{(k)} \in \mathbb{R}^{7307}$  und die symmetrische, positiv semi-definite Kovarianzmatrix  $\boldsymbol{\Sigma}_{ij}^{(k)} \in \mathbb{R}^{7307 \times 7307}$  charakterisiert ist. Die Berechnung der Wasserstein-Distanz zwischen zwei WDF des Trainings- und Validierungsdatensatzes erfolgt durch

$$\mathbb{W}\left(\mathbf{p}_{ij}^{(\text{Tra})} \parallel \mathbf{p}_{ij}^{(\text{Val})}\right) = \sqrt{\left\| \boldsymbol{\mu}_{ij}^{(\text{Tra})} - \boldsymbol{\mu}_{ij}^{(\text{Val})} \right\|_2^2 + \text{tr}\left(\boldsymbol{\Sigma}_{ij}^{(\text{Tra})} + \boldsymbol{\Sigma}_{ij}^{(\text{Val})} - 2\left(\boldsymbol{\Sigma}_{ij}^{(\text{Tra})} \boldsymbol{\Sigma}_{ij}^{(\text{Val})}\right)^{\frac{1}{2}}\right)}, \quad (\text{A.54})$$

wobei  $\text{tr}(\cdot)$  die Matrixspur und  $\|\cdot\|_2$  die L2-Vektornorm darstellt. Der L2-Term unter der Wurzel quantifiziert Abweichungen der Mittel- bzw. Erwartungswerte beider WDF, während der Spurterm abweichende Varianzen bestraft. Um eine bessere Interpretierbarkeit der berechneten Wasserstein-Distanzen zwischen Trainings- und Validierungsdatensatz sicherzustellen, werden zusätzlich die Wasserstein-Distanzen von multivariaten WDF  $\mathbb{W}\left(\mathbf{p}_{ij}^{(\text{Tra1})} \parallel \mathbf{p}_{ij}^{(\text{Tra2})}\right)$  berechnet, wobei  $\mathbf{p}_{ij}^{(\text{Tra1})}$  auf der einen und  $\mathbf{p}_{ij}^{(\text{Tra2})}$  auf der anderen Hälfte aufgenommener Kraftsignale des Trainingsdatensatzes für das  $i$ -te Material und die  $j$ -te Blechdicke beruhen. Aus Gründen der Übersichtlichkeit werden datensatzübergreifende Wasserstein-Distanzen mit  $\mathbb{W}_{ij}^{(\text{Tra}|\text{Val})}$  und ausschließlich auf dem Trainingsdatensatz beruhende Wasserstein-Distanzen mit  $\mathbb{W}_{ij}^{(\text{Tra})}$  umschrieben.

## A.14. Zusätzliche Angaben zur Anwendung bestärkender Lernalgorithmen auf Gesenkbiegeprozesse

Abbildung A.18 stellt das von Veitenheimer [S14] konstruierte, flexible Gesenkbiegewerkzeug als Prinzipskizze dar, dessen CAD-Visualisierung Abbildung A.21 zu entnehmen ist und im gefertigten, im Prototypen der 3DSP montierten Zustand in Abbildung A.22 dargestellt wird. Nähere Angaben über den Aufbau und die Komponenten des FEM-Simulationsmodells sind Abbildung A.19 zu entnehmen, eine Beschreibung der beschrifteten Komponenten findet sich in Tabelle A.9. Die für die Simulationen angenommenen Materialkennwerte und Prozessparameter sind den Tabellen A.7 bzw. A.8 zu entnehmen. Einen Überblick über den Ablauf der FEM-Simulation bietet Abbildung A.20.

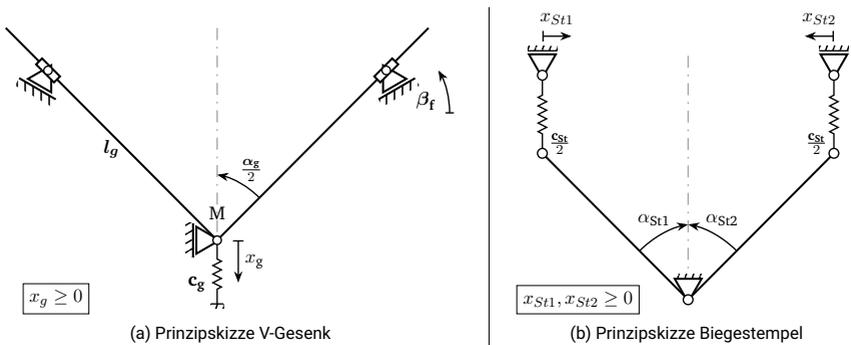


Abbildung A.18.: Funktionelle Darstellung von V-Gesenk und Biegestempel in Prinzipskizzen [S14]

Werkstoff	E-Modul [GPa]	$R_{p0,2}$ [GPa]	$R_m$ [GPa]	$A_g$ [-]	$\nu$ [-]
DC01	210	280	315	0.21	0.3
EN AW 6082	70	240	295	0.08	0.33
Kupfer	130	120	250	0.25	0.35

Tabelle A.7.: Verwendete Materialien mit dazugehörigen mechanischen Kennwerten [S14]

Werkzeug- winkel [°]	Blechdicke [mm]	Blechbreite [mm]	Stempelradi- us [mm]	Reibungs- zahl [-]
70-110	0.5-1	50	5	0.1

Tabelle A.8.: Gewählte Prozessparameter zur Abschätzung der Stempelkraft

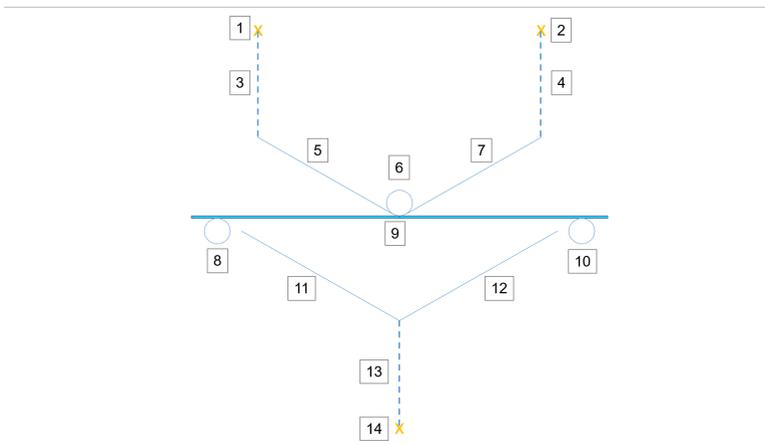


Abbildung A.19.: Simulationsmodell in Abaqus [S14]

Nummer	Name	Typ	Länge/Radius	Steifigkeit
[-]	[-]	[-]	[mm]	[ $\frac{N}{mm}$ ]
1	Federhalter 1	<i>RP</i>	-	-
2	Federhalter 2	<i>RP</i>	-	-
3	Stempelfeder 1	<i>Spring</i>	-	16.3
4	Stempelfeder 2	<i>Spring</i>	-	16.3
5	Stempelhälfte 1	<i>Wire</i>	60	-
6	Stempelmitte	<i>Wire</i>	5	-
7	Stempelhälfte 2	<i>Wire</i>	60	-
8	Auflage 1	<i>Wire</i>	5	-
9	Blech	<i>Deformable</i>	160	-
10	Auflage 2	<i>Wire</i>	5	-
11	Gesenkhälfte 1	<i>Wire</i>	70	-
12	Gesenkhälfte 2	<i>Wire</i>	70	-
13	Gesenkfeder	<i>Spring</i>	-	22
14	Federhalter 3	<i>RP</i>	-	-

Tabelle A.9.: Einzelteile des Simulationsmodells [S14]

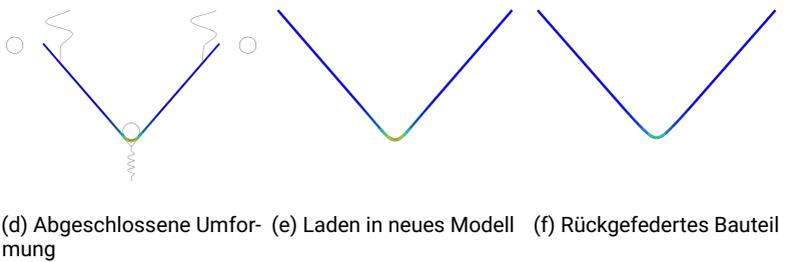
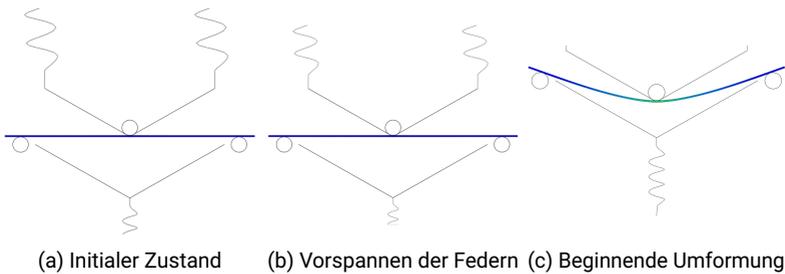
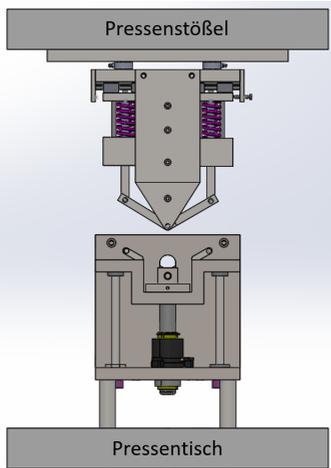
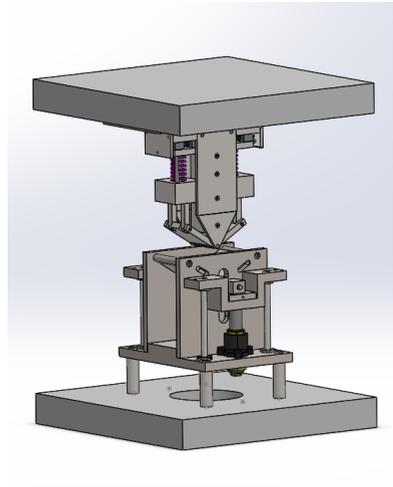


Abbildung A.20.: Schematischer Ablauf des simulativen Umformprozesses mit Rückfederung für einen Sollwinkel von 80 Grad und DC01 bei einer Blechdicke von 1 mm [S14]



(a) Seitenansicht

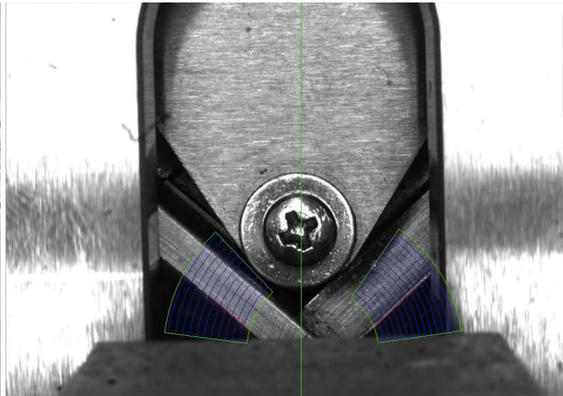


(b) 3D-Ansicht

Abbildung A.21.: Seitenansicht und 3D-Ansicht des Werkzeugsystems im CAD [S14]



(a) Montiertes Werkzeug



(b) Kamerabild während Gesenkbiegeprozess

Abbildung A.22.: Im Werkzeugraum der 3DSP eingebautes Werkzeug und Kamera- bild mit überlagerter, auf Kantendetektionsalgorithmen beruhender Winkelerfassung im Prozess [S14]

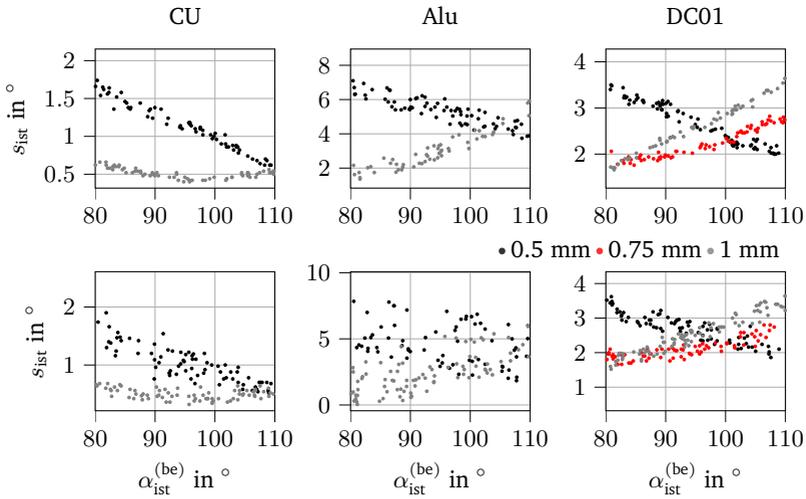


Abbildung A.23.: Simulatives Rückfederungsverhalten für FEM-Simulationen mit unterschiedlich stark unsicherheitsbehafteten Materialparametern (Datensatz GU oben, Datensatz HU unten)

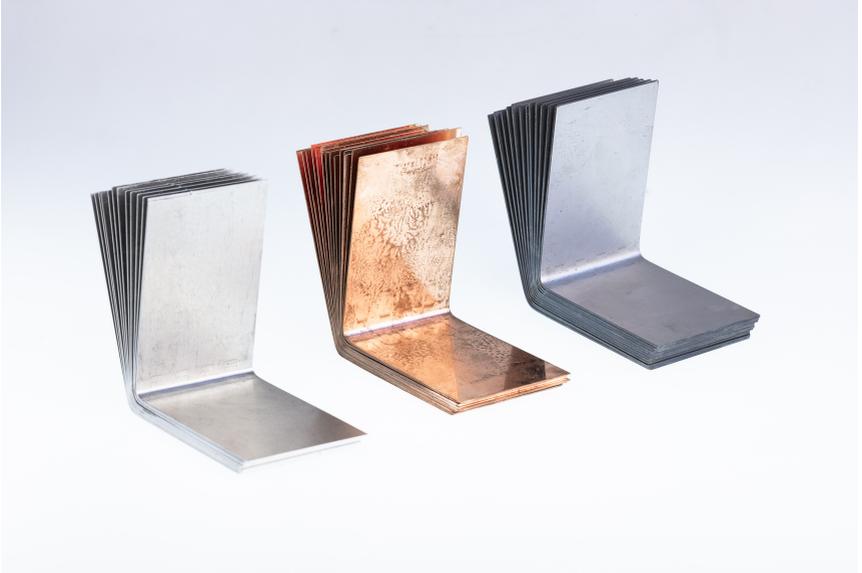


Abbildung A.24.: Bilder produzierter Gesenkbiegebauteile mit unterschiedlichen Biegewinkeln und Materialien

## A.15. Zusätzliche Angaben zur Anwendung bestärkender Lernalgorithmen auf SPIF-Prozesse

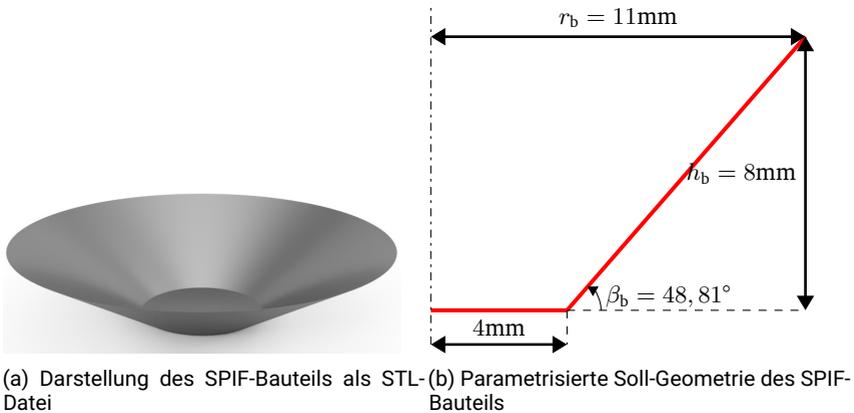


Abbildung A.25.: Darstellungen der gewünschten Geometrie des SPIF-Bauteils

Abbildung A.26 stellt eine Schnittansicht eines vermessenen SPIF-Bauteils dar. Es ist zu sehen, dass geometrische Abweichungen zwischen der Soll- (rot) und Ist-Geometrie (blau) bestehen. Die Ist-Geometrie ist dabei als Mittelwertverlauf mit entsprechenden Konfidenzintervallen dargestellt. Die Konfidenzintervalle ergeben sich aus Messunsicherheiten und Rotationsasymmetrien um die Bauteilhochachse, sodass über den Rondenumfang (tangential) und der Rondenhöhe (axial) unterschiedliche Radien, Höhen und Flankenwinkel gemessen werden. Die Berechnung der Bauteileigenschaften wird daher in unterschiedlichen Schnittebenen durchgeführt. Demzufolge basieren die in Kapitel 5.3.3 vorgestellten Fehlermetriken auf multiplen Messwerten, die aus mehreren axialen Schnittebenen (siehe Abbildung A.26 und A.27a) und/oder radialen Abtastungen (siehe Abbildung A.27b) resultieren. Weitere Informationen über die Bestimmung der geometrischen Merkmale sind [S7] zu entnehmen.

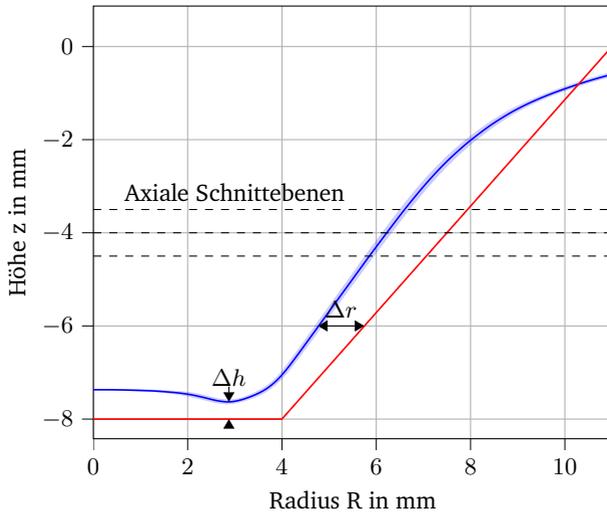
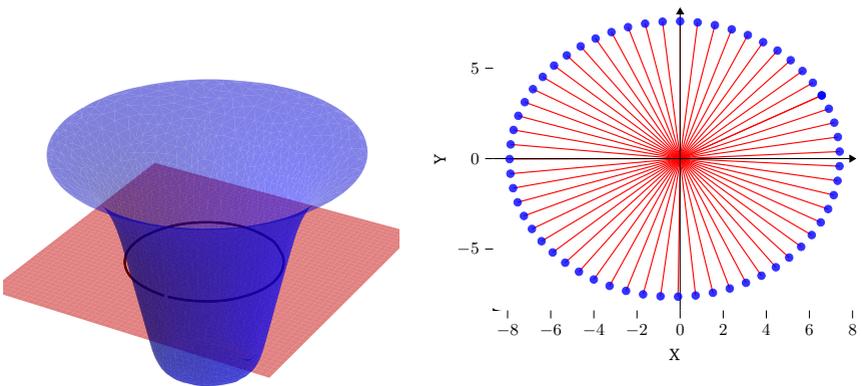


Abbildung A.26.: Schnittansicht eines aus einer STL-Datei vermessenen SPIF-Bauteils



(a) Einbringung einer axialen Schnittebene in die STL-Datei eines SPIF-Bauteils (b) Radiale Abtastung des SPIF-Bauteils in der axialen Schnittebene

Abbildung A.27.: Visualisierung der Auswertung der 3D-Messdaten durch Einbringung von axialen Schnittebenen und Bestimmung unterschiedlicher Radien über den Rondenumfang [S7]

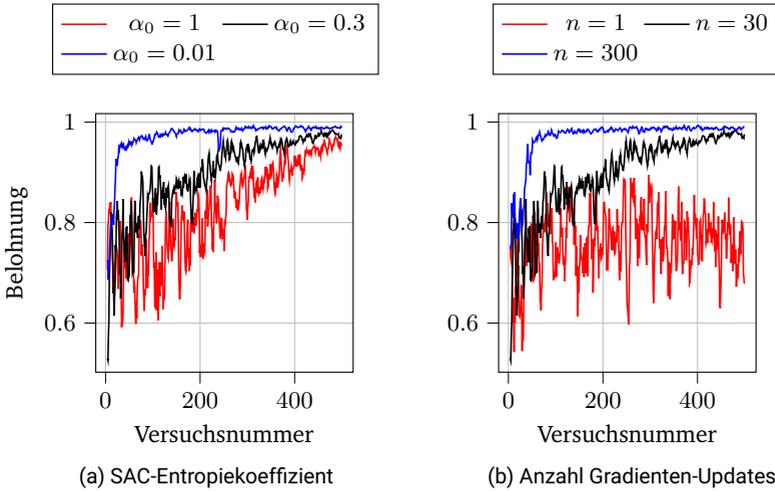


Abbildung A.28.: Konvergenzverhalten erhaltener Belohnungswerte bei unterschiedlicher Hyperparameterwahl in der virtuellen Umgebung [S7]

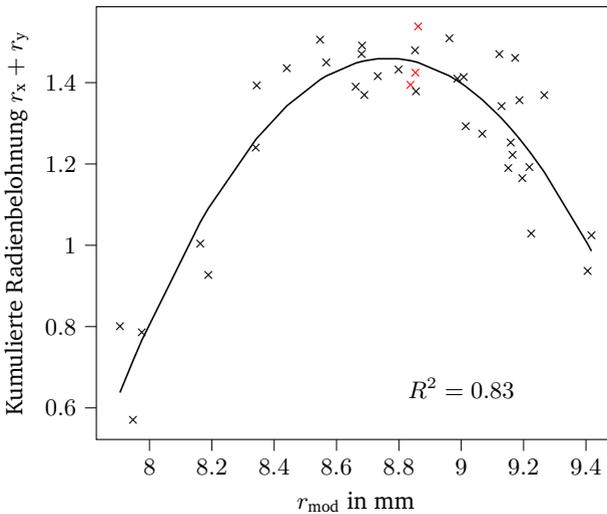


Abbildung A.29.: Zusammenhang zwischen Wahl des modifizierten Radius (Aktion) und kumulierten Teilbelohnungen der Radien  $r_x$  und  $r_y$  im SPIF-Prozess

## A.16. Schematische Darstellung der Kraftbegrenzung von Servopressen mit nichtlinearer Kinematik

Abbildung A.30 zeigt ähnlich wie Abbildung 2.12 für beliebige Kurbel- und Kniehebelpressen als auch 4.3 und 6.1 für die Forschungsversion der 3DSP, dass mit zunehmender Entfernung der Antriebsstellungen zu Totpunktbereichen die verfügbare Presskraft drastisch absinkt. Diese wird in Totpunktbereichen durch die maximale, mechanische Belastbarkeit der Presse, außerhalb von Totpunktbereichen durch das am Motor aufbringbare Drehmoment begrenzt.

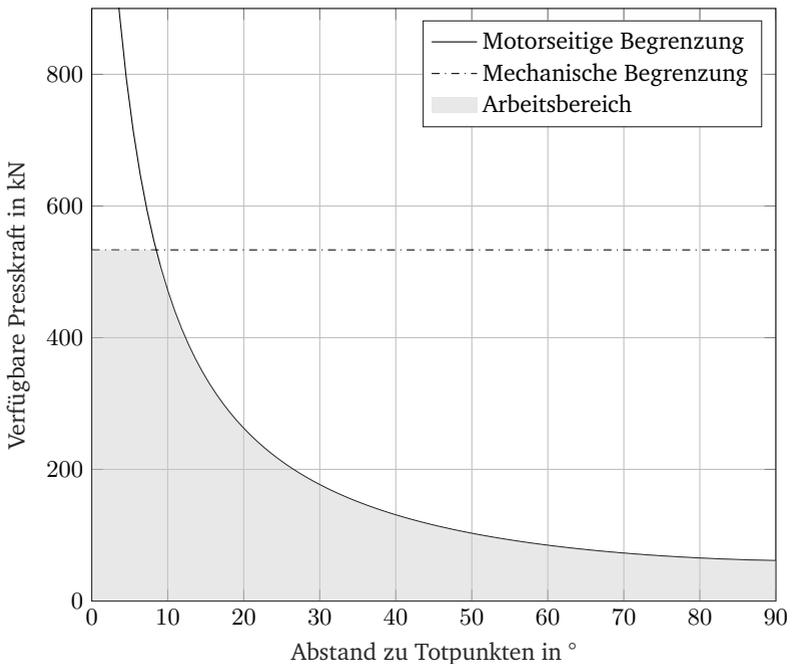


Abbildung A.30.: Bereitgestellte Presskraft der Forschungsversion der 3DSP in Abhängigkeit der relativen Positionierung eines Exzenterantriebes zu den Totpunkten in Anlehnung an [S11]

## A.17. Zusätzliche Angaben zur Anwendung von modellprädiktiver Regelung auf die Positionsregelung der 3D-Servo-Press

Besonderes Augenmerk beim Entwurf einer MPC muss auf die in der Kostenfunktion genutzten Gewichtungsmatrizen gelegt werden. Da unterschiedliche Variablen und Einheiten in der Kostenfunktion bestraft werden (bspw. Regelabweichungen der Stoßeltranslation  $\Delta_{zst}$  und Regelabweichungen der Stoßelverkipnungen  $\Delta\theta$ ), müssen Berechnungsvorschriften festgelegt werden, die schlecht konditionierten Gewichtungsmatrizen entgegenwirken. Im Folgenden wird daher vorgestellt, wie die Hauptelemente der einzelnen Gewichtungsmatrizen skaliert werden.

Gemäß des Optimalsteuerproblems aus Kapitel 6.2 gehen in die Kostenfunktion 5 Gewichtungsmatrizen ein, die die Regelabweichungen der Stoßelfreiheitsgrade ( $\mathbf{Q}$  und  $\mathbf{Q}_e$ ), Geschwindigkeitstellgrößen ( $\mathbf{W}$ ) und Beschleunigungstellgrößen ( $\mathbf{J}$ ) der Antriebe sowie Unterschreitungen der erforderlichen Presskraft ( $\mathbf{Z}$ ) bestrafen. Die Regelabweichungen der Stoßelpose werden auf maximal auftretende Regelabweichungen skaliert, sodass

$$\bar{e} = \begin{pmatrix} \frac{1}{s_{e\theta_x}^2} & & \\ & \frac{1}{s_{e\theta_y}^2} & \\ & & \frac{1}{s_{e_{zst}}^2} \end{pmatrix} e \quad (\text{A.55})$$

$$e^T Q e = \bar{e}^T (w_Q \mathbf{I}) \bar{e}$$

gilt. Dabei stellen  $s_{e_i}$  die maximal auftretenden Regelabweichungen,  $w_Q$  den Gewichtungsfaktor der Matrix und  $\mathbf{I} \in \mathbb{R}^{3 \times 3}$  eine Einheitsmatrix dar. Entsprechendes Vorgehen gilt ebenfalls für  $\mathbf{Q}_e$ .

Die Antriebsgeschwindigkeiten werden mithilfe der durchschnittlichen Manipulierbarkeit eines Antriebs auf die Stoßelfreiheitsgrade skaliert. Die Gewichtungsmatrix  $\mathbf{W}$  besteht ebenfalls ausschließlich aus Hauptdiagonalelementen und lässt sich durch

$$\mathbf{W} = \begin{pmatrix} \frac{w_W}{s_{u_{spo}}^2} & & & & \\ & \frac{w_W}{s_{u_{spu}}^2} & & & \\ & & \frac{w_W}{s_{u_{\varphi,1}}^2} & & \\ & & & \frac{w_W}{s_{u_{\varphi,2}}^2} & \\ & & & & \frac{w_W}{s_{u_{\varphi,3}}^2} \end{pmatrix} \quad (\text{A.56})$$

beschreiben, wobei sich  $s_{u_i}$  aus den durchschnittlichen Einträgen der Jakobimatrix zwischen Antriebs- und Abtriebsfreiheitsgraden ergeben. Das Geschwindigkeitsüber-

tragungsverhältnis ergibt sich bei der 3DSP aus

$$\dot{\mathbf{x}}_{\text{st}} = \mathbf{J}(\mathbf{q}) \cdot \dot{\mathbf{q}} \quad (\text{A.57})$$

und ist stark abhängig von den aktuellen Antriebspositionen  $\mathbf{q}$ . Daher werden das gesamte Spindelprozessfenster mitsamt unterschiedlichen Stellungen der Exzenterantriebe als Gitternetz dargestellt und abgetastet, die entsprechenden Einträge der Jakobimatrix aufsummiert und abschließend ein Mittelwert berechnet, der die durchschnittliche Manipulierbarkeit des  $i$ -ten Antriebs auf den  $j$ -ten Abtriebsfreiheitsgrad quantifiziert. Dies führt auf die durchschnittliche Jakobimatrix

$$\bar{\mathbf{J}} = \begin{pmatrix} \bar{j}_{1,1} & \bar{j}_{1,2} & \bar{j}_{1,3} & \bar{j}_{1,4} & \bar{j}_{1,5} \\ \bar{j}_{2,1} & \bar{j}_{2,2} & \bar{j}_{2,3} & \bar{j}_{2,4} & \bar{j}_{2,5} \\ \bar{j}_{3,1} & \bar{j}_{3,2} & \bar{j}_{3,3} & \bar{j}_{3,4} & \bar{j}_{3,5} \end{pmatrix}, \quad (\text{A.58})$$

deren Elemente für den  $i$ -ten Antrieb gemäß

$$s_{u_i} = \sqrt{\sum_{j=1}^3 j_{j,i}^2} \quad (\text{A.59})$$

aufsummiert werden und anschließend in Formel A.56 eingesetzt werden. Für  $\mathbf{J}$  werden manuell festgelegte Skalierungsfaktoren  $s_{u_i}$  gewählt, die sich zu

$$\mathbf{J} = \begin{pmatrix} \frac{w_J}{s_{u_{\text{spo}}}^2} & & & & \\ & \frac{w_J}{s_{u_{\text{spu}}}^2} & & & \\ & & \frac{w_J}{s_{u_{\varphi,1}}^2} & & \\ & & & \frac{w_J}{s_{u_{\varphi,2}}^2} & \\ & & & & \frac{w_J}{s_{u_{\varphi,3}}^2} \end{pmatrix} \quad (\text{A.60})$$

ergeben. Die Skalierungsfaktoren der die Presskraft bestrafenden Gewichtungsmatrix  $\mathbf{Z}$  führen auf

$$\mathbf{Z} = \begin{pmatrix} \frac{w_Z}{s_{\epsilon_1}^2} & & \\ & \frac{w_Z}{s_{\epsilon_2}^2} & \\ & & \frac{w_Z}{s_{\epsilon_3}^2} \end{pmatrix}. \quad (\text{A.61})$$

Die verbleibenden Gewichtungsfaktoren  $w_i$  mit  $i \in [\mathbf{Q} \ \mathbf{W} \ \mathbf{J} \ \mathbf{Z}]$  sind anschließend Gegenstand von Hyperparameteroptimierungen, deren optimierte Werte über eine Grid Search ermittelt werden.

Die genauen Skalierungsfaktoren sind Tabelle A.10 zu entnehmen.

<b>Matrix</b>	<b>Symbol</b>	<b>Einheit</b>	<b>Wert</b>	<b>Kommentar</b>
<b>Q &amp; Q<sub>e</sub></b>	$s_{e\theta_x}$	rad	$\pi/45$	Zweifache maximale Abweichung
	$s_{e\theta_y}$	rad	$\pi/45$	
	$s_{e z_{st}}$	m	0.05	
<b>W</b>	$s_{u_{spo}}$	m/s	0.0841	Skaliert auf durchschnittliche Manipulierbarkeit
	$s_{u_{spu}}$	m/s	0.1633	
	$s_{u_{\varphi,1}}$	rad/s	0.0058	
	$s_{u_{\varphi,2}}$	rad/s	0.0058	
	$s_{u_{\varphi,3}}$	rad/s	0.0058	
<b>J</b>	$s_{\dot{u}_{spo}}$	m/s <sup>2</sup>	200	Manuelle Wahl
	$s_{\dot{u}_{spu}}$	m/s <sup>2</sup>	200	
	$s_{\dot{u}_{\varphi,1}}$	rad/s <sup>2</sup>	200	
	$s_{\dot{u}_{\varphi,2}}$	rad/s <sup>2</sup>	200	
	$s_{\dot{u}_{\varphi,3}}$	rad/s <sup>2</sup>	200	
<b>Z</b>	$s_{\epsilon_1}$	N	500000	Aufteilung der Presskraft auf drei Getriebe
	$s_{\epsilon_2}$	N	500000	
	$s_{\epsilon_3}$	N	500000	

Tabelle A.10.: Skalierungsfaktoren der Gewichtungsmatrizen bei Anwendung der MPC

Einstellungen für die Nutzung von *Acados* sind Tabellen A.11 (Modell) und A.12 (Strecke) zu entnehmen.

Eintrag	Einstellung
'compile_interface'	'auto'
'codgen_model'	'true'
'compile_model'	'true'
'param_scheme_N'	10
'shooting_nodes'	[0, 0.01, 0.02, ...0.1]
'time_steps'	[]
'parameter_values'	[]
'nlp_solver'	'sqp'
'nlp_solver_exact_hessian'	'false'
'nlp_solver_max_iter'	100
'nlp_solver_tol_stat'	10 <sup>-6</sup>
'nlp_solver_tol_eq'	10 <sup>-6</sup>
'nlp_solver_tol_ineq'	10 <sup>-6</sup>
'nlp_solver_tol_comp'	10 <sup>-6</sup>
'nlp_solver_ext_qp_res'	0
'nlp_solver_step_length'	1
'rti_phase'	0
'qp_solver'	'partial_condensing_hpipm'
'globalization'	'fixed_step'
'alpha_min'	0.05
'alpha_reduction'	0.7
'line_search_use_sufficient_descent'	0
'globalization_use_SOC'	0
'full_step_dual'	0
'eps_sufficient_descent'	0.0001
'qp_solver_iter_max'	50
'qp_solver_cond_ric_alg'	1
'qp_solver_ric_alg'	1
'qp_solver_warm_start'	0
'warm_start_first_qp'	0
'sim_method'	'erk'
'collocation_type'	'gauss_legendre'
'sim_method_num_stages'	1
'sim_method_num_steps'	2
'sim_method_newton_iter'	3
'sim_method_jac_reuse'	0
'gnsf_detect_struct'	'true'
'regularize_method'	'no_regularize'
'print_level'	0
'levenberg_marquardt'	0
'exact_hess_dyn'	1
'exact_hess_cost'	1
'exact_hess_constr'	1
'ext_fun_compile_flags'	'-02'
'output_dir'	-
'qp_solver_cond_N'	5

Tabelle A.11.: Einstellungen von Acados-Modell und Optimierer

Eintrag	Einstellung
'compile_interface'	'auto'
'codgen_model'	'true'
'compile_model'	'true'
'method'	'irk'
'collocation_type'	'gauss_legendre'
'num_stages'	3
'num_steps'	3
'newton_iter'	3
'sens_forw'	'false'
'sens_adj'	'false'
'sens_hess'	'false'
'sens_algebraic'	'false'
'output_z'	'false'
'jac_reuse'	'false'
'gnsf_detect_struct'	'true'
'output_dir'	-
'ext_fun_compile_flags'	'-O2'

Tabelle A.12.: Einstellungen der Acados-Strecke

## A.18. Zusätzliche Angaben zur Anwendung von Actor-Critic-Algorithmen auf die Positionsregelung der 3D-Servo-Press

Agent	Critic Netz		Actor Netz	
	Aktions-Bew.	Zustands-Bew.	det.	stoch.
TRPO [Sch15]	-	1	-	1
PPO [Sch17]	-	1	-	1
DDPG [Lil15]	1	-	1	-
TD3 [FHM18]	2	-	1	-
SAC [Haa18a; Haa18b]	2	-	-	1

Tabelle A.13.: Übersicht über angewandte Algorithmen und die Art sowie Anzahl genutzter Bewertungsfunktionen und Entscheidungsstrategien

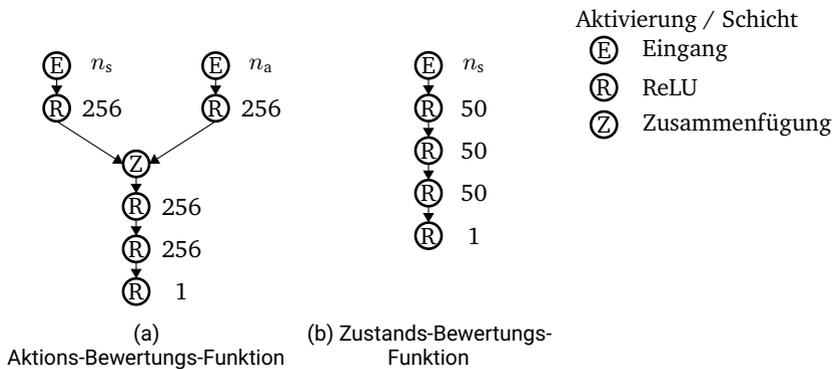


Abbildung A.31.: Gewählte Netztopologien der Aktions- und Zustands-Bewertungsfunktionen

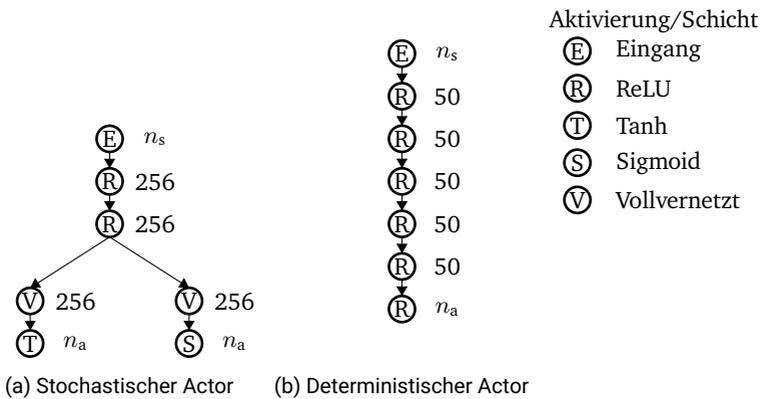


Abbildung A.32.: Gewählte Netztopologien der deterministischen und stochastischen Entscheidungsstrategien

Hyperparameter	Ausprägung
Entropielernrate	$10^{-3}$
Entropiekoeffizient	0,3
Target Smooth Factor	$5 \cdot 10^{-3}$
Frequenz Aktualisierung Entscheidungsstrategie	1
Frequenz Aktualisierung Bewertungsfunktion	1
Anzahl Schritte bis erstes Update	$10^5$
Gradientenschritte pro Update	1
Anzahl Schritte zwischen Actor & Critic Update	1
Diskontierungsfaktor	0.99
Größe Replay Buffer	$10^6$
Mini Batch Size	256
Prädiktionshorizont in Schritten	1
Critic	
Lernrate	$10^{-3}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	0
Actor	
Lernrate	$3 \cdot 10^{-3}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	0

Tabelle A.14.: Hyperparameter SAC-Algorithmus

Hyperparameter	Ausprägung
Explorationsmodell	
Rauschen Aktionen Mittelwert	0
Rauschen Aktionen Standardabweichung	0.44
Rauschen Aktionen Standardabweichung Abnahmerate	0
Target Policy Smooth Model	
Rauschen Aktionen Mittelwert	0
Rauschen Aktionen Standardabweichung	0.44
Rauschen Aktionen Standardabweichung Abnahmerate	0
Target Smooth Factor	$5 \cdot 10^{-3}$
Frequenz Aktualisierung Bewertungsfunktion	1
Anzahl Schritte zwischen Actor & Critic Update	2
Diskontierungsfaktor	1
Größe Replay Buffer	$10^6$
Mini Batch Size	64
Prädiktionshorizont in Schritten	1
Critic	
Lernrate	$10^{-3}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	$10^{-4}$
Actor	
Lernrate	$10^{-4}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	$10^{-4}$

Tabelle A.15.: Hyperparameter TD3-Algorithmus

Hyperparameter	Ausprägung
Ornstein Uhlenbeck Aktionsrauschen	
Mittelwert (MeanAttractionConstant)	0,15
Standardabweichung	0,2
Standardabweichung Abnahmerate	$10^{-5}$
Minimale Standardabweichung	0,1
Target Smooth Factor	0.01
Diskontierungsfaktor	0,99
Größe Replay Buffer	$10^6$
Mini Batch Size	256
Prädiktionshorizont in Schritten	1
Critic	
Lernrate	$10^{-3}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	$10^{-4}$
Actor	
Lernrate	$10^{-4}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	$10^{-4}$

Tabelle A.16.: Hyperparameter DDPG-Algorithmus

Hyperparameter	Ausprägung
Anzahl Schritte vor Lernbeginn	512
Mini Batch Size	128
Clip Factor	0, 2
Gewichtung Entropieverlust	0, 01
Normalized Advantage Method	-
Diskontierungsfaktor	1
GAE-Faktor	0, 95
Critic	
Lernrate	$10^{-4}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	$10^{-4}$
Actor	
Lernrate	$10^{-5}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	$10^{-4}$

Tabelle A.17.: Hyperparameter PPO-Algorithmus

Hyperparameter	Ausprägung
Mini Batch Size	128
Anzahl Schritte vor Lernbeginn	128
Gewichtung Entropieverlust	0, 01
Anzahl Epochen	10
GAE-Faktor	0, 95
ConjugateGradientDamping	$10^{-4}$
Kullback-Leibler-Divergenz Grenzwert	0, 01
Anzahl Iterationen Conjugate Gradient	10
Anzahl Iterationen LineSearch	10
Residualtoleranz ConjugateGradient	$10^{-8}$
Normalized Advantage Method	-
Diskontierungsfaktor	1
Critic	
Lernrate	$10^{-3}$
Gradientengrenzwert	$\infty$
L2-Regularisierungsfaktor	$10^{-4}$

Tabelle A.18.: Hyperparameter TRPO-Algorithmus

Nr.	E-Lernrate	E-Gewichtung	Actor-Lernrate	$\max(r)$	$\bar{r}$
1	$10^{-3}$	0,3	$10^{-4}$	2378,6	1136,2
2	$5 \cdot 10^{-4}$	0,3	$10^{-4}$	7095,6	5540,7
3	$5 \cdot 10^{-4}$	0,2	$10^{-4}$	7162,1	5835,3
4	$10^{-3}$	0,2	$10^{-4}$	6583,2	3130,5
5	$10^{-3}$	0,2	$3 \cdot 10^{-3}$	5524,2	1373,2
6	$5 \cdot 10^{-4}$	0,2	$5 \cdot 10^{-4}$	6597,4	3398,5
7	$10^{-3}$	0,2	$10^{-3}$	7195,7	4384,8
8	$10^{-5}$	0,2	$10^{-4}$	6991,9	5960,3
9	$10^{-5}$	0,3	$10^{-4}$	6980,7	5795,0
10	$10^{-3}$	0,3	$3 \cdot 10^{-3}$	6982,6	4243,9
11	$10^{-3}$	0,3	$10^{-3}$	7155,8	5502,0
12	$5 \cdot 10^{-4}$	0,2	$3 \cdot 10^{-3}$	7183,6	5079,8
13	$5 \cdot 10^{-4}$	0,2	$10^{-3}$	6919,8	5158,4
14	$10^{-4}$	0,2	$10^{-4}$	7135,2	5495,2
15	$10^{-4}$	0,3	$10^{-4}$	3076,2	44,6
16	$10^{-4}$	0,2	$5 \cdot 10^{-4}$	7108,2	5849,7
17	$5 \cdot 10^{-5}$	0,2	$10^{-4}$	<b>7223,6</b>	5978,0
18	$5 \cdot 10^{-5}$	1	$3 \cdot 10^{-4}$	6974,5	6066,4
19	$5 \cdot 10^{-5}$	1	$10^{-4}$	6642,6	4508,0
20	$5 \cdot 10^{-5}$	0,2	$10^{-3}$	6844,6	5245,2
21	$10^{-4}$	0,2	$10^{-3}$	7128,9	6216,1
22	$5 \cdot 10^{-4}$	1	$10^{-4}$	7084,8	5805,8
23	$5 \cdot 10^{-4}$	1	$5 \cdot 10^{-4}$	7205,9	<b>6308,9</b>

Tabelle A.19.: Hyperparameterkombinationen des SAC-Algorithmus zur Optimierung der Stauchtrajektorie (E = Entropie)

Nr.	E-Lernrate	Actor-Lernrate	$\max(r)$	$\bar{r}$
1	$5 \cdot 10^{-5}$	$5 \cdot 10^{-2}$	1844,6	321,8
2	$5 \cdot 10^{-5}$	$10^{-2}$	1763,5	516,8
3	$5 \cdot 10^{-4}$	$5 \cdot 10^{-4}$	3456,2	2425,9
4	$5 \cdot 10^{-4}$	$5 \cdot 10^{-4}$	3485,8	2962,2
5	$5 \cdot 10^{-5}$	$10^{-4}$	3511,9	2981,6
6	$10^{-5}$	$5 \cdot 10^{-5}$	3424,6	3011,8
7	$10^{-4}$	$10^{-4}$	3428,5	2394,6
8	$5 \cdot 10^{-5}$	$10^{-3}$	3452,4	2912,5
9	$10^{-4}$	$10^{-4}$	1154,0	561,9
10	$10^{-4}$	$10^{-4}$	3465,9	2667,5
11	$10^{-4}$	$10^{-3}$	3487,2	3109,0
12	$5 \cdot 10^{-5}$	$5 \cdot 10^{-5}$	3472,1	3108,8
13	$5 \cdot 10^{-5}$	$3 \cdot 10^{-4}$	3480,1	2775,6
14	$10^{-5}$	$3 \cdot 10^{-4}$	<b>3529,4</b>	3146,1
15	$10^{-5}$	$10^{-4}$	3482,6	3110,8
16	$10^{-3}$	$10^{-4}$	3356,5	2449,6
17	$10^{-3}$	$10^{-3}$	3437,2	2801,0
18	$5 \cdot 10^{-4}$	$3 \cdot 10^{-3}$	3482,2	<b>3146,8</b>
19	$5 \cdot 10^{-4}$	$10^{-3}$	3505,8	3133,8
20	$10^{-4}$	$5 \cdot 10^{-4}$	3464,9	2778,7
21	$10^{-4}$	$10^{-4}$	3428,5	2394,6

Tabelle A.20.: Hyperparameterkombinationen des SAC-Algorithmus zur Optimierung der Taumelschmiedetrajektorie (E = Entropie)

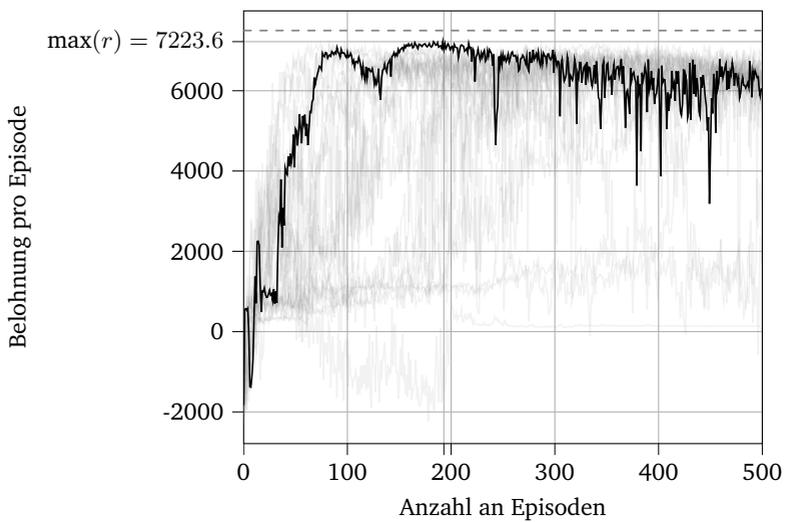


Abbildung A.33.: Verlauf der Belohnungswerte pro Episode für die 23 Hyperparameterkombinationen unter Anwendung des SAC-Algorithmus im Stauchprozess

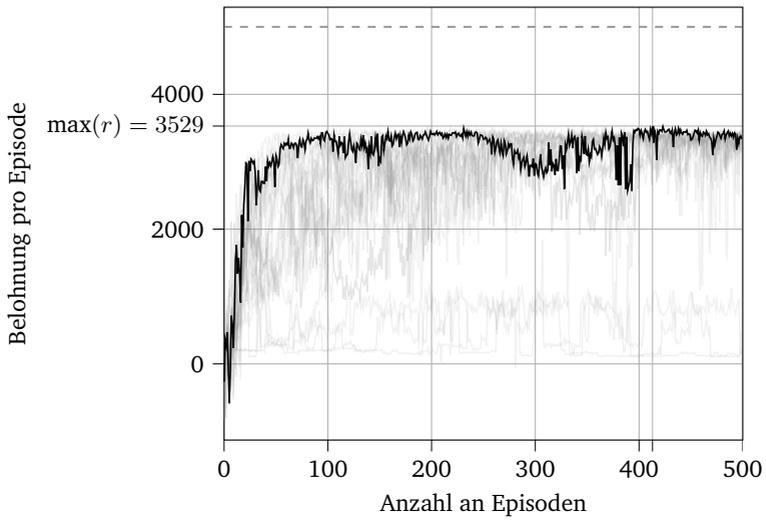


Abbildung A.34.: Verlauf der Belohnungswerte pro Episode für die 21 Hyperparameterkombinationen unter Anwendung des SAC-Algorithmus im Taumelschmiedeprozess

---

## B. Symbole, Abkürzungen und Verzeichnisse

---

### B.1. Allgemein

Aufgrund der Vielzahl an genutzten Symbolen, Formelzeichen und Indizes werden diese im Folgenden für die einzelnen Kapitel gesondert aufgelistet. Die Notation orientiert sich dabei an DIN EN ISO 80000-2 [DIN23], bei der skalare Größen kursiv ( $x$ ), vektorielle Größen fett ( $\mathbf{x}$ ), Matrizen und Tensoren höherer Ordnung fett und mit Großbuchstaben ( $\mathbf{X}$ ) notiert werden. Abweichungen zur dargelegten Notation sind möglich, sofern eine abweichende Notation in ingenieurwissenschaftlicher Literatur üblich ist.

## Operatoren und Funktionen

Symbol	Beschreibung
$f(\cdot)$	mathematische Funktion
$f^{-1}(\cdot)$	inverse mathematische Funktion
$f_{IK}(\cdot)$	Approximierte IK zwischen Stößelpose und Stößellager
$f_P(\cdot)$	Modell zur Berechnung der maximal bereitgestellten Presskraft am Stößellager
$f_{Ste}(\cdot)$	vorwärtskinematisches Modell zwischen Antrieben und Stößelpose
$f_{ERK3}(\cdot)$	Runge-Kutta-Integrator dritter Ordnung
$f_{Reg}(\cdot)$	vorwärtskinematisches Modell zwischen Stößellagern und Stößelpose
$f_{tot}(\cdot)$	vorwärtskinematisches Modell zwischen Spindelantrieben und Totpunkten
$L(\cdot)$	Lagrange-Term in der Kostenfunktion bei Anwendung von MPC
$p(\cdot)$	Wahrscheinlichkeitsdichtefunktion
$p_f(\cdot)$	Polynomfunktion
$Q_{\mathbf{w}}(\cdot)$	Über Parametervektor $\mathbf{w}$ parametrisierbare Aktions-Bewertungsfunktion eines AC-Algorithmus
$V(\cdot)$	Mayer-Term in der Kostenfunktion bei Anwendung von MPC
$V_{\mathbf{w}}(\cdot)$	Über Parametervektor $\mathbf{w}$ parametrisierbare Zustands-Bewertungsfunktion eines AC-Algorithmus
$\times$	Kreuzprodukt
$\cdot$	Skalarprodukt
$\otimes$	Tensorprodukt
$\frac{\partial f}{\partial x}$	Partielles Differential bzw. Gradient
$\ (\cdot)\ $	Euklidische Norm
$\hat{(\cdot)}$	Schätzgröße
$\eta(\cdot)$	explizites Modell
$\pi_{\theta}(\cdot)$	Über Parametervektor $\theta$ parametrisierbare Entscheidungsstrategie von einem deterministischen Actor (AC-Algorithmus)
$\pi_{\theta}(\cdot \cdot)$	Über Parametervektor $\theta$ parametrisierbare Entscheidungsstrategie von einem stochastischen Actor (AC-Algorithmus)
$\bar{(\cdot)}$	Mittelwert
$\sigma(\cdot)$	Standardabweichung
$\mathcal{N}(\cdot)$	Charakteristisches Nennerpolynom der Übertragungsfunktion $(\cdot)$ im Laplace-Bereich
$\Re(\cdot)$	Realteil des Pols $(\cdot)$
$\Im(\cdot)$	Imaginärteil des Pols $(\cdot)$

## Abkürzungen

---

Kürzel	vollständige Bezeichnung
AC	Actor-Critic
BMBF	Bundesministerium für Bildung und Forschung
CAD	Computer Aided Design
CAM	Computer Aided Manufacturing
CNN	faltendes neuronales Netz (engl.: Convolutional Neural Network)
DDPG	Deep Deterministic Policy Gradient
DLS	damped least-squares
FEM	Finite-Elemente-Methode
GU	<i>Geringe Unsicherheit</i>
HU	<i>Hohe Unsicherheit</i>
IK	Inverse Kinematik
KAP	Kraftangriffspunkt
KDT-EA	Knowledge Discovery in Times Series for Engineering Applications
KI	Künstliche Intelligenz
KU	<i>Keine Unsicherheit</i>
LR	lineare Regression
ML	maschinelles Lernen (engl.: Machine Learning)
MLR	multiple, lineare Regression
MPC	modellprädiktive Regelung (engl.: Model Predictive Control)
MU	Mittlere Unsicherheit
NN	neuronales Netz
OT	oberer Totpunkt
PPO	Proximal Policy Optimization
PtU	Institut für Produktionstechnik und Umformmaschinen
RL	bestärkendes Lernen (engl.: Reinforcement Learning)
SAC	Soft-Actor-Critic
SISO	Single-Input-Single-Output
SPIF	Single Point Incremental Forming
SPS	Speicherprogrammierbare Steuerung
TD3	Twin Delayed Deep Deterministic Policy Gradient
TL	Transfer Learning
TRPO	Trust Region Policy Optimization
UT	Unterer Totpunkt
WGP	Wissenschaftliche Gesellschaft für Produktionstechnik
WDF	Wahrscheinlichkeitsdichtefunktion
3DSP	3D-Servo-Pressen

---

---

## B.2. Kapitel 2 und 3

### Indizes Kapitel 2 und 3

---

Index	Bedeutung
Ab	Abtrieb
H	Halbzeug
ist	Ist-Verlauf
kin	kinematisch
KH	Kniehebel
KP	Kraftangriffspunkt
KU	Kurbel
M	Maschine
Me	Messung
Mo	Modell
NB	Nebenbedingung
OT	Oberer Totpunkt
soll	Soll-Verlauf
U	Umwelt
UT	Unterer Totpunkt

### Lateinische Symbole und Formelzeichen Kapitel 2 und 3

---

Symbol	Beschreibung	Einheit
<b>c</b>	Zentrifugal- und Corioliskräfte (generalisierte Koordinaten)	Nm
$C_p$	Prozessfähigkeitsindex	-
$C_{pk}$	Prozessfähigkeitsindex unter Berücksichtigung der Verschiebung	-
<b>d</b>	Positionen Aktivelemente nach Abbildung 2.8	mm
$F$	Kraft	N
$F_p$	Abtriebskräfte (generalisierte Koordinaten)	Nm
<b>g</b>	Gravitationskräfte (generalisierte Koordinaten)	Nm
<b>J</b>	Jakobimatrix	mm/°, mm/mm, °/mm, °/°

---

Symbol	Beschreibung	Einheit
$\mathbf{J}^\dagger$	Moore-Penrose-Pseudoinverse der Jakobimatrix	mm/°, mm/mm, °/mm, °/°
$j$	Geschwindigkeitsübersetzung (analog zu Jakobimatrix für eindimensionale Übertragung)	mm/°, mm/mm, °/mm, °/°
$k$	Federsteifigkeit	N/mm
$\mathbf{K}_p$	proportionale Verstärkungsmatrix	-
$\mathbf{m}$	Modellparameter	-
$m_{\text{Man}}$	Manipulierbarkeitsmaß nach [Yos85]	-
$\mathbf{M}$	Massenmatrix	kg
$M_\varphi$	Nenndrehmoment rotatorischer Antrieb	Nm
$\mathbf{M}_q$	Antriebsdrehmomente	Nm
$N$	Stichprobenanzahl	-
$\mathbf{p}$	Geregelte Bauteileigenschaften	-
$\mathbf{q}$	Antriebsvariablen (generalisiert)	mm, rad
$\mathbf{g}$	Reibkräfte (generalisierte Koordinaten)	Nm
$R_m$	Zugfestigkeit	MPa
$R_e$	Streckgrenze	MPa
$t$	Zeit	s
$t_b$	Blechdicke	mm
$\mathbf{u}$	Modelleingangsgröße	-
$\mathbf{x}$	Abtriebsvariablen	mm, rad
$\mathbf{x}_{\text{KP}}$	Kraftangriffspunkt beim Tiefziehen auf der 3DSP	mm
$\mathbf{y}$	zeitlich veränderliche, interne Modellvariablen	-
$\mathbf{z}$	Modellausgangsgröße	-
$z_{\text{spo}}$	Position oberer Spindeltrieb der 3DSP	mm
$z_{\text{spu}}$	Position unterer Spindeltrieb der 3DSP	mm

### Griechische Symbole und Formelzeichen Kapitel 2 und 3

Symbol	Beschreibung	Einheit
$\epsilon$	Rauschterm	-
$\varepsilon$	mechanische Dehnung	-
$\varphi_i$	Winkelposition des $i$ -ten Exzenterantriebs der 3DSP	rad
$\dot{\varphi}$	Geschwindigkeiten Exzenterantriebe der 3DSP	rad/s

Symbol	Beschreibung	Einheit
$\lambda$	Dämpfungsfaktor der DLS-Inversen	-
$\theta_x$	Stößelkippwinkel um raumfeste x-Achse der 3DSP	rad
$\theta_y$	Stößelkippwinkel um raumfeste y-Achse der 3DSP	rad
$\delta$	Residualterm / Unsicherheit	-
$\theta$	Modellparameter	-

---

## B.3. Kapitel 4

### Indizes Kapitel 4

---

Index	Bedeutung
dls	damped least-squares
IK	Inverse Kinematik
Kom	Kompensation
OT	Oberer Totpunkt
P	proportional
Reg	Regelung
sp	Spindelantriebe
st	Stößel
Ste	Steuerung
tot	Totpunkte
UT	Unterer Totpunkt
Vor	Vorsteuerung

### Lateinische Symbole und Formelzeichen 4

---

Symbol	Beschreibung	Einheit
$a_i$	Polynomkoeffizienten nach Gleichung 4.17 zum Fitting der Ellipsen	-
$B_0$	Rotationspunkt des Teilsystems Kniehebel der 3DSP	mm
$b_i$	Positionen der Kraftangriffspunkte im Stauchprozess relativ zum Stößelmittelpunkt	mm
$d$	Stauchtiefe	mm
$D_z$	Position linear geführtes Gelenk der Stößelanlenkstan-ge (siehe Abbildung 4.3)	mm
$e$	Regelabweichung	mm, rad
$F$	Kraft	N
$F_\varphi(s)$	Diagonalmatrix mit Übertragungsverhalten der Exzen-terantriebe im s-Bereich (Laplace)	-
$F_{sp}(s)$	Diagonalmatrix mit Übertragungsverhalten der Spin- delantriebe im s-Bereich (Laplace)	-
$F_R$	Übertragungsfunktion des Stößelposenreglers	-
$F_z$	Maximale Presskraft der 3DSP	kN
$f_\varphi$	Kraftübersetzung von Exzenterantrieb auf Stößellager	1/mm
$h$	Hubhöhe	mm

---

Symbol	Beschreibung	Einheit
$h_0$	Initiale Höhe der Stauchprobe	mm
$h_1$	Finale Höhe der Stauchprobe	mm
<b>I</b>	Einheitsmatrix	-
$\dot{j}_\varphi$	Geschwindigkeitsübersetzung von Exzenterantrieb auf Stößellager	mm/rad
$j_{\text{Grenz},\varphi}$	Grenzwert der Geschwindigkeitsübersetzung für Umschaltung zwischen Berechnungsvorschriften für adaptiven Verstärkungsfaktor	mm/rad
<b>J</b>	Jakobimatrix	mm/rad, mm/mm, rad/mm, rad/rad
<b>J</b> <sup>+</sup>	DLS-Inverse einer Jakobimatrix	mm/rad, mm/mm, rad/mm, rad/rad
<b>J</b> <sub>tot</sub>	Jakobimatrix zwischen Spindelantrieben und Totpunkten	mm/mm
<b>J</b> <sub>st</sub>	Jakobimatrix zwischen Stößellagern und Stößelpose	rad/mm, mm/mm
<b>J</b> <sub>B<sub>0</sub></sub>	Jakobimatrix zwischen Spindelantrieben und Rotationspunkt des Kniehebels	mm/mm
<b>K</b> <sub>P,<math>\varphi</math></sub>	proportionale Verstärkungsmatrix des Stößelposenreglers	-
<b>K</b> <sub>P,sp</sub>	proportionale Verstärkungsmatrix des Totpunktreglers	-
$M_\varphi$	Nennmoment Exzenterantrieb der 3DSP	Nm
$N$	Prädiktionshorizont der MPC	-
$p_i$	Begrenzende Eckpunkte des Spindelprozessfensters	mm
<b>q</b>	Antriebsvariablen (generalisiert)	mm, rad
<b>q</b> <sub>sp</sub>	Positionen der Spindelantriebe der 3DSP	mm
<b>q</b> $\varphi$	Winkelpositionen der Exzenterantriebe der 3DSP	rad
$r_a$	Länge der kleinen elliptischen Halbachse	mm
$r_b$	Länge der großen elliptischen Halbachse	mm
$r_E$	Radius einer Ellipse an beliebigem Punkt	mm
<b>r</b> <sub>o</sub>	Lage des Walzenmittelpunktes relativ zum Kontaktpunkt zwischen Walze und Blech im Lochwalzprozess	mm
$R_{z,i}$	Position des $i$ -ten Stößellagers der 3DSP	mm
<b>R</b>	Positionen aller Stößellager der 3DSP	mm
$r$	Entfernung zwischen Stößelmittelpunkt und Kraftangriffspunkt des Stauchprozesses	mm
<b>t</b>	Positionen der Totpunkte	mm

Symbol	Beschreibung	Einheit
$t$	Zeit	s
$t_b$	Blechdicke	mm
$t_{OT}$	Positionen des oberen Totpunktes	mm
$t_{UT}$	Positionen des oberen Totpunktes	mm
$\mathbf{u}$	Geschwindigkeitsstellgröße Antriebe der 3DSP	rad/s, mm/s
$\mathbf{u}_\varphi$	Geschwindigkeitsstellgröße Exzenterantriebe	rad/s
$\mathbf{u}_{Kom}$	Geschwindigkeitsstellgröße Spindelkompensation	rad/s
$\mathbf{u}_{sp}$	Geschwindigkeitsstellgröße Spindelantriebe	mm/s
$\mathbf{u}_{Reg}$	Geschwindigkeitsstellgröße Stoßelposenregler	rad/s
$\mathbf{u}_{Vor}$	Geschwindigkeitsstellgröße Vorsteuerung	rad/s
$w$	Wurzelterm zur Berechnung der Polstellen gemäß Formel 4.11	-
$\mathbf{x}$	Abtriebsvariablen	mm, rad
$x_{st}$	Horizontale Position des Stoßelmittelpunktes der 3DSP in x-Richtung	mm
$y_{st}$	Horizontale Position des Stoßelmittelpunktes der 3DSP in y-Richtung	mm
$z_{spo}$	Position oberer Spindeltrieb der 3DSP	mm
$z_{spu}$	Position unterer Spindeltrieb der 3DSP	mm
$z_{st}$	Vertikale Position des Stoßelmittelpunktes der 3DSP	mm

## Griechische Symbole und Formelzeichen Kapitel 4

Symbol	Beschreibung	Einheit
$\varphi_i$	Winkelposition des $i$ -ten Exzenterantriebs der 3DSP	rad
$\gamma$	Umlaufender Winkel zur Erstellung des Walzenmittelpunktpfades im Lochwalzprozess	rad
$\lambda$	Pole einer Übertragungsfunktion	-
$\lambda_{DLS}$	Dämpfungsfaktor der DLS-Inversen	-
$\lambda_{Kp}$	Dämpfungsfaktor des regularisierten Verstärkungsfaktors	-
$\tau$	Zeitkonstante des PT1-Übertragungsverhalten der Antriebe	s
$\theta_x$	Stoßelkippwinkel um raumfeste x-Achse der 3DSP (Nicken)	rad
$\theta_y$	Stoßelkippwinkel um raumfeste y-Achse der 3DSP (Rollen)	rad

---

## B.4. Kapitel 5

### Indizes Kapitel 5

---

Index	Bedeutung
Ab	Abtrieb
AlMg3	Aluminiumlegierung AlMg3
ana	analytisch
$\beta$	Flankenwinkel
be	Belasteter Zustand
DC01	unlegierter Qualitätsstahl DC01 (1.0330)
E	Exzentrizität
ent	Entlasteter Zustand
Gre	Grenzwert
H	Höhe
id	ideal
ist	Ist-Wert
MF	mittlerer Fehler
MLR	multiple lineare Regression
mod	modifiziert
MQA	mittlere quadratische Abweichung
NB	Nebenbedingung
NN	neuronaes Netz
OT	Oberer Totpunkt
Pea	Pearson-Korrelation
R	Radius
RMSE	Wurzel des quadratischen Mittelwerts der Abweichungen (engl.: Root Mean Squared Error)
soll	Soll-Wert
TCP	Tool Center Point (Werkzeugspitze)
Tra	Trainingsdatensatz
UT	Unterer Totpunkt
Val	Validierungsdatensatz
W	Werkzeug

### Lateinische Symbole und Formelzeichen Kapitel 5

---

Symbol	Beschreibung	Einheit
$d$	Rondendurchmesser der SPIF-Bauteile	mm

---

Symbol	Beschreibung	Einheit
$E$	Elastizitätsmodul	$\text{N mm}^{-2}$
$F$	Normalisiertes Kraftsignal	-
$h$	Hubhöhe	mm
$h_b$	Höhe eines SPIF-Bauteils	mm
$\mathbb{J}_{(p  q)}$	Jensen-Shannon-Divergenz zwischen diskreten Wahrscheinlichkeitsdichtefunktionen (siehe Anhang A.12)	-
$k_i$	$i$ -ter Kennwert aus aufgenommenen Signal	-
$K$	Verfestigungskonstante nach Ludwik	$\text{N mm}^{-2}$
$\mathbf{K}$	Kennwertmatrix	-
$\mathbf{m}$	Materialparameter	-
$n$	Verfestigungsexponent	-
$\mathbf{p}$	Bauteileigenschaften	-
$\mathbf{q}$	Antriebsvariablen (generalisiert)	mm, rad
$r$	Belohnung des SAC-Algorithmus	-
$r_{\text{Pea}}$	Pearson-Korrelationskoeffizient	-
$r_b$	Radius eines SPIF-Bauteils	mm
$R$	Biegekantenradius	mm
$R^2$	Bestimmtheitsmaß einer Regression	-
$s$	Rückfederung	°
$s_{\text{SAC}}$	Zustände für SAC-Algorithmus	-
$\mathbf{s}_K$	Sensorisch erfasste Kraftsignale	N
$\mathbf{S}_K$	Sensorisch erfasste Kraftsignale in Matrixform	N
$t$	Totpunkt	mm
$t_b$	Blechdicke	mm
$\nu$	Poisson-Zahl	-
$\mathbb{W}$	Wasserstein-Distanz zwischen zwei multivariaten Normalverteilungen (siehe Anhang A.13)	-
$\mathbf{x}$	Abtriebsvariablen	mm, rad
$\mathbf{x}_F$	Fehlermetrik	-
$\mathbf{x}_{\text{TCP}}$	Koordinaten der Werkzeugspitze im dreidimensionalen Raum	mm
$Y$	Streckgrenze	$\text{N mm}^{-2}$
$z_W$	Vertikale Zustellung Werkzeug	mm
$z_{\text{st}}$	Vertikale Position des Stoßelmittelpunktes der 3DSP	mm

## Griechische Symbole und Formelzeichen Kapitel 5

Symbol	Beschreibung	Einheit
$\alpha$	Biegewinkel	°
$\beta_b$	Flankenwinkel eines SPIF-Bauteils	°
$\beta_0$	Regressionskonstante einer MLR	-
$\delta$	Unsicherheit	-
$\sigma_x$	Spannungszustand	N mm <sup>-2</sup>
$\varepsilon_x$	Dehnung	-
$\theta_x$	Stößelkippwinkel um raumfeste x-Achse der 3DSP	rad
$\theta_y$	Stößelkippwinkel um raumfeste y-Achse der 3DSP	rad

## B.5. Kapitel 6

### Indizes Kapitel 6

Index	Bedeutung
3DSP	3D-Servo-Pressen
F	Kraft
ges	gesamt
ist	Ist-Größe
min	minimal
MPC	Modellprädiktive Regelung (engl.: Model Predictive Control)
OT	Oberer Totpunkt
P	Prozess
pos	Position
soll	Soll-Größe
st	Stößel
UT	Unterer Totpunkt

### Lateinische Symbole und Formelzeichen Kapitel 6

Symbol	Beschreibung	Einheit
<b>a</b>	Geschwindigkeitsstellgrößen der AC-Algorithmen (Aktionen) für Antriebe der 3DSP	rad/s, mm/s
<b>A</b>	vollständige Systemmatrix zur Anwendung von MPC	-
<b>A<sub>qi</sub></b>	Systemmatrix des <i>i</i> -ten Antriebs zur Anwendung von MPC	-
<b>b</b>	vollständiger Eingangsvektor zur Anwendung von MPC	-
<b>b<sub>qi</sub></b>	Eingangsvektor des <i>i</i> -ten Antriebs zur Anwendung von MPC	-
<b>C</b>	Transformationsmatrix zur Prüfung, ob Antriebspositionen im definierten Polygon liegen	-
<i>d<sub>min</sub></i>	minimaler Abstand zu Grenzen des Spindelprozessfensters in Hohhöhen-Totpunkt-Repräsentation	mm
<i>F</i>	Presskraft	kN
<i>F<sub>p</sub></i>	Prozesskraft	kN
$\bar{\mathbf{h}}$	Vektoren zur Beschreibung der als Polygon definierten Prozessfenstergrenzen	mm
<i>j<sub>φ</sub></i>	Geschwindigkeitsübersetzung von Exzenterantrieb auf Stößellager	mm/rad

Symbol	Beschreibung	Einheit
<b>J</b>	Jakobimatrix der 3DSP zwischen Antrieben und Stößelpose	mm/rad, rad/mm, rad/rad, mm/mm
<b>J</b>	Gewichtungsmatrix zur Bestrafung von hohen Stellgrößen (Antriebsbeschleunigungen) bei Anwendung von MPC	-
$M_{\varphi}$	Nenn Drehmoment Exzenterantrieb der 3DSP	Nm
$\Sigma M_q$	kumuliertes Antriebsdrehmoment der 3DSP	Nm
<b>q</b>	Antriebsvariablen (generalisiert)	mm, rad
$\mathbf{q}_{sp}$	Positionen der Spindelantriebe der 3DSP	mm
$\bar{\mathbf{q}}$	Beschränkung für Antriebsgeschwindigkeit der 3DSP unter Anwendung von MPC	mm/s, rad/s
$\bar{\bar{\mathbf{q}}}$	Beschränkung für Antriebsbeschleunigung der 3DSP unter Anwendung von MPC	mm s <sup>-2</sup> , rad s <sup>-2</sup>
<b>Q</b>	Gewichtungsmatrix zur Bestrafung von Stößelposenabweichungen bei Anwendung von MPC	-
<b>Q<sub>e</sub></b>	Gewichtungsmatrix zur Bestrafung von Stößelposenabweichungen am Ende des Prädiktionshorizontes bei Anwendung von MPC	-
$r$	Belohnung eines AC-Algorithmus	-
$r_F$	Teilbelohnung für bereitgestellte Kraft eines AC-Algorithmus	-
$r_{pos}$	Teilbelohnung für Genauigkeit der Stößelpose eines AC-Algorithmus	-
<b>R</b>	Positionen aller Stößellager der 3DSP	mm
$R_{z,i}$	Position des $i$ -ten Stößellagers der 3DSP	mm
<b>s</b>	Zustände der AC-Algorithmen	mm
<b>t</b>	Trajektorienparameter bestehend aus Stößelpose und bereitzustellenden Kraft	mm, rad, kN
$t$	Zeit	s
<b>u</b>	Geschwindigkeitsstellgrößen der MPC für Antriebe der 3DSP	rad/s, mm/s
$\bar{\mathbf{u}}$	Beschränkung für Stellgröße (Antriebsgeschwindigkeiten) unter Anwendung von MPC	mm/s, rad/s
$\bar{\bar{\mathbf{u}}}$	Beschränkung für Stellgröße (Antriebsbeschleunigungen) unter Anwendung von MPC	mm s <sup>-2</sup> , rad s <sup>-2</sup>
<b>u*</b>	Optimale, durch MPC ermittelte Beschleunigungsstellgröße für Antriebe der 3DSP	rad s <sup>-2</sup> , mm s <sup>-2</sup>

Symbol	Beschreibung	Einheit
<b>W</b>	Gewichtungsmatrix zur Bestrafung von hohen Stellgrößen (Antriebsgeschwindigkeiten) bei Anwendung von MPC	-
<b>x</b>	Zustandsvektor der MPC	rad, rad/s, mm, mm/s
<b>x<sub>st</sub></b>	Stößelpose der 3DSP	rad, mm
<b>z<sub>st</sub></b>	Vertikale Position des Stößelmittelpunktes der 3DSP	mm
<b>Z</b>	Gewichtungsmatrix zur Bestrafung von Unterschreitungen der erforderlichen Presskraft bei Anwendung von MPC	-

### Griechische Symbole und Formelzeichen Kapitel 6

Symbol	Beschreibung	Einheit
$\varphi_i$	Winkelposition des $i$ -ten Exzenterantriebs der 3DSP	rad
$\theta_x$	Stößelkippwinkel um raumfeste x-Achse der 3DSP	rad
$\theta_y$	Stößelkippwinkel um raumfeste y-Achse der 3DSP	rad
$\tau$	Zeitkonstante des Übertragungsverhalten der Antriebe der 3DSP	s

---

## Abbildungsverzeichnis

---

2.1. Ursache-Wirkungs-Diagramm zwischen ausgewählten, unsicherheits-behafteten Einflussfaktoren und Bauteileigenschaften in umform-technischen Prozessen . . . . .	5
2.2. Bauteile aus einem Scherschneidprozess gefertigt durch unterschied-lich stark verrundete Schneidstempel [E15] . . . . .	6
2.3. Aus uniaxialen Zugversuchen ermittelte Häufigkeitsverteilungen und WDF der Zugfestigkeit $R_m$ und Streckgrenze $R_e$ in Walzrichtung ( $0^\circ$ ) und quer zur Walzrichtung ( $90^\circ$ ) sowie entsprechende Angaben für Blechdickenmessungen $t_b$ [Kot22] . . . . .	9
2.4. Nichtlineares Steifigkeitsverhalten des Prototypens der 3DSP in Hub-richtung in Abhängigkeit der Spindelpositionen (oben) und des Exz-erterantriebs bei festgelegten Spindelpositionen (unten) [GHS17] .	11
2.5. Klassifikation von Modellen in White-, Gray- und Black-Box-Modelle in Anlehnung an [Vol19] . . . . .	17
2.6. KDT-EA-Prozessmodell in Anlehnung an [E10; E6] . . . . .	23
2.7. Kaskadiertes Blockschaltbild zur Regelung von Bauteileigenschaften in der Metallumformung in Anlehnung an [All16] und Kennzeichnung auftretender Unsicherheitsquellen $\delta_i$ . . . . .	30
2.8. Vergleich der Offline-Regelung nach [DZH19] (links) und Online-Regelung nach [E1] (rechts) mit schematischer Draufsicht auf die Werkzeuge (oben) und Blockschaltbild der Regelung (unten) . . . .	31
2.9. Übersicht zu Bestandteilen selbstoptimierender Maschinen in Anleh-nung an [Möh20] mit Unsicherheitsquellen $\delta_i$ . . . . .	34
2.10. Vorgehen zur inversen Ermittlung optimaler Antriebsverläufe aus gemessenen Qualitätsdaten . . . . .	36
2.11. Regelungsarten nichtlinear-übersetzender Werkzeugmaschinen . . .	40
2.12. Vergleich zwischen Kurbel- und Kniehebelkinematik bei mechani-schen Pressen in Anlehnung an [Lan85] . . . . .	41
3.1. Schematisches Blockschaltbild zur Regelung redundanter Mehrpunkt-Servopressen in Anlehnung an [All16], das der Ableitung von Ziel-setzung und Forschungsfragen dient . . . . .	48

---

4.1. Maschinentopologien von 3DSP - Prototyp mit 1t Presskraft (links) und Forschungsversion mit 160t Presskraft (rechts) [Pel21c] . . . . .	53
4.2. Prozessfenster der Spindelantriebe der Forschungsversion und dazugehörige kinematische Transformationen in $\mathbf{B}_0$ - und Totpunktkoordinaten . . . . .	54
4.3. Kinematik und Kraftübersetzung der Forschungsversion der 3D-Servo-Pressen . . . . .	55
4.4. Blockschaltbild der 3DSP Positionsregelung in Anlehnung an [Hop21] und [E12] . . . . .	57
4.5. a) Draufsicht des Stößels mit eingezeichneten Positionierungen des Stauchwerkzeugs $\mathbf{b}_i$ und b) CAD-Darstellung des Werkzeugs und Kupferproben im unverformten und umgeformten Zustand in Anlehnung an [E12] . . . . .	61
4.6. a) Drehmomenten- und Kraftverläufe von Stauchversuchen für unterschiedliche Positionierungen $\mathbf{b}_i$ am Stößel und b) zugehörige Verkippwinkel gesteuerter und geregelter Versuche . . . . .	62
4.7. Residualverteilung der angenäherten IK des Teilsystems Stößel a) ohne Kompensation und b) mit Kompensation eines zweischichtigen NN . . . . .	67
4.8. Blockschaltbild der optimierten Positionsregelung der 3D Servo Presse im Stößellagerraum . . . . .	68
4.9. Simulatives Verhalten der Stößellagerregelung für konstant gewählten Verstärkungsfaktor $\mathbf{K}_{ii,p,\varphi} = 10$ . . . . .	69
4.10. Simulatives Verhalten der Stößellagerregelung für den adaptiven Verstärkungsfaktor $\mathbf{K}_{ii,p,\varphi W_i \neq 0}$ gemäß Formel 4.14 . . . . .	73
4.11. Versuchsaufbau bestehend aus a) Umformzone mit eingespanntem Blech, b) Lochwalzwerkzeug und c) Forschungsversion der 3DSP mit integriertem Lochwalzwerkzeug . . . . .	75
4.12. Darstellung der Geometrie elliptisch lochgewalzter Bauteile (links) und Vorgehen zur Planung des Pfades des Walzenmittelpunktes (rechts) . . . . .	76
4.13. Führungsgrößen des Positionsregelkreises der 3DSP zur Herstellung elliptischer Lochwalzproben mit $r_a = 14$ mm und $r_b = 20$ mm . . . . .	77
4.14. Visualisierung des Vorgehens zur Auswertung erfasster, optischer Messdaten . . . . .	79
4.15. Vergleich resultierender Geometrien lochgewalzter Bauteile bei Anwendung unterschiedlicher Regelgesetze [E9] . . . . .	80
4.16. Ansatz zur Werkzeugpfadkorrektur mittels linearer Regression zwischen Ist- und Soll-Werten elliptischer Halbachsenradien (a) und Vergleich resultierender Lochgeometrien (b) sowie Radienverläufe (c) zwischen korrigiertem (schwarz) und unkorrigiertem Bauteil (rot) 81	

---

5.1. a) Schematische Darstellung eines Freibiegeprozesses mit dazugehörigen Spannungsverläufen und b) prädiizierte und gewünschte Biegewinkel im belasteten und entlasteten Zustand . . . . .	85
5.2. Blockschaltbild des eigenschaftsgeregelten Freibiegeprozesses . . . . .	88
5.3. Verwendetes Biegewerkzeug mit farblich hervorgehobenen Kraftmessringen (links) und schematische Visualisierung der Schritte zur Datenvorbereitung (rechts) . . . . .	89
5.4. Übersicht über die verwendeten Algorithmen mit entsprechenden Ein- und Ausgangsgrößen . . . . .	90
5.5. Validierung der Biegewinkelerfassung durch Vergleich mit optischem 3D-Messsystem . . . . .	90
5.6. Übersicht über Vorgehen zur algorithmenspezifischen Verarbeitung aufgenommener Kraftsignale nach dem KDTEA-Prozess . . . . .	91
5.7. Normalisierte Kraftverläufe . . . . .	95
5.8. Boxplots der Rückfederungen . . . . .	95
5.9. Biegewinkelabweichungen $\Delta\alpha$ für unterschiedliche Modellarten . . . . .	96
5.10. Modell- und materialspezifischer Vergleich der Abweichungen rückfederter Biegewinkel anhand geschätzter WDF $p(\Delta\alpha^{(ent)})$ . . . . .	97
5.11. Biegewinkelabweichungen $\Delta\alpha$ für unterschiedliche Modellarten . . . . .	99
5.12. Vergleich modellspezifischer WDF . . . . .	99
5.13. Vergleich gemessener und durch unterschiedliche Modelle prädiizierter Rückfederungen für Biegeversuche mit variierender Blechdicke . . . . .	100
5.14. Modell- und materialspezifischer Vergleich der Abweichungen rückfederter Biegewinkel anhand geschätzter WDF $p(\Delta\alpha^{(ent)})$ . . . . .	102
5.15. Geschätzte WDF der gemessenen Rückfederungen auf Trainings- und Validierungsdatensatz aus Kapitel 5.1.4 und dazugehörige Jensen-Shannon-Divergenzen $\mathbb{J}_{(p q)}$ . . . . .	103
5.16. Kraftsignale auf Trainings- und Validierungsdatensatz . . . . .	104
5.17. Spannungszustände und Biegewinkel im V-Gesenkbiegeprozess . . . . .	107
5.18. Bilder des Gesenkbiegewerkzeugs bestehend aus Gesenk und Stempel [S14] . . . . .	108
5.19. Blockschaltbild des eigenschaftsgeregelten Gesenkbiegeprozesses . . . . .	109
5.20. Aufbau des KI-gestützten Produktreglers bei Anwendung auf Gesenkbiegeprozess . . . . .	111
5.21. Simulatives Rückfederungsverhalten für FEM-Simulationen mit konstanten (Datensatz KU oben) und unsicherheitsbehafteten Materialparametern (Datensatz MU unten) . . . . .	114
5.22. Vergleich der Belohnungsverläufe bei Training des SAC-Algorithmus mit diskretem und stetigem Zustandsraum basierend auf Datensätzen mit (MU) und ohne Materialparameterschwankungen (KU) . . . . .	115

---

5.23. Vergleich von WDF der Biegewinkelabweichungen unter Einsatz der Modelle auf mit unterschiedlichen Unsicherheitsgraden versehenen Simulationsdatensätzen . . . . .	116
5.24. Vergleich der WDF der Biegewinkelabweichungen für Modelle mit und ohne Kenntnis über auftretende Schwankungen der Materialparameter . . . . .	117
5.25. Vergleich der experimentellen Rückfederungen auf dem Datensatz <i>Sim2Real</i> und den prädizierten Rückfederungen des ausschließlich auf Simulationsdaten trainierten SAC-Algorithmus (gestrichelte Linie)	118
5.26. Vergleich der experimentellen Rückfederungen auf dem <i>Trainingsdatensatz</i> und den prädizierten Rückfederungen des auf Experimentaldaten nachtrainierten SAC-Algorithmus (gestrichelte Linie) . . . . .	119
5.27. Vergleich der experimentellen Rückfederungen auf dem <i>Validierungsdatensatz</i> und den prädizierten Rückfederungen des auf Experimentaldaten nachtrainierten SAC-Algorithmus (gestrichelte Linie) . . . . .	120
5.28. WDF der Biegewinkelabweichungen für experimentelle Anwendungen des SAC-Algorithmus . . . . .	121
5.29. Werkzeugspitzenpfad und typische Fehlerbilder in rotationssymmetrischen SPIF-Prozessen . . . . .	122
5.30. 3DSP mit montiertem SPIF-Werkzeug und Rondenthalterung [Ste17]	123
5.31. Blockschaltbild des eigenschaftsgerichteten SPIF-Prozesses . . . . .	124
5.32. Unterschiedlich parametrisierte Werkzeugspitzenpfade im SPIF-Prozess im raumfesten Koordinatensystem . . . . .	125
5.33. Aufbau des KI-gestützten Produktreglers bei Anwendung auf SPIF-Prozess . . . . .	126
5.34. Verlauf erhaltener Belohnungswerte über der Versuchsanzahl bei explorierendem SAC-Algorithmus . . . . .	128
5.35. Zusammenhang zwischen gewählten Aktionen und Teilbelohnungen im SPIF-Prozess . . . . .	129
5.36. Vergleich der Schnittansichten von produzierten SPIF-Bauteilen [S7]	131
6.1. Vergleich der Übersetzungen von Geschwindigkeit und Kraft zwischen Exzenterantrieb $\varphi_i$ und Stoßellager $\mathbf{R}_i$ . . . . .	135
6.2. Übergeordnetes Blockschaltbild unter Anwendung von MPC und AC-Algorithmen zur Findung optimaler Antriebspfade redundanter Serpovpressen . . . . .	137
6.3. Übersicht über die entworfene MPC . . . . .	140
6.4. Linearisiertes Prozessfenster zur Beschränkung der Spindelpositionen (links) und Beziehung zwischen Reglerstellgröße und Streckeneingang (rechts) . . . . .	141
6.5. Übersicht über den entwickelten AC-Ansatz zur Regelung der 3DSP .	143

6.6. Visualisierung des minimalen Abstands $d_{\min}$ zu Grenzen des Spindelprozessfensters (links) und Teilkomponenten der Belohnungsfunktion (rechts) . . . . .	145
6.7. Schematische Darstellung eines Stauchprozesses in Anlehnung an [DB10] . . . . .	147
6.8. Sollgrößen im Stauchprozess . . . . .	147
6.9. Performanzvergleich angewandter AC-Algorithmen bei modellfreier Regelung der 3DSP in einem Stauchprozess . . . . .	148
6.10. Antriebsgeschwindigkeiten beider Regleransätze im Stauchprozess .	150
6.11. Kraft- und Positionsabweichungen beider Regleransätze im Stauchprozess . . . . .	150
6.12. Exzenterpositionen beider Regleransätze im Stauchprozess . . . . .	152
6.13. Vergleich der kumulierten Antriebsdrehmomente unter Anwendung beider Regleransätze im Stauchprozess . . . . .	153
6.14. Schematische Darstellung eines Taumelschmiedeprozesses in Anlehnung an [DB10] . . . . .	154
6.15. Sollgrößen im Taumelschmiedeprozess . . . . .	155
6.16. Antriebsgeschwindigkeiten beider Regleransätze im Taumelschmiedeprozess . . . . .	155
6.17. Kraft- und Posenabweichungen beider Regleransätze im Taumelschmiedeprozess . . . . .	156
6.18. Exzenterpositionen beider Regleransätze im Taumelschmiedeprozess	157
6.19. Vergleich der kumulierten Antriebsdrehmomente unter Anwendung beider Regleransätze im Taumelschmiedeprozess . . . . .	158
A.1. Kinematik und Kraftübersetzung des Prototypens der 3DSP . . . . .	197
A.2. Sprungantworten der Exzenterantriebe zur Ermittlung der Zeitkonstanten $\tau$ eines postulierten PT1-Übertragungsverhaltens basierend auf 15 Messungen (Mittelwerte und 95% Konfidenzintervalle für $\hat{q}_{\varphi,i}$ und $\hat{q}_{\dot{\varphi},i}$ dargestellt) [E12] . . . . .	199
A.3. Soll- und Ist-Positionen der Stößellager $\mathbf{R}_{z,i}$ (oben) und dazugehörige Geschwindigkeitsstellgrößen $u_i$ und Ist-Größen $\dot{q}_i$ eines im Arbeitsraum geregelten Stauchprozesses bei außermittiger Krafteinwirkung (Werkzeugpositionierung gemäß Abbildung 4.5: $\mathbf{b}_1$ ) [E12] . . . . .	202
A.4. Simulatives Verhalten der Stößelpose und deren Regelabweichung unter Nutzung der Stößelposenregelung und adaptiven Stößellagerregelung . . . . .	203
A.5. Zeitlicher Verlauf der Führungsgrößen der geregelten Stößelfreiheitsgrade und korrespondierende Regelgrößen für die in Tabelle 4.3 erfassten Regelgesetze [E9] . . . . .	205

A.6. Führungsgrößen der Kippfreiheitsgrade des Stößels und korrespondierende Regelgrößen für die in Tabelle 4.3 erfassten Regelgesetze [E9] . . . . .	206
A.7. Hexagon Absolute Arm 8525-7 . . . . .	207
A.8. Vergleich der elliptischen Löcher der Lochwalzbauteile mit großem Halbachsenradius $r_b = 20$ mm für die drei angewandten Regelgesetze [E9] . . . . .	208
A.9. Gängige nichtlineare Aktivierungsfunktionen $h(\cdot)$ bei der Anwendung neuronaler Netze . . . . .	211
A.10. Performanzvergleich eines NN und einer LR bei verrauschter, nichtlinearer Datengrundlage . . . . .	212
A.11. Aufbau eines 1D-CNN zur Verarbeitung von Zeitreihen . . . . .	213
A.12. Funktionsweise kombinierter Faltungs- und Poolingschichten eines 1D-CNN in Anlehnung an [Kir18] . . . . .	214
A.13. Interaktion von Agenten und Umwelt in Anlehnung an [SB18] . . . . .	216
A.14. Übergeordnete Architektur von Actor-Critic-Algorithmen in Anlehnung an [Sze10] . . . . .	220
A.15. Funktionsprinzip der MPC mit Verlauf der Soll-, Ist- und Stellgrößen in Anlehnung an [GPM89] . . . . .	228
A.16. Abweichungen der mittleren quadratischen Biegewinkelabweichungen in Abhängigkeit der Anzahl an genutzten Kennwerten bei der Anwendung des vorwärtsgerichteten Wrapper-Algorithmus auf eine MLR (Kapitel 5.1.4) . . . . .	229
A.17. Verlustfunktionen entwickelter NN (Kapitel 5.1.4). $x_{MQA}$ wird ohne Einheit angegeben, da zu prädizierende Biegewinkelwerte für Trainingszwecke auf einen Wertebereich zwischen 0 und 1 skaliert wurden und damit die Vergleichbarkeit zu mit Einheiten versehenen Werten nicht gegeben ist. . . . .	230
A.18. Funktionelle Darstellung von V-Gesenk und Biegestempel in Prinzipskizzen [S14] . . . . .	235
A.19. Simulationsmodell in <i>Abaqus</i> [S14] . . . . .	236
A.20. Schematischer Ablauf des simulativen Umformprozesses mit Rückfederung für einen Sollwinkel von 80 Grad und DC01 bei einer Blechdicke von 1 mm [S14] . . . . .	238
A.21. Seitenansicht und 3D-Ansicht des Werkzeugsystems im CAD [S14] . . . . .	239
A.22. Im Werkzeugraum der 3DSP eingebautes Werkzeug und Kamerabild mit überlagerter, auf Kantendetektionsalgorithmen beruhender Winkelerfassung im Prozess [S14] . . . . .	239
A.23. Simulatives Rückfederungsverhalten für FEM-Simulationen mit unterschiedlich stark unsicherheitsbehafteten Materialparametern (Datensatz GU oben, Datensatz HU unten) . . . . .	240

---

A.24. Bilder produzierter Gesenkbiegebauteile mit unterschiedlichen Biege- winkeln und Materialien . . . . .	241
A.25. Darstellungen der gewünschten Geometrie des SPIF-Bauteils . . . . .	242
A.26. Schnittansicht eines aus einer STL-Datei vermessenen SPIF-Bauteils .	243
A.27. Visualisierung der Auswertung der 3D-Messdaten durch Einbringung von axialen Schnittebenen und Bestimmung unterschiedlicher Radien über den Rondenumfang [S7] . . . . .	243
A.28. Konvergenzverhalten erhaltener Belohnungswerte bei unterschiedli- cher Hyperparameterwahl in der virtuellen Umgebung [S7] . . . . .	244
A.29. Zusammenhang zwischen Wahl des modifizierten Radius (Aktion) und kumulierten Teilbelohnungen der Radien $r_x$ und $r_y$ im SPIF-Prozess	244
A.30. Bereitgestellte Presskraft der Forschungsversion der 3DSP in Abhän- gigkeit der relativen Positionierung eines Exzenterantriebes zu den Totpunkten in Anlehnung an [S11] . . . . .	245
A.31. Gewählte Netztopologien der Aktions- und Zustands-Bewertungs- Funktionen . . . . .	251
A.32. Gewählte Netztopologien der deterministischen und stochastischen Entscheidungsstrategien . . . . .	252
A.33. Verlauf der Belohnungswerte pro Episode für die 23 Hyperparame- terkombinationen unter Anwendung des SAC-Algorithmus im Stauch- prozess . . . . .	259
A.34. Verlauf der Belohnungswerte pro Episode für die 21 Hyperparame- terkombinationen unter Anwendung des SAC-Algorithmus im Tau- melschmiedeprozess . . . . .	260

---

## Tabellenverzeichnis

---

2.1. Vergleich von KAP-Regelungen in Tiefziehprozessen zwischen [DZH19] und [E1] . . . . .	33
4.1. Kennwerte der 3DSP nach [Hop21] . . . . .	54
4.2. Stauchtiefen $d$ und finale Probenhöhen $h_1$ für gesteuerte und geregelte Stauchversuche . . . . .	64
4.3. Übersicht über Parameter der drei verglichenen Regelgesetze . . . . .	78
4.4. Mittlere ( $ \bar{\cdot} $ ) und maximale Regelabweichungen $\max( \cdot )$ der im Lochwalzprozess geregelten Stößelfreiheitsgrade für unterschiedliche Regelgesetze [E9] . . . . .	79
5.1. Überblick über Versuchsplan unter Nutzung unterschiedlicher Materialien und Blechdicken $t_b$ . . . . .	94
5.4. Überblick über Versuchsplan unter Nutzung unterschiedlicher Materialien und Blechdicken $t_b$ für Validierungsversuche des KI-gestützten Produktreglers . . . . .	95
5.2. $x_{MQA}$ in $^{\circ 2}$ auf Trainings- und Testdatensatz . . . . .	96
5.3. Fehlermetriken $x_{MQA}^{(ent)}$ in $^{\circ 2}$ und $\max( \Delta\alpha^{(ent)} )$ in $^{\circ}$ für rückgefederte Biegewinkel unter Einsatz der unterschiedlichen Modelle als KI-gestützter Produktregler . . . . .	96
5.5. Überblick über Versuchsplan zur Entwicklung des KI-gestützten Produktreglers bei geringfügigen Blechdickenvariationen . . . . .	98
5.6. Überblick über Versuchsplan bei schwankenden Blechdicken für Validierungsversuche des KI-gestützten Produktreglers . . . . .	98
5.7. Fehlermetriken für rückgefederte Biegewinkel unter Einsatz der unterschiedlichen Modelle als KI-gestützter Produktregler und Korrelationskoeffizienten der Rückfederungen zwischen Messungen und modellbasierten Prädiktionen . . . . .	99
5.8. Wasserstein-Distanzen zur Quantifizierung der Ähnlichkeit datensatzübergreifender und -spezifischer WDF basierend auf Kraftsignalen	104

5.9. Unsichere Modellierung der Materialparameter in Abhängigkeit des verwendeten Simulationsdatensatzes ( $E_i$ in $\text{N mm}^{-2}$ : $E_{\text{DC01}} = 210000$ , $E_{\text{Alu}} = 70000$ , $E_{\text{Kup}} = 130000$ ; $\nu_i$ : $\nu_{\text{DC01}} = 0.3$ , $\nu_{\text{Alu}} = 0.33$ , $\nu_{\text{Kup}} = 0.35$ ) sowie Anzahl durchgeführter Simulationen $N$ . . . . .	112
5.10. Maximale und durchschnittliche Biegewinkelabweichungen unter Einsatz des SAC-Algorithmus als KI-gestützter Produktregler auf den unterschiedlichen Simulationsdatensätzen ohne (schwarz) und mit Kenntnis (grau) über Unsicherheit der Materialparameter (Mittelwerte basierend auf jeweils 30 trainierten Modellen) . . . . .	116
5.11. Übersicht über experimentell durchgeführte Versuchsreihen und deren Versuchsparameter . . . . .	118
5.12. Fehlermetriken für Biegewinkelabweichungen bei der Anwendung des SAC-Algorithmus auf die unterschiedlichen experimentellen Datensätze	121
A.1. Mittlere ( $ \bar{\cdot} $ ) und maximale Regelabweichung $\max( \cdot )$ der geregelten Stößelfreiheitsgrade beim Taumelschmieden mit spiraler Bewegungsbahn [E9] . . . . .	204
A.2. Übersicht der durch Bayes'sche Optimierung optimierten Hyperparameter und deren mögliche Ausprägungen . . . . .	229
A.3. Durch Bayes'sche Optimierung optimierte Hyperparameter für CNN und NN (Kapitel 5.1.4) . . . . .	230
A.4. Durch Bayes'sche Optimierung optimierte Hyperparameter für CNN und NN (Kapitel 5.1.4) . . . . .	231
A.5. $x_{\text{MQA}}$ in $^{\circ 2}$ auf Trainings- und Testdatensatz (Kapitel 5.1.4) . . . . .	231
A.6. Eingangsgrößen und entsprechende Unsicherheit zur analytischen Berechnung von Rückfederungen nach [BC04] . . . . .	231
A.7. Verwendete Materialien mit dazugehörigen mechanischen Kennwerten [S14] . . . . .	235
A.8. Gewählte Prozessparameter zur Abschätzung der Stempelkraft . . . . .	236
A.9. Einzelteile des Simulationsmodells [S14] . . . . .	237
A.10. Skalierungsfaktoren der Gewichtungsmatrizen bei Anwendung der MPC . . . . .	248
A.11. Einstellungen von Acados-Modell und Optimierer . . . . .	249
A.12. Einstellungen der Acados-Strecke . . . . .	250
A.13. Übersicht über angewandte Algorithmen und die Art sowie Anzahl genutzter Bewertungsfunktionen und Entscheidungsstrategien . . . . .	251
A.14. Hyperparameter SAC-Algorithmus . . . . .	253
A.15. Hyperparameter TD3-Algorithmus . . . . .	254
A.16. Hyperparameter DDPG-Algorithmus . . . . .	255
A.17. Hyperparameter PPO-Algorithmus . . . . .	256
A.18. Hyperparameter TRPO-Algorithmus . . . . .	256



A.19.Hyperparameterkombinationen des SAC-Algorithmus zur Optimierung der Stauchtrajektorie (E = Entropie) . . . . . 257

A.20.Hyperparameterkombinationen des SAC-Algorithmus zur Optimierung der Taumelschmiedetrajektorie (E = Entropie) . . . . . 258