

Konzept zur Anwendung von Deep Transfer Learning am Beispiel der Fertigungsvorgangsermittlung

Deep Transfer Learning in der Arbeitsplanung

M. Hussong, M. Glatt, J. C. Aurich

Für die Nutzung von Deep Learning zur Unterstützung der Prozesse innerhalb der Arbeitsplanung wird eine Vielzahl von Daten benötigt. In der industriellen Praxis ist die Aufbereitung solcher Datensätze sehr komplex und mit hohem Aufwand verbunden. Durch die Nutzung von Deep Transfer Learning kann die benötigte Datenmenge reduziert werden. Am Beispiel der Fertigungsvorgangsermittlung wird ein Konzept vorgestellt, das die Anwendung von Deep Transfer Learning innerhalb der Arbeitsplanung ermöglicht.

STICHWÖRTER

Künstliche Intelligenz (KI), Arbeitsorganisation, CAE (Computer Aided Engineering)

1 Motivation

Kürzer werdende Produktlebenszyklen und der Trend zu kundenindividuellen Produkten steigern den Aufwand der Arbeitsplanung im industriellen Umfeld, besonders in Einzel- und Kleinserienfertigung [1]. Vor diesem Hintergrund bietet eine Unterstützung der Arbeitsplanung durch computerbasierte Systeme (englisch: computer aided process planning, CAPP) weitreichende Einsparpotenziale.

Aktuelle Ansätze zur Umsetzung von CAPP-Systemen verwenden meist Methoden des Deep Learning [2]. Die Methoden des Deep Learning sind tiefe künstliche neuronale Netze (englisch: deep artificial neural networks, ANN), die Zusammenhänge in Daten durch Training erfassen können und für Vorhersagen anwendbar machen. Zum Training von ANN wird eine große Menge an Daten benötigt, deren Aufbereitung in der industriellen Praxis sehr komplex und mit einem großen manuellen Aufwand verbunden ist [3]. Um die benötigte Menge an Daten zu reduzieren, kann Deep Transfer Learning (DTL) verwendet werden. Im DTL werden ANN genutzt, um Wissen aus einer Quelldomäne in eine Zieldomäne zu übertragen [4]. Als Quelldomäne können beispielsweise Datensätze mit Bildern alltäglicher Objekte und für die Zieldomäne ein industrieller Datensatz mit Bildern von Bauteilen aus der Produktion genutzt werden [5]. Durch die Kombination an Daten aus Quell- und Zieldomäne kann die benötigte Menge an Daten für die Zieldomäne im Vergleich zum klassischen Training von maschinellen Lernalgorithmen reduziert werden bei gleichzeitiger Erhaltung beziehungsweise Steigerung der Vorhersagegenauigkeit [6, 7].

Deep transfer learning in process planning – A concept for applying deep transfer learning in process planning using the example of manufacturing operations selection

A large amount of data is required for the use of deep learning to support process planning. In industrial practice, the preparation of such data sets is very complex and requires a lot of manual effort. By using deep transfer learning, the required amount of data can be reduced. Therefore, using the example of manufacturing operation selection, a concept is introduced that enables the application of deep transfer learning within process planning.

Um die benötigte Datenmenge für Aufgabenstellungen in der Arbeitsplanung zu reduzieren, wird in diesem Beitrag ein Konzept zur Anwendung von DTL vorgestellt. Dieses Konzept wird beispielhaft an der Fertigungsvorgangsermittlung beschrieben, kann analog aber auch auf andere Aufgabenstellungen der Arbeitsplanung übertragen werden.

In den nächsten beiden Kapiteln werden die Arbeitsplanung und das DTL beschrieben. Gegenstand von Kapitel 3 ist die Beschreibung des Konzepts. Abschließend werden eine Zusammenfassung und ein Ausblick gegeben.

2 Unterstützung der Arbeitsplanung durch CAPP-Systeme

Die Arbeitsplanung bildet den Übergang zwischen der Entwicklung und Fertigung eines Produktes [8]. Die Eingangsgrößen der Arbeitsplanung werden dementsprechend von der Produktentwicklung definiert und umfassen Toleranz-, Oberflächen- und Materialangaben sowie geometrische Formelemente, welche die Gestalt des Bauteils beschreiben [9]. In der industriellen Praxis werden die beschriebenen Größen in Form von 3D-CAD-Modellen oder Technischen Zeichnungen festgelegt, was die Datengrundlage für Entscheidungen in der Arbeitsplanung bildet.

Die Arbeitsplanung kann in Grob- und in Detailplanungsaufgaben aufgeteilt werden. Die Grobplanung umfasst die Bestimmung des Rohmaterials und die Aufgabe der Vorgangsfolgeermittlung. Die Ermittlung der Vorgangsfolge ist grundsätzlich zweigeteilt und bestimmt zuerst alle Vorgänge beziehungsweise Technologien, die für die Fertigung eines Bauteils benötigt

werden (Fertigungsvorgangsermittlung). Anschließend werden die identifizierten Fertigungsvorgänge in eine Reihenfolge überführt, die eine fertigungsgerechte Bearbeitung des Bauteils ermöglicht [8]. Im Anschluss an die Vorgangsfolgeermittlung wird für die definierten Fertigungsvorgänge eine Detailplanung vorgenommen, welche die nachfolgenden Aufgaben umfasst.

Für die identifizierten Fertigungsvorgänge innerhalb der Vorgangsfolgeermittlung werden zunächst Werkzeuge, Vorrichtungen und Halterungen bestimmt. Dabei wird die Anzahl an Einspannvorgängen festgelegt, welche Einfluss auf die Fertigungsdauer des Werkstücks haben. Danach werden die Maschinenparameter, wie etwa die Schnittgeschwindigkeit beim Fräsen, bestimmt. Zusätzlich zu den Maschinenparametern wird der Verfahrensweg des Werkzeugs festgelegt, aus dem sich die gefertigten Geometrien am Werkstück ergeben. Durch die Bestimmung der Einspannungen, der Schnittparameter und des Verfahrenswegs des Werkzeugs lassen sich für die verschiedenen Fertigungsvorgänge die Fertigungszeiten ableiten. Aus den Fertigungszeiten können schließlich die Fertigungskosten für das Bauteil kalkuliert werden.

Für die Unterstützung der genannten Aufgaben der Arbeitsplanung werden CAPP-Systeme eingesetzt, die auf Methoden des Deep Learning basieren. Eingangsgrößen für ein CAPP-System, das auf Methoden des Deep Learning basiert, sind 3D-CAD-Modelle, die analysiert werden, um beispielsweise als Ausgangsgröße die benötigten Fertigungsvorgänge zu identifizieren. So können Arbeitsplanungsaufgaben vereinfacht und teilweise automatisiert werden. Dies führt zur Reduktion von manuellen Aufwänden, was die Durchführung von Aufgaben der Arbeitsplanung beschleunigt, woraus letztlich Kosteneinsparungen resultieren [9].

Zur Anwendung von Methoden des Deep Learning in CAPP-Systemen wird eine große Menge an Daten benötigt, die diversifiziert und für überwachtes Lernen annotiert werden muss. Eine breite Diversifikation der Daten erlaubt auch vereinzelt auftretende Ereignisse mithilfe von ANN zu erfassen und zu analysieren. Für die Arbeitsplanung können somit auch komplexe und außergewöhnliche Geometrien analysiert werden, was zu einem breiten Anwendungsspektrum der ANN führt. In der industriellen Praxis ist die Aufbereitung solcher diversifizierter und annotierter Datensätze sehr komplex und mit großem manuellen Aufwand verbunden [3]. Für die Diversifizierung müssen im Vorfeld der Datenaufbereitung statistische Analysen durchgeführt werden, um auch selten auftretenden Ereignisse zu identifizieren und im Datensatz verteilungsgerecht abzubilden. Hinzu kommt die Annotation der Daten in der Aufbereitungsphase, die für die große Menge an Datenpunkten mit Softwareapplikationen manuell durchgeführt werden muss [10]. Die Anwendung von Transfer Learning bietet die Möglichkeit die Datenmenge und dadurch den Aufwand für die Aufbereitung der Datensätze zu reduzieren und gleichzeitig Deep Learning für CAPP-Systeme zu nutzen.

Erste Ansätze adressieren die Nutzung von Transfer Learning in CAPP-Systemen. *Kamal et al.* verwenden induktives (englisch: inductive) Transfer Learning zur Erkennung von Bauteilfeatures und zur Beschreibung der geometrischen Ähnlichkeit unterschiedlicher 3D-CAD-Modelle [11]. Die Erkennung von Bauteilfeatures zielt darauf ab, die Merkmale in 3D-CAD-Modellen zu ermitteln, die durch einen Fertigungsvorgang bearbeitet werden müssen [12]. *Shi et al.* verwenden DTL zur Erkennung von Features. Hierzu wird ein vortrainiertes ANN von der Quelldomäne

der Bildklassifikation genutzt, um die Bauteilfeatures auf Bildern unterschiedlicher Perspektiven zu erkennen [13]. *Pedireddy et al.* nutzen DTL zur Identifikation von Fräs- und Drehvorgängen in der Zieldomäne. Als Quelldomäne wird ein Datensatz für die Erkennung von Bauteilfeatures verwendet. Die beiden Datensätze für Quell- und Zieldomäne sind synthetisch erstellt [14].

Die beschriebenen Ansätze fokussieren Transfer Learning hauptsächlich auf die Erkennung von Bauteilfeatures. Mit dem in diesem Beitrag vorgestellten Konzept soll ein Vorgehen beschrieben werden, das die Adaption von DTL für weitere Bereiche der Arbeitsplanung ermöglicht. Dies wird am Beispiel der Ermittlung von Fertigungsvorgängen vorgenommen. Auch der Ansatz von *Pedireddy et al.* fokussiert die Erkennung von zwei Fertigungsvorgängen. Im Ansatz von *Pedireddy et al.* werden jedoch synthetisch erstellte Datensätze genutzt, wogegen das Konzept in diesem Beitrag die Verwendung realer 3D-CAD-Modelle aus der Industrie adressiert.

3 Ansätze von Deep Transfer Learning

Transfer Learning ist eine Methode des Maschinellen Lernens, bei dem Wissen aus einer Quelldomäne auf eine Zieldomäne übertragen wird [4]. Findet eine Anwendung von ANN zur Analyse von Quell- beziehungsweise Zieldomäne statt, wird dies als Deep Transfer Learning (DTL) bezeichnet.

Das DTL unterscheidet vier Kategorien: Instanzbasiertes (englisch: instance-based) DTL ergänzt gezielt Datenpunkte aus der Quelldomäne im Datensatz der Zieldomäne und gewichtet diese, um die Datenmenge in der Zieldomäne zu erhöhen. Abbildungsbasiertes (englisch: mapping-based) DTL vereint die Datenmenge aus der Quelldomäne mit der Zieldomäne, um einen großen und diversifizierten Datensatz für das Training der ANN zu erhalten. Gegnerbasiertes (englisch: adversarial-based) DTL basiert auf der Einführung von gegnerbasierten Schichten (englisch: adversarial layers), um Merkmale aus der Quell- und Zieldomäne zu bewerten. Dadurch wird die Zielfunktion um einen zusätzlichen Term erweitert, sodass durch Minimierung der Zielfunktion, Merkmale definiert werden, die eine ähnliche Beschreibung von Quell- und Zieldomäne vornehmen. Netzwerkbasierendes (englisch: network-based) DTL nutzt Teile eines ANN, das auf Basis der Daten der Quelldomäne trainiert wurde, zum Training auf den Daten der Zieldomäne [15].

Netzwerkbasierendes DTL zeigt im Gegensatz zu instanzbasiertem, abbildungsbasiertem und gegnerbasiertem DTL die größte Eignung für die Aufgaben der Arbeitsplanung. Für instanzbasiertes oder abbildungsbasiertes DTL wird die Zieldomäne mit Daten der Quelldomäne angereichert. Dies wäre im Kontext der Arbeitsplanung in der industriellen Praxis mit hohem manuellem Aufwand verbunden, da für die Anreicherung der Zieldomäne künstliche Arbeitspläne erstellt werden müssten, die auf Eingangsdaten der Quelldomäne basieren. Die Verwendung von gegnerbasiertem DTL weist im Gegensatz zu netzwerkbasierendem DTL aufgrund der Analyse von 3D-CAD-Modellen als Eingangsdaten eine größere Komplexität auf. Dies ist vor allem hinsichtlich der Tiefe und Breite des Netzwerks, das für die Analyse von 3D-CAD-Modellen verwendet wird, wesentlich, sodass das folgende Konzept sich auf das netzwerkbasierende DTL fokussiert.

4 Konzeption von Deep Transfer Learning für die Arbeitsplanung

Das Konzept definiert die Anwendung von netzwerkbasierendem DTL für die Arbeitsplanung anhand des Beispiels der Fertigungsvorgangsermittlung. Für die Anwendung des netzwerkbasierenden DTL lassen sich allgemein verschiedene Schritte definieren. Zuerst erfolgt eine Merkmals- und Wissensextraktion aus der Quelldomäne durch Training eines Netzwerks auf einem großen und diversifizierten Datensatz. Durch die Verwendung bereits trainierter Merkmale kann das Modell der Zieldomäne mit einer höheren Abstraktionsebene beginnen, wodurch die für das Training benötigte Datenmenge reduziert und die Leistung verbessert werden kann. Nach der Merkmals- und Wissensextraktion aus der Quelldomäne erfolgt eine Domänenanpassung. Weisen die Datenverteilungen der Domänen große Unterschiede auf, müssen die Quell- und Zieldomäne aneinander angepasst werden.

Anschließend erfolgt die Feinabstimmung des Netzwerks mit der Zieldomäne. Dazu wird das Modell mithilfe des Datensatzes der Zieldomäne trainiert. Dabei werden zuerst die Gewichte der neuen Schichten optimiert, während die Gewichte der vortrainierten Schichten zuerst unverändert bleiben. Nach Optimierung der Gewichte der neuen Schichten, wird ein Training mit einer kleinen Lernrate auf dem Zieldatensatz durchgeführt, bei dem alle Gewichte des ANN optimiert werden. Zum Schluss erfolgt die Bewertung des Modells. Modelle des Deep Transfer Learning sollten grundsätzlich anhand der Leistung bei der Zielaufgabe bewertet werden. Die Leistung sollte mit anderen Ansätzen verglichen werden, vor allem mit dem Training eines Modells, welches von Grund auf für die Zielaufgabe optimiert wurde. Für die endgültige Auswahl des besten Ansatzes können gegebenenfalls auch Zielgrößen wie die Höhe der Rechenressourcen berücksichtigt werden.

Um diese vier Schritte für das netzwerkbasierende DTL anwenden zu können, müssen im Vorfeld eine geeignete Beschreibung für die Kategorisierung von Lernmethoden des Maschinellen Lernens und eine Definition der Quell- und Zieldomäne vorgekommen werden.

Die Zielaufgabe ist die Ermittlung von Fertigungsvorgängen, die in die Kategorie des überwachten Lernens zugeordnet wird. Konkret werden beim überwachten Lernen Ein- und Ausgangsgrößen gegenübergestellt. Dadurch lernen die maschinellen Algorithmen durch Minimierung einer definierten Zielfunktion die Zusammenhänge zwischen Ein- und Ausgangsgrößen innerhalb verschiedener Trainingsepochen und können diese nach dem Training zur Vorhersage auf unbekanntem Eingangsgrößen verwenden. Bei der Ermittlung der Fertigungsvorgänge müssen dementsprechend CAD-Daten als Eingangsgröße und die benötigten Fertigungsvorgänge als Ausgangsgröße vorliegen. Die Zuordnung eines Bauteils zu unterschiedlichen Fertigungsvorgängen kann innerhalb des überwachten Lernens als Klassifikationsaufgabe definiert werden. Die Klassifikationsaufgabe kann entweder als Multi-Label-Klassifikation oder als mehrfache binäre Klassifikation ausgestaltet werden. Die beiden Ansätze unterscheiden sich in der verwendeten Anzahl an ANN. Bei der Multi-Label-Klassifikation wird ein einzelnes ANN zur Vorhersage aller benötigten Fertigungsvorgänge eingesetzt, wohingegen bei einer mehrfachen binären Klassifikation jeweils ein ANN für die Vorhersage eines Fertigungsvorganges eingesetzt wird.

Nach der Definition der Zieldomäne durch Kategorisierung der Ermittlung von Fertigungsvorgängen als Klassifikationsaufgabe innerhalb des überwachten Lernens, wird im nächsten Schritt eine Quelldomäne bestimmt. Als Quelldomänen können ähnliche Aufgaben des Maschinellen Lernens angesehen werden, die bestenfalls ähnliche Eingangsdaten nutzen. Aufgrund der inzwischen großen Vielfalt an frei verfügbaren industriellen 3D-CAD-Datensätzen, wie etwa ABC [16], DMU-Net [17] oder Mechanical Components Benchmark (MCB) [18], bilden diese eine Basis zur Definition von Quelldomänen für das Transfer Learning. Der MCB-Datensatz soll hier als Quelldomäne dienen, da dieser eine ähnliche Klassifikationsaufgabe, wie die Bestimmung von Fertigungsvorgängen, abbildet. Bei diesem Datensatz stehen industriennahe 3D-CAD-Modelle als Eingangsgröße und verschiedene Bauteilklassen, wie beispielsweise Federn, Dämpfer oder Schrauben als Klassifikationsgrößen zur Verfügung.

Für die Analyse von 3D-CAD-Modellen mithilfe von ANN müssen diese transformiert werden. Als Transformation eignen sich beispielsweise Voxel, Punktwolken, Meshes oder projizierte Ansichten. Voxel approximieren die Gestalt eines 3D-CAD-Modells über kleine Quader im Raum und bilden damit als Volumenpixel das Pendant zu Pixel im zweidimensionalen Raum. Punktwolken sind vergleichbar mit dem Voxel-Ansatz, approximieren die Gestalt des Bauteils jedoch mit Punkten im dreidimensionalen Raum. Im Gegensatz dazu bilden Meshes die Oberflächen des Bauteils mit Gitternetzstrukturen bestehend aus Knoten und Kanten ab. Projizierte Ansichten sind Bilder eines Bauteils aus verschiedenen Raumrichtungen.

Zur Analyse von Voxel, Punktwolken, Meshes oder projizierten Ansichten werden oftmals ANN in Form von Convolutional Neural Networks (CNN) eingesetzt, die als Encoder über konvolutionale Schichten (englisch: convolutional layers) und Aggregationsschichten (englisch: pooling layers) die dreidimensionalen Eingangsgrößenstrukturen in kompakte Merkmalsausprägungen überführen. Diese kompakte Darstellung der Merkmalsausprägungen wird anschließend über weitere vollständig verbundene Schichten in die gewünschte Ausgangsgröße der Klassifikation übersetzt.

Die Encoderschichten des CNN leisten die Merkmalsextraktion auf hoher Abstraktionsebene durch Training auf dem Datensatz der Quelldomäne, in diesem Fall des MCB-Datensatzes. Danach werden die extrahierten Merkmale auf der hohen Abstraktionsebene, also den ersten Schichten des ANN, für das Training mithilfe des Datensatzes der Zieldomäne verwendet. Eine Domänenanpassung ist aufgrund der Ähnlichkeit zwischen Quell- und Zieldomäne nur geringfügig notwendig. Lediglich eine weitere Diversifizierung des Datensatzes durch weitere 3D-CAD-Modelle aus Datenquellen wie ABC [16] oder DMU-NET [17] kann durchgeführt werden, um Verteilungsabweichungen zwischen den Datensätzen der Quell- und Zieldomäne zu verringern. Für die Feinabstimmung wird das CNN für die Zieldomäne gebildet, das die Encoderschichten aus dem Training der Quelldomäne übernimmt und mit vollständig verbundenen Schichten ergänzt wird.

Das Training innerhalb der Feinabstimmung ist zweigeteilt. Zuerst werden die Encoderschichten aus der Quelldomäne konstant gehalten und ausschließlich die vollständig verbundenen Schichten optimiert. Im zweiten Schritt werden alle Parameter des CNN optimiert und das Training mit einer kleinen Lernrate durchgeführt. Die Bewertung erfolgt anhand typischer Zielgrößen

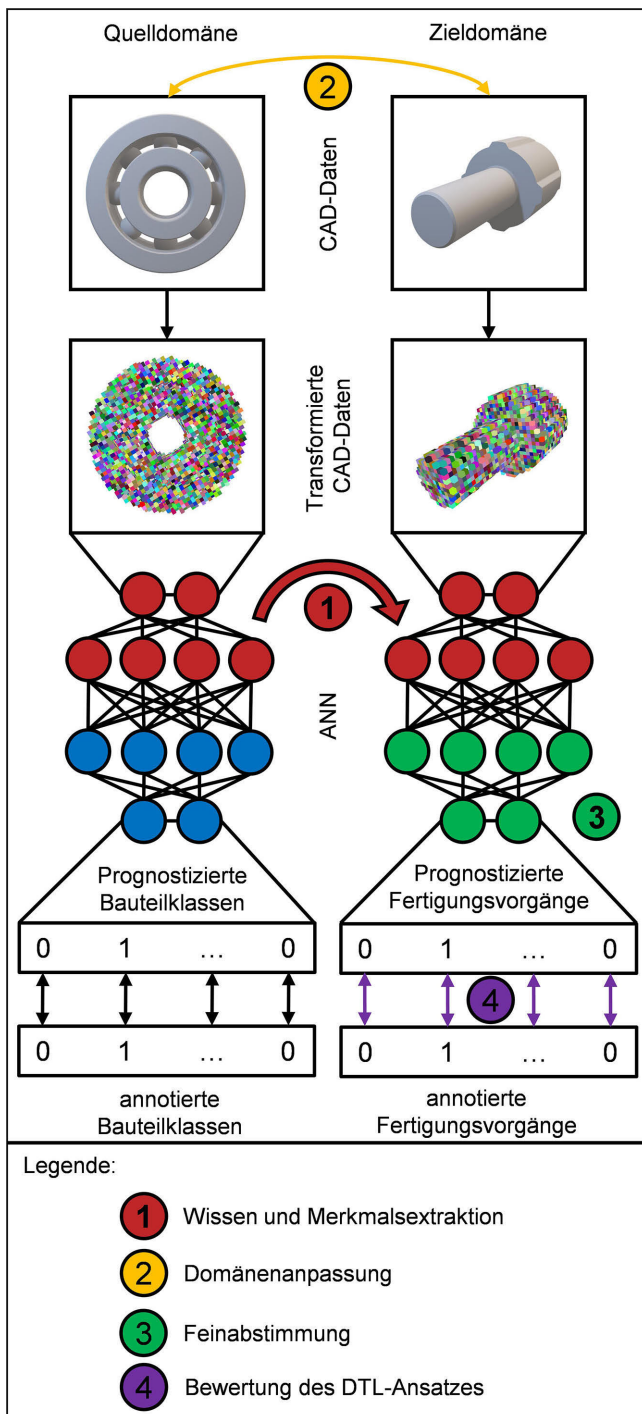


Bild 1. Konzept zur Ermittlung von Fertigungsvorgängen mittels Deep Transfer Learning. Grafik: RPTU Kaiserslautern

für Klassifikationsaufgaben wie beispielsweise einer Konfusionsmatrix. Das Bild illustriert das Konzept zur Anwendung von netzwerkbasierter DTL für die Fertigungsvorgangsermittlung.

Zusammenfassend kann netzwerkbasiertes DTL in der Arbeitsplanung eingesetzt werden, um die benötigte Menge an annotierten Industriedaten zu verringern, indem ML-Modelle auf großen und diversifizierten Datensätzen mit 3D-CAD-Modellen vortrainiert werden. Dadurch können die ML-Modelle bereits Wissen und Merkmale aus der Quelldomäne extrahieren, was anschließend für die Zieldomäne angewendet werden kann. Dem-

entsprechend benötigt die Zieldomäne eine deutlich geringere Anzahl an Daten, was die Aufbereitung solcher Datensätze deutlich vereinfacht und beschleunigt.

5 Zusammenfassung und Ausblick

In diesem Beitrag wurde ein Konzept zur Anwendung von DTL in der Arbeitsplanung am Beispiel der Fertigungsvorgangsermittlung dargestellt. Netzwerkbasierter DTL in der Arbeitsplanung ermöglicht demnach die benötigte Menge an annotierten Industriedaten zu verringern, indem ML-Modelle auf großen und diversifizierten Datensätzen mit 3D-CAD-Modellen vortrainiert werden. Dadurch können die ML-Modelle bereits Wissen und Merkmale aus der Quelldomäne extrahieren, was anschließend für die Zieldomäne angewendet werden kann. Dementsprechend benötigt die Zieldomäne eine deutlich geringere Anzahl an Daten, was die Aufbereitung solcher Datensätze deutlich vereinfacht und beschleunigt.

Zukünftig wird das vorgestellte Konzept durch Training der ANN auf Basis von Voxel, Punktwolke, Mesh und projizierte Ansichten umgesetzt und ein Vergleich der unterschiedlichen Repräsentation der 3D-CAD-Modelle für die Ermittlung von Fertigungsvorgängen vorgenommen. Weiterhin wird eine Erweiterung des Konzepts auf andere Bereiche der Arbeitsplanung durch eine geeignete Problemdefinition im Kontext von Maschinellem Lernen angestrebt.

FÖRDERHINWEIS

Die Autoren danken dem Bundesministerium für Bildung und Forschung (BMBF) für die finanzielle Unterstützung im Rahmen des Forschungsvorhabens „Unterstützung der Vorgangsfolgeermittlung in der Arbeitsplanung durch maschinelles Lernen“ (FKZ 01IS21010).

Literatur

- [1] Schuh, G.; Prote, J.-P.; Luckert, M. et al.: Automatisierung in der Arbeitsplanung. Zeitschrift für wirtschaftlichen Fabrikbetrieb 112 (2017) 12, S. 827–830
- [2] Natarajan, K.; Gokulachandran, J.: Application of artificial neural network techniques in computer aided process planning—a review. International Journal of Process Management and Benchmarking 11 (2021) 1, pp. 80–100
- [3] Tercañ, H.; Guajardo, A.; Meisen, T.: Industrial Transfer Learning: Boosting Machine Learning in Production. 2019 IEEE 17th International Conference on Industrial Informatics (INDIN), Helsinki, Finland, 2019, pp. 274–279, doi: 10.1109/INDIN41052.2019.8972099
- [4] Torrey, L.; Shavlik, J.: Transfer Learning. In: Olivas, E. S.; Guerrero, J. D. M.; Martínez-Sober, M. (eds): Handbook of research on machine learning applications and trends: algorithms, methods, and techniques. New York: IGI Global 2009, pp. 242–264
- [5] Ruediger-Flore, P.; Glatt, M.; Hussong, M. et al.: CAD-based data augmentation and transfer learning empowers part classification in manufacturing. The International Journal of Advanced Manufacturing Technology 125 (2023) 11–12, pp. 5605–5618
- [6] Zhuang, F.; Qi, Z.; Duan, K. et al.: A Comprehensive Survey on Transfer Learning. Journal of Big Data 3 (2020) 1, pp. 1–40
- [7] Eversheim, W.: Organisation in der Produktionstechnik Heidelberg: Springer 2002
- [8] Wiendahl, H.-P.; Wiendahl, H.-H.: Betriebsorganisation für Ingenieure. München: Carl Hanser Verlag 2019

- [9] Al-wswasi, M.; Ivanov, A.; Makatsoris, H.: A survey on smart automated computer-aided process planning (ACAPP) techniques. *The International Journal of Advanced Manufacturing Technology* 97 (2018) 1–4, pp. 809–832
- [10] Sager, C.; Zschech, P.; Kühl, N.: labelCloud: A lightweight domain-independent labeling tool for 3D object detection in point clouds. *arXiv preprint arXiv:2103.04970* (2021), doi.org/10.48550/arXiv.2103.04970
- [11] Kamal, N. S.; Barathi Ganesh, H. B.; Sajith Variyar, V. V. et al.: Geometry Based Machining Feature Retrieval with Inductive Transfer Learning. *Intelligent Data Engineering and Analytics: Proceedings of the 9th International Conference on Frontiers in Intelligent Computing: Theory and Applications (FICTA 2021)* (2021), pp. 31–39
- [12] Shi, Y.; Zhang, Y.; Xia, K. et al.: A Critical Review of Feature Recognition Techniques. *Computer-Aided Design and Applications* 17 (2020) 5, pp. 861–899
- [13] Shi, P.; Qi, Q.; Qin, Y. et al.: A novel learning-based feature recognition method using multiple sectional view representation. *Journal of Intelligent Manufacturing* 31 (2020) 5, pp. 1291–1309
- [14] Peddireddy, D.; Fu, X.; Shankar, A. et al.: Identifying manufacturability and machining processes using deep 3D convolutional networks. *Journal of Manufacturing Processes* 64 (2021), pp. 1336–1348
- [15] Tan, C.; Sun, F.; Kong, T. et al.: A Survey on Deep Transfer Learning. *arxiv.org/abs/1808.01974* (2018), doi.org/10.48550/arXiv.1808.01974 oder doi.org/10.1007/978-3-030-01424-7_27
- [16] Koch, S.; Matveev, A.; Jiang, Z. et al.: ABC: A Big CAD Model Dataset For Geometric Deep Learning. *arXiv:1812.06216v2* (2018), doi.org/10.48550/arXiv.1812.06216
- [17] Dekhtiar, J.; Durupt, A.; Bricogne, M. et al.: Deep learning for big data applications in CAD and PLM – Research review, opportunities and case study. *Computers in Industry* 100 (2018), pp. 227–243
- [18] Kim, S.; Chi, H.; Hu, X. et al.: A Large-Scale Annotated Mechanical Components Benchmark for Classification and Retrieval Tasks with Deep Neural Networks. In: Vedaldi, A.; Bischof, H.; Brox, T. et al. (Hrsg.): *Computer Vision – ECCV 2020*. Cham: Springer International Publishing 2020, pp. 175–191



Marco Hussong, M.Sc. 

Foto: RPTU Kaiserslautern FBK

Moritz Glatt, M.Sc. 

Prof. Dr.-Ing. **Jan C. Aurich** 

Rheinland-Pfälzische Technische Universität
Kaiserslautern-Landau (RPTU)
Lehrstuhl für Fertigungstechnik
und Betriebsorganisation [FBK]
Gottlieb-Daimler-Str. 42, 67663 Kaiserslautern
Tel. +49 631 / 205-2618
marco.hussong@mv.rptu.de
<https://mv.rptu.de/fgs/fbk>

