

Einsatz von Deep Learning zur orts aufgelösten Beschreibung von Bauteileigenschaften

Christopher Sauer, Christof Küstner, Benjamin Schleich, Sandro Wartzack

*Lehrstuhl für Konstruktionstechnik (KTmfk);
Friedrich-Alexander-Universität Erlangen-Nürnberg*

Abstract

Within the Transregional Collaborative Research Centre 73 (SFB/TR 73) a self-learning engineering workbench (SLASSY) is being developed. SLASSY assists product developers in designing sheet-bulk metal formed (SBMF) parts by computing product properties based on given product and process characteristics. SLASSY enables product developers to evaluate the manufacturability of their current part design. For this, SLASSY uses data from manufacturing experts to create metamodels. Currently, it can handle product properties which apply for a whole part variant (on whole part level), for instance the minimum form filling degree. The further development of the SBFM manufacturing technology requires the consideration of the product properties in higher detail (on local level). This requires a higher data density, that is, data for each part variant and product property need to be acquired on every point of interest. Due to the increased amount of data, the currently used data mining algorithms in SLASSY for creating the metamodels cannot be reused. To face this challenge, deep learning algorithms are utilized which are good in processing big data. In this contribution, two approaches for the use of deep learning to compute product properties on local level are presented.

Keywords: product properties, deep learning, data mining, neural networks

1 Einleitung und Motivation

Deep Learning ist ein sehr erfolgreicher Ansatz aus dem Bereich des maschinellen Lernens, welcher die Entwicklung von künstlicher Intelligenz ein Stück weiter bringt. Von Deep Learning wird unter anderem gesprochen, wenn künstliche neuronale Netze mit mehr als einer versteckten Schicht eingesetzt werden. So schlug im Jahr 2017 der Deep Learning Algorithmus von Google DeepMind, genannt AlphaGo den weltbesten Go-Spieler Ke Jie [1]. Go ist ein 2500 Jahre altes chinesisches Brettspiel, bei dem zwei Spieler abwechselnd schwarze und weiße Steine legen, um ihren Gegner mit den eigenen Steinen einzukreisen. Um die Bedeutung des Siegs von AlphaGo zu verdeutlichen, kann der Sieg des Schachcomputers Deep Blue im Jahr 1997 über den damalige Schachweltmeister herangezogen werden. Deep Blue war dem Menschen überlegen, da zu jedem Zeitpunkt im Spiel alle sinnvollen Züge bis zum Sieg sekundenschnell vorausberechnet wurden [2]. Das Spiel Go besitzt allerdings eine wesentlich höhere Spielbaum-Komplexität (mögliche Züge bis zum Sieg) als Schach, welche in heutigen Computern nicht ansatzweise abgebildet werden kann. Aus diesem Grund verfolgte AlphaGo einen anderen Ansatz: Anstatt alle möglichen Spielzüge wie bisher vorauszuberechnen, lernte AlphaGo durch datengetriebene Ansätze des Deep Learning das Spielen von Go. Neben dem Spielen von Go kann Deep Learning in vielen weiteren Bereichen eingesetzt werden. So wird es vor allem verstärkt in der Bild- und Spracherkennung namhafter Technologiekonzerne wie Google, Amazon oder Apple eingesetzt, oder im Moment sehr populär in Form des Neural Artistic Style Transfer. Dabei wird zuerst ein tiefes künstliches neuronales Netz auf den Malstil eines Künstlers trainiert, wie z. B. in Bild 1. Anschließend kann es auf Basis eines beliebigen Fotos ein neues Bild im Stil des Malers erschaffen.



Bild 1: Leistungsfähigkeit der Deep Learning Ansätze beim Übertragen eines Malstils auf eine Fotovorlage (hier: Vincent van Gogh – „Sternennacht“)

Im Rahmen des Sonderforschungsbereichs Transregio 73 der Deutschen Forschungsgemeinschaft (DFG) wird im Teilprojekt B1 zurzeit das selbstlernende Assistenzsystem SLASSY entwickelt, das die Produktentwickler bei der Entwicklung von blechmassivumgeformten Bauteilen unterstützt. SLASSY berechnet hierbei die Eigenschaften auf Basis der Eingaben (Merkmale) der Produktentwickler eines gesamten Bauteils, z. B. den Formfüllungsgrad auf Basis der definierten Bauteilmerkmale (z.B. Geometrie des Bauteils). Diese werden vom Produktentwickler benötigt, um die Fertigbarkeit des Bauteils zu bewerten. SLASSY nutzt zur Berechnung der Eigenschaften einer Bauteilvariante Metamodelle, welche auf Basis von numerischen und experimentellen Versuchsdaten der Fertigungsexperten unter Zuhilfenahme der Methoden des Data-Minings erzeugt werden. Aufgrund der Weiterentwicklung der Blechmassivumformung ist zukünftig eine detailliertere Betrachtung der Eigenschaften notwendig, da das Technologiepotential vollständig ausgeschöpft werden soll. Neben der Eigenschaft muss daher auch deren Position auf einer Bauteilvariante im Datensatz erfasst werden. Die Durchführung einer orts aufgelösten Berechnung von Bauteileigenschaften für verschiedene Bauteilvarianten, z. B. lokaler Umformgrad einer Bauteilvariante, erfordert demzufolge eine größere Datendichte. Die orts aufgelöste Berechnung ist mit den klassischen Data-Mining Methoden aufgrund der höheren Komplexität der Daten nur eingeschränkt möglich. Einen Lösungsansatz hierfür bieten die Methoden aus dem Bereich des Deep Learning, welche auf die Verarbeitung von großen Datensätzen spezialisiert sind. [3] In diesem Beitrag werden zwei Ansätze vorgestellt, mit denen der Einsatz von Deep Learning zur orts aufgelösten Beschreibung von Bauteileigenschaften ermöglicht wird. Hierdurch werden dem Produktentwickler wichtige orts aufgelöste Informationen für die Beurteilung der Fertigbarkeit bereitgestellt. Der Vorteil gegenüber dem bestehenden Vorgehen ist ein Zeit- und Kostenersparnis durch die Nutzung von orts aufgelösten Metamodellen, da für die Beurteilung einer Bauteilvariante keine neuen experimentellen oder numerischen Versuche durchgeführt werden müssen.

2 Hintergrund und Stand der Forschung

2.1 Blechmassivumformung als Anwendungskontext

Das übergeordnete Ziel des Sonderforschungsbereichs SFB/TR73 ist die Entwicklung eines neuen Fertigungsverfahrens, der Blechmassivumformung. Hierbei werden blechumgeformte Bauteile mit eng tolerierten Funktionselementen am Blechrand versehen (s. Bild 2). Zur Herstellung werden Ansätze aus der Massivumformung am Blechrand eingesetzt. Die Herausforderung für die Fertigungstechnologen liegt in der Überlappung von zwei- und dreiaxigen Dehnungs- und Spannungszuständen [4]. Blechmassivumgeformte Bau-

teile werden in Haupt- und Nebenformelemente untergliedert. Ein Blechmassivumgeformtes Bauteil besteht immer aus einem Hauptformelement und einem oder mehreren, verschiedenen Nebenformelementen. [5]

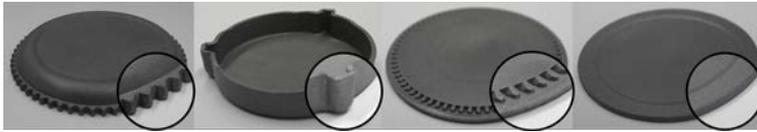


Bild 2: Drei durch Blechmassivumformung hergestellte Bauteile und ein Tailored Blank (ganz rechts).

Bild 2 zeigt drei durch Blechmassivumformung hergestellte Bauteile. Daneben ist ein „Tailored Blank“ (ganz rechts) zu finden, diese werden als Halbzeug in der Blechmassivumformung eingesetzt. So wird das in Bild 3 ganz links dargestellte Bauteil mit Hilfe eines solchen Tailored Blanks gefertigt.

2.2 Bauteilsynthese im selbstlernenden Assistenzsystem

Das selbstlernende Assistenzsystem SLASSY verfügt über ein Synthese- und ein Analyse-Werkzeug, mit dessen Hilfe Produktentwickler ein Bauteil entwerfen und anschließend hinsichtlich seiner Eigenschaften analysieren können. Das Synthese-Werkzeug fungiert hierbei wie ein Produktkonfigurator: Die Produktentwickler können das Hauptformelement sowie verschiedene Nebenformelemente auswählen und deren Geometrieparameter verändern. Der Entwurf wird in einem bidirektional angesteuertem CAD-System (Dassault Systèmes CATIA) direkt dargestellt, wodurch die Produktentwickler in ihrer gewohnten Umgebung im Anschluss weiterarbeiten können. Ein kleiner Auszug an möglichen blechmassivumgeformten Bauteilen ist in Bild 3 dargestellt. [4, 5]

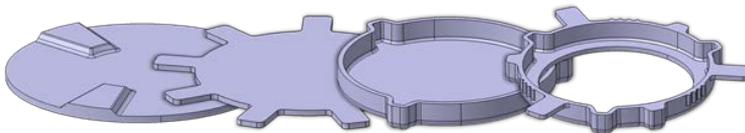


Bild 3: Vier mittels SLASSY erstellte Bauteilentwürfe für die Blechmassivumformung nach [4]

2.3 Analyse: Berechnung von globalen Bauteileigenschaften

Nachdem die Produktentwickler den Entwurf im Synthese-Werkzeug abgeschlossen haben, werden die Geometriemerkmale zur Analyse des erzeug-



ten Entwurfs eingesetzt. Hierzu nutzt das Assistenzsystem SLASSY die Wissensbasis zur Berechnung der Produkteigenschaften für den erzeugten Entwurf (vgl. Bild 4). Die Wissensbasis stellt für jede globale Bauteileigenschaft ein Metamodell zur Verfügung. Die Metamodelle werden aus numerischen und experimentellen Versuchsdaten durch Methoden des Data-Minings im Selbstlernprozess von SLASSY erzeugt (vgl. [4, 5]). Auf Basis der Analyseergebnisse und den Vorgaben der Fertigungsexperten kann der Produktentwickler eine Entscheidung zur Fertigbarkeit eines Bauteilentwurfs treffen. [4]

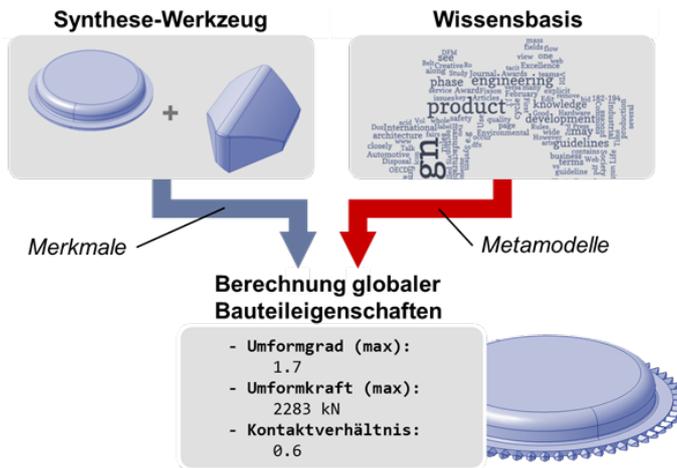


Bild 4: Berechnung globaler Bauteileigenschaften in SLASSY nach [4]

2.4 Deep Learning in der Produktentwicklung

In der Literatur sind sehr unterschiedliche Definitionen zum Begriff „Deep Learning“ zu finden. So wird von Deep Learning gesprochen, wenn künstliche neuronale Netze mit mehreren versteckten Schichten zum Einsatz kommen. Durch diese versteckten Schichten ist das künstliche neuronale Netz in der Lage auch stark nichtlineare Zusammenhänge zu abstrahieren. [3]

Der erfolgreiche Einsatz von Deep Learning im Kontext der Produktentwicklung wird bereits im FEA-Assistenzsystem zur Plausibilitätsprüfung von FEM-Berechnungen gezeigt. Dort wird das Ergebnis einer FEM-Simulation durch Methoden des Deep Learning auf Plausibilität überprüft. [6]

Neben diesem Einsatz werden künstliche neuronale Netze auch im Produktdesign verwendet. Dort werden diese Netze auf für den späteren Nutzer

visuell interessante Stellen trainiert und können diese in neuen Varianten des Produktes vorhersagen. [7]

3 Forschungsproblem: Beschreibung von orts aufgelösten Bauteileigenschaften

Die bisherigen Methoden aus dem Bereich des maschinellen Lernens (Data-Mining) berechnen Eigenschaften für verschieden Varianten eines Bauteils losgelöst von deren Position auf dem Bauteil (Bild 5, links). Die im TR 73 entwickelte Fertigungstechnologie ist mittlerweile so weit fortgeschritten, dass die Fertigungstechnologen die Beurteilung der Fertigbarkeit wesentlich genauer (ortsgebunden) definieren können. So müssen zum Beispiel Aussagen für verschiedene Nebenformelemente an einem Hauptformelement getrennt getroffen werden können. Das bedeutet, dass die Bauteileigenschaften an die Position auf dem Bauteil gebunden sind (Bild 5, rechts). Die Position der Eigenschaften auf dem Bauteil wird durch die bisherigen Ansätze nicht erfasst und bleibt deshalb bei der Beurteilung der Fertigbarkeit unberücksichtigt.

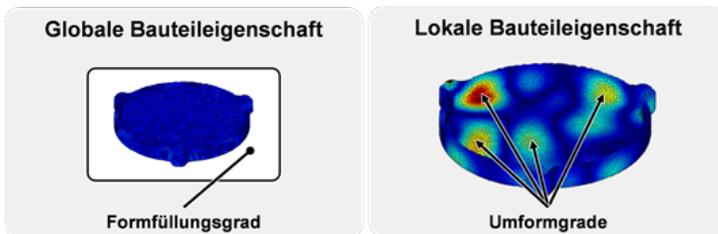


Bild 5: Vergleich globaler (links) und lokaler Bauteileigenschaft (rechts)

Grundsätzlich erfordert die orts aufgelöste Betrachtung der Bauteileigenschaften eine wesentlich höhere Auflösung der Daten, welche neben der Bauteileigenschaft auch den Ort der Eigenschaft erfasst. Die höhere Auflösung und Art der Daten schließt klassische Metamodelle, wie z. B. die lineare Regression aus. Die aktuell in SLASSY eingesetzten Methoden besitzen daher für eine orts aufgelöste Beschreibung einige Nachteile. Falls SLASSY die Überschreitung einer Grenze der Bauteileigenschaften ermittelt, wird der Bauteilentwurf i. d. R. als nicht fertigbar klassifiziert. Die Überschreitung der Grenze kann allerdings an einer nicht relevanten Stelle auf dem Bauteil erfolgen. Nicht relevant sind bspw. Positionen auf dem Bauteil, die in der Nachbearbeitung entfernt werden. Ebenso können durch die fehlende orts aufgelöste Beschreibung wichtige Funktionsflächen nicht gezielt betrachtet werden. Hierdurch wird das Potential der Fertigungstechnologie nicht ausgeschöpft.

4 Konzept zur orts aufgelösten Beschreibung von Bauteileigenschaften

In diesem Kapitel wird ein Konzept vorgestellt, um Bauteileigenschaften orts aufgelöst zu beschreiben. Beginnend mit der Erhebung von orts aufgelösten Daten werden anschließend Methoden des Deep Learning eingesetzt, um orts aufgelöste Metamodelle zu berechnen. Die so erzeugten Metamodelle werden genutzt, um orts aufgelöste Vorhersagen von Bauteileigenschaften zu berechnen.

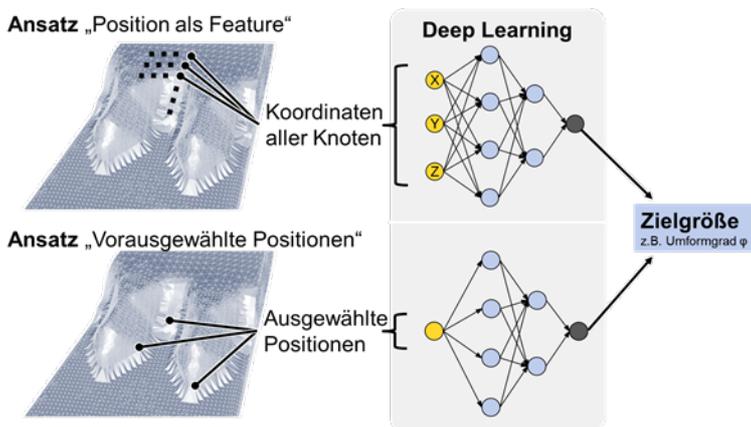


Bild 6: Ansätze zur orts aufgelösten Beschreibung der Daten für den Einsatz von Deep Learning

Der erste Ansatz zur orts aufgelösten Beschreibung „Position als Feature“ (Bild 6, oben) nutzt ein tiefes künstliches neuronales Netz als Metamodell, das eine Bauteileigenschaft, wie zum Beispiel den Umformgrad an jeder Position beschreibt.

Der zweite Ansatz zur orts aufgelösten Beschreibung „Vorausgewählte Positionen“ (Bild 6, unten) bindet Produktentwickler im vornherein direkt mit ein, um den Aufwand für die Datenerhebung zu minimieren. Hierbei werden Positionen von Interesse für die spätere Analyse vorher ausgewählt und dann durch ein Metamodell abgebildet. So wird das künstliche neuronale Netz nur mit den ausgewählten Datensätzen trainiert und nicht mit den gesamten vorhandenen Daten wie im Ansatz „Position als Feature“. Dadurch kann Rechenkapazität und Speicherplatz eingespart werden und die Produktentwickler erhalten eine Aussage bezüglich der orts aufgelösten Bauteileigenschaft in kürzerer Rechenzeit.

4.1 Erhebung der orts aufgelösten Daten

Bei der Erhebung von orts aufgelösten Daten ist eine Unterscheidung zwischen den im vorherigen Abschnitt vorgestellten Ansätzen zu treffen. Für Ansatz „Position as Feature“ genügt es, die Daten - wie zum Beispiel den Umformgrad - verknüpft mit den entsprechenden Koordinaten strukturiert in einer Datei abzulegen. Für die Metamodelle werden dann alle vorhandenen Daten verwendet. So werden alle Varianten der Parameterstudie in einer großen Punktwolke zusammengeführt und das Metamodell auf den gesamten Datensatz trainiert. Hierfür sind eine höhere Speicherkapazität und später mehr Rechenkapazität notwendig.

Aufgrund der für jede Variante der Parameterstudie veränderten Merkmalskonfiguration sind für den Ansatz „Vorausgewählte Positionen“ die gewünschten Punkte entsprechend zu verfolgen, da die Punkte in den einzelnen Varianten der Parameterstudie aufgrund der veränderten Geometrie wandern. Um hier eine lokal höhere Auflösung der Daten zu erzielen sind Detektionsmethoden notwendig. Für die Verfolgung der Punkte über die Varianten hinweg sind daher zwei Algorithmen denkbar, diese werden im Folgenden dargestellt. Da bei dem Ansatz „Vorausgewählte Positionen“ weniger Daten benötigt werden ist dieser Ansatz auch mit weniger Rechenkapazität realisierbar.

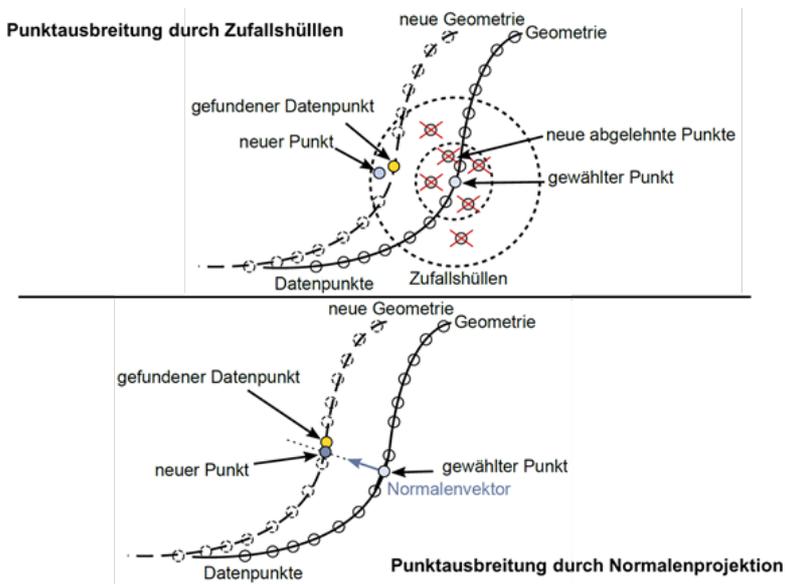


Bild 7: Entwickelte Algorithmen der Punktausbreitung

Bei der Punktausbreitung durch Zufallshüllen (Bild 7, oben) werden um den vorher gewählten Punkt Hüllen gebildet, in denen eine zufällig Punktauswahl stattfindet. Wird nach einer gewissen Anzahl an Versuchen kein Netzknoten der äußeren Hülle der Geometrie getroffen, vergrößert sich der Radius der Zufallshülle. Dies wird solange durchgeführt bis ein Oberflächenknoten gefunden wurde (Random hulls). Der zweite Algorithmus, die Punktausbreitung durch Normalenprojektion (Bild 7, unten) nutzt den Normalenvektor des Dreiecks auf dem der vorher gewählte Punkt liegt, so wird dieser solange an den gewählten Punkt projiziert, bis ein weiterer Knoten der Oberfläche in der nächsten Geometrie der Parameterstudie gefunden wurde (Normal shooting).

4.2 Training des orts aufgelösten Metamodells

Je nach Erfahrungshintergrund der Produktentwickler ist die Variante „Vorausgewählte Positionen“ der Variante „Position als Feature“ vorzuziehen, da zu erwarten ist, dass sie wesentlich weniger Rechen- und Trainingsaufwand für die Metamodelle benötigt. Die Produktentwickler benötigen für den zweiten Ansatz wesentlich weniger Daten, da nicht die gesamte Geometrie der einzelnen Varianten berücksichtigt werden muss. Sind die Daten aus dem FEM-Datensatz extrahiert, kann das Metamodell trainiert werden. Als Training wird dabei das Lernen aus den Daten mithilfe der Ansätze des Deep Learning bezeichnet. Während des Trainingsprozesses wird der Ausgabefehler des künstlichen neuronalen Netzes anhand der Knotengewichte minimiert. Die Knotengewichte der einzelnen Neuronen stellen dabei die zu optimierenden Größen dar. Das Metamodell wird mit Hilfe eines Gradientenabstiegsverfahrens und der Fehlerrückpropagation optimiert [3]. Die entsprechenden künstlichen neuronalen Netze können über ein Deep Learning Framework im Rechner abgebildet werden; dieses muss jedoch das Training und die Vorhersage anhand entsprechender Daten für beide Varianten unterstützen. Grundsätzlich führt hierfür eine Vergrößerung der Datenbasis zu einer Verbesserung des Deep Learning Modells hinsichtlich seiner Vorhersagequalität, da in den Daten vorhandene Muster besser erkannt werden und sich so innerhalb des künstlichen neuronalen Netzes verfestigen können. Gefahr dabei ist jedoch eine Überanpassung des künstlichen neuronalen Netzes an die Eingangsdaten. Damit ist gemeint, dass das künstliche neuronale Netz den Datensatz zwar in hoher Güte vorhersagt, jedoch für die Vorhersage von unbekanntem Daten eine schlechtere Vorhersagequalität aufweist [3].

4.3 Einsatz von orts aufgelösten Metamodellen

Nach dem Training ermöglicht es das Metamodell anhand der Eingangsgrößen (z. B. Position) die Vorhersage der entsprechenden Eigenschaften

(z. B. Umformgrad) verschiedener Bauteilvarianten. Dabei sind die Eingangsgrößen immer von den vorher durch die Produktentwickler festgelegten Merkmalen abhängig. So kann zum Beispiel der Umformgrad an verschiedenen Positionen auf dem Bauteil und für verschiedene Varianten des Bauteils berechnet werden. Soll nur eine Aussage zu einem konkreten Ort getroffen werden, bietet sich hierfür der Ansatz „Vorausgewählte Positionen“ an. Ist hingegen eine globale Vorhersage nötig ist der Ansatz „Position als Feature“ zu verwenden. Dabei spielen Rechenzeit und Speicherplatz eine wichtige Rolle, so ist grundsätzlich für den Ansatz „Vorausgewählte Positionen“ weniger Speicherplatz und Rechenzeit notwendig um eine Vorhersage zu generieren. Diese Vorhersage erfolgt für beide Ansätze „Position als Feature“ und „Vorausgewählte Positionen“ über die Eingabe der gewünschten Koordinaten auf der Bauteilvariante, das Metamodell gibt dann die entsprechende orts aufgelöste Bauteileigenschaft über eine Textausgabe zurück. Die Orte können direkt auf der Geometrie über eine GUI ausgewählt werden, die Ausgabe der orts aufgelösten Bauteileigenschaft erfolgt dann textuell. Durch diese Ausgabe können Aussagen über die Fertigbarkeit des Bauteilentwurfs getroffen werden.

5 Anwendungsbeispiel: Sperrverzahnung eines Getriebesynchronrings

Die Datenbasis für diesen Beitrag bildet eine numerische Parameterstudie einer blechmassivumgeformten Sperrverzahnung eines Getriebesynchronrings [8, 9]. Sie umfasst 16 Analysen und bildet damit die Grundlage für ein orts aufgelöstes Metamodell. Aufgrund des verwendeten Latin-Hypercube-Samplings der Parameterstudie, wird der Entwurfsraum auch in seinen Rändern hinreichend genau abgebildet [10]. Ausgehend von der numerischen Parameterstudie werden ein oder mehrere Metamodelle mit Hilfe der Python Bibliothek *Keras* trainiert. Die Metamodelle stellen ein generalisiertes Ersatzmodell der Daten zu den Bauteilvarianten dar. Im Rahmen der Datenvorbereitung ist zuerst ein Pre-Processing durchzuführen, bei diesem müssen die Daten aus dem Ergebnisformat der FEM-Software in Textdateien übersetzt werden. Hierzu wurde die Python Schnittstelle der Software MSC Simufact.Forming genutzt. Über die Python Bibliothek *PY_POST* werden die erzeugten Ergebnisdateien der Parameterstudie zur Extraktion der relevanten Daten genutzt. Exportiert werden jeweils die entsprechenden Netzknotten der einzelnen FEM-Analysen. An den Knoten werden die gewünschten orts aufgelösten Bauteileigenschaften ausgelesen und in einer csv-Datei gespeichert. In diesem Anwendungskontext wurde als orts aufgelöste Bauteileigenschaft der Umformgrad ausgelesen.

Anhand des R²-COP (Coefficient of optimal prognosis) wurde die Vorhersagequalität der Deep Learning Metamodelle ermittelt [11]. Es zeigt sich eine durchgehend hohe Qualität der Vorhersage, so sind die ermittelten R²-COP Werte durchgängig im Bereich um 90% (je höher desto genauer das Metamodell). Grundsätzlich können Produktentwickler für eine schnelle gezielte Vorhersage zum Ansatz „Vorausgewählte Positionen“ greifen, da dort mit wesentlich geringerem Zeitaufwand zu rechnen ist. Wird ein vollständiges Vorhersagemodell der Geometrie benötigt, bspw. für nachfolgende Optimierungsschritte, sollte der Ansatz „Position als Feature“ genutzt werden.

6 Zusammenfassung und Ausblick

In diesem Beitrag wurden zwei Ansätze „Position als Feature“ und „Vorausgewählte Positionen“ vorgestellt, durch die sich Bauteileigenschaften orts aufgelöst beschreiben lassen. Hierdurch sind die methodischen Grundvoraussetzungen gelegt, um numerische oder experimentelle Versuchsdaten orts aufgelöst durch Metamodelle zu beschreiben.

Zusammenfassend ist zu sagen, dass durch Deep Learning neue Metamodelle erzeugt werden können, die eine höher aufgelöste Beschreibung bei hinreichender Genauigkeit zulassen. So zeigen die vorgestellten Ansätze für die Zukunft neue Möglichkeiten auf, Bauteileigenschaften orts aufgelöst zu beschreiben. Die durch diesen Beitrag erarbeiteten Grundlagen, können nun so erweitert werden, dass sie direkt im Assistenzsystem SLASSY genutzt werden können. So ist es denkbar, dass gewünschte ortal aufgelöste Größe in eine ingenieurgerechtere Darstellung zum Beispiel über Falschfarbenbilder gebracht werden kann.

Danksagung

Die Autoren danken der Deutschen Forschungsgemeinschaft (DFG) für die Förderung des Teilprojekts B1 „Entwicklung eines selbstlernenden Assistenzsystems“ im Rahmen des Sonderforschungsbereiches Transregio 73.

Literatur

- [1] N.N.: "The Future of Go Summit: Legendary players and DeepMind's AlphaGo explore the mysteries of Go together". URL: <https://events.google.com/alphago2017/>. Aufgerufen am: 21.06.2017.
- [2] Newborn, M.: "Kasparov versus Deep Blue: Computer chess comes of age". Springer Science & Business Media, 2012.

-
- [3] Witten, I.; Frank, E.; Hall, M.; Pal, C.: "Data Mining: Practical machine learning tools and techniques". Morgan Kaufmann, 2017.
- [4] Wartzack, S.; Sauer, C.; Küstner, C.: "What does Design for Production mean? – From Design Guidelines to Self-learning Engineering Workbenches". In: Meyer, A.; Schirmeyer, R.; Vajna, S. (Hrsg.) Proceedings of the 11th International Workshop on Integrated Design Engineering, 5–7 April 2017. Universität Magdeburg Lehrstuhl für Maschinenbauinformatik, Magdeburg, 2017.
- [5] Breitsprecher, T.; Wartzack, S.: "Architecture and realization of a self-learning engineering assistance system for the use within sheet-bulk metal forming". In: Hansen, P. K.; Rasmussen, J.; Jørgensen, K. A.; Tollestrup, C. (Hrsg.) DS 71: Proceedings of NordDesign 2012, the 9th NordDesign conference, 22–24 August 2012. Design Society, Aalborg, 2012.
- [6] Sprügel, T.; Kestel P.; Wartzack S.: "FEA-Assistenzsystem–Plausibilitätsprüfung für Finite-Elemente-Simulationen mittels sphärischen Detektorflächen." DFX 2016: Proceedings of the 27th Symposium Design for X, 5-6 October 2016, Jesteburg, Germany. 2016.
- [7] Pan, Y et al.: "A Quantitative Model for Identifying Regions of Design Visual Attraction and Application to Automobile Styling." Proceedings of the 2016 International Design Conference. 2016.
- [8] Hetzner, H. et al. "Improved sheet bulk metal forming processes by local adjustment of tribological properties." Journal of Manufacturing Science and Engineering 133.6. 2011.
- [9] Breitsprecher, T. et al. "Acquisition of Heuristic Knowledge for the Prediction of the Frictional Behavior of Surface Structures Created by Self-Excited Tool Vibrations." Key Engineering Materials. Vol. 504. Trans Tech Publications. 2012.
- [10] McKay, M.; Beckman R.; Conover, W.: "Comparison of three methods for selecting values of input variables in the analysis of output from a computer code." Technometrics 21.2 (1979): 239-245.
- [11] Most, T.; Will, J.: "Metamodel of Optimal Prognosis-an automatic approach for variable reduction and optimal metamodel selection." Proc. Weimarer Optimierungs-und Stochastiktage 5 (2008): 20-21.