

Ein Konzept zur Nutzung von Reinforcement Learning zur Parametrisierung von CT-Messungen

CT-Messungen automatisieren

E. Blum, F. Stamer, G. Lanza

ZUSAMMENFASSUNG Industrielle Computertomographie erfordert umfassendes Expertenwissen. In diesem Beitrag wird ein Konzept vorgestellt, um die Parametrisierung von Messungen durch Reinforcement Learning zu automatisieren. Innerhalb einer Simulation sollen Agenten Messstrategien wie das Auslegen zeitminimaler Messungen erlernen. Auch wenn aktuelle virtuelle CTs realitätsnahe Messungen erlauben, verhindert die Laufzeit aktueller Simulationsumgebungen noch den Einsatz als effiziente Trainingsumgebung.

STICHWÖRTER

Reinforcement Learning, virtuelles CT, Simulation

1 Einleitung und Motivation

Die industrielle Computertomographie (CT) ermöglicht die zerstörungsfreie Prüfung von inneren Strukturen sowie metrologische Messungen von Bauteilen und bietet dadurch Vorteile gegenüber klassischen Messmaschinen wie taktile Koordinatenmessgeräte [1]. Der breite Einsatz als prozessnahe Messtechnik wird derzeit aufgrund des zugrunde liegenden Komplexitätsgrads bei der Durchführung von Messungen sowie der langen Messdauer verhindert [2]. Besonders die Auslegung von Messungen verlangt umfangreiches Wissen und Erfahrung, um die große Zahl an konfigurierbaren Parametern eines CTs zielgerichtet auszuliegen. Aktuelle Unterstützungssysteme zur Optimierung von CT-Messungen konzentrieren sich meist auf einzelne Parameter, wie die Positionierung des Bauteils innerhalb des CT [3], die Anzahl der erzeugten Röntgenprojektionen [2] oder die Optimierung der Messtrajektorie [4]. Andere Ansätze setzen auf den Aufbau großer Datensätze von unterschiedlichen CT Messungen, um dieses Wissen auf noch nicht vermessene Bauteile zu externalisieren [5]. Ansätze zur automatischen Optimierung aller Parameter einer Messung sind aktuell nicht existent, wodurch Messungen stets durch Zutun menschlichen Wissens ausgelegt werden müssen.

Zur autonomen Parametrisierung von visuellen robotergeführten Messsystemen hat sich Reinforcement Learning (RL) bewährt. In [6] wird mittels RL die Pose eines Vertikalknickarmroboters sowie die Ausrichtung einer montierten 3D RGBD-Kamera autonom auf ein zu vermessenes Bauteil angepasst, um eine Bauteiloberfläche mittels einer minimalen Anzahl an Kameraposen vollumfänglich zu befunden. Durch das Training von RL-Agenten in einer Simulation kann eine Generalisierbarkeit des Ansatzes erreicht werden, die es dem Messsystem erlaubt sich autonom auf Lageänderungen oder andere Varianten eines

Automating CT measurements

ABSTRACT Industrial computed tomography requires extensive expert knowledge. This paper presents a concept to automate the parameterization of measurements by reinforcement learning. Within a simulation, agents are supposed to learn measurement strategies such as the design of time-minimal measurements. Even though current virtual CTs allow realistic measurements, their runtime currently still prevents their use as an efficient training environment.

Produktes anzupassen. Mit dem verwandten Problem des produktspezifischen Parametrisierens von Messaufgaben könnte RL auch Potenziale für die autonome Auslegung von CT-Messungen besitzen. In diesem Beitrag wird daher ein Konzept vorgestellt, wie sich RL-Agenten auch zur autonomen Parametrisierung von CT-Messungen einsetzen lassen.

2 Grundlagen industrieller CTs und Herausforderungen bei der Durchführung von Messungen

Zur Durchführung einer CT-Messung sind eine Vielzahl an Parameter einzustellen, die gegenseitige Wechselwirkungen besitzen und das Resultat einer Messung beeinflussen. Diese Parameter lassen sich in software- und hardwareseitige einteilen. Hardwareseitig gehören dazu die Bauteilpositionierung auf dem kinematischen System und der metallische Vorfilter. Softwareseitig können Parameter für die Röntgenröhre (Spannung, Stromstärke), den Detektor (Integrationszeit, Verstärkung, Bildmittelung) und das kinematische System (Positionen in x-, y- und z-Richtung und Anzahl der Projektionen) definiert werden. Die Lage des Bauteils auf dem kinematischen System hat großen Einfluss auf die Rekonstruktionsgüte einer Messung. Neben Unschärfefeffekten, ausgelöst durch eine fehlende Fixierung während der Messung, ist besonders die Lage des Bauteils ausschlaggebend für die erzielte Güte. Parallele Bauteilflächen zur Mittelebene des Detektors führen beispielsweise zu Artefakten in der Rekonstruktion, worunter die Qualität einer Messung leidet [4]. Ein dünner metallischer Vorfilter zwischen Röntgenröhre und Messraum entfernt niederenergetische Strahlung, wodurch sog. Strahlaufhärtungsartefakte verhindert und die Rekonstruktionsgüte verbessert wird. Die Wahl des Vorfilters hängt vom zu vermessenden Bauteil ab [7]. Die Strahlenergie wird durch die ange-

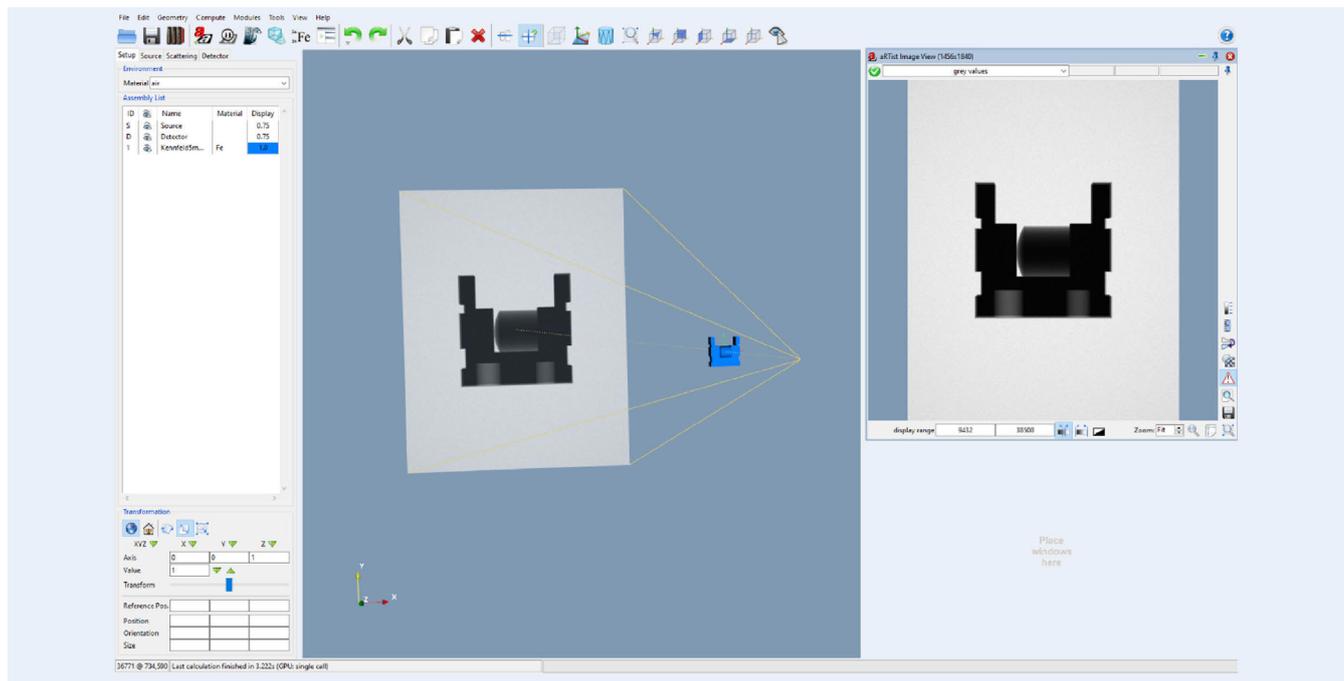


Bild 1. Benutzeroberfläche der Simulationssoftware „aRTist“ dargestellt anhand des 30 mm PEEK Probekörpers Prüfkörpers aus [5]. *Grafik: wbk*

legte Spannung und Stromstärke in der Röntgenröhre definiert. Höhere Spannung ermöglicht das Durchdringen dichter Materialien. Die Erhöhung der Stromstärke führt zu einer höheren Helligkeit und Rauschfreiheit der erzeugten Projektion. Beide Parameter erhöhen jedoch die Energie der Röntgenstrahlung. Eine hohe Energie erfordert jedoch eine größere Defokussierung des Elektronenstrahles und einen größeren Brennfleck, was die Projektionsunschärfe erhöht. Die Integrationszeit definiert die Dauer der Erzeugung einer Projektion. Eine Erhöhung führt vergleichbar zur Stromstärke zu helleren und rauschfreieren Projektionen, die Dauer der Messung erhöht sich jedoch. Die Verstärkung bestimmt die Empfindlichkeit des Detektors. Eine hohe Empfindlichkeit geht mit rauschbehafteten Bildern einher. Definiert man eine Anzahl an Projektionen über die eine Bildmitteilung erfolgen soll, werden die erfassten Pixelwerte über diese Anzahl gemittelt. Ein Rauschen der Projektionen kann so reduziert werden, die benötigte Anzahl an Projektionen und so die Dauer der Messung steigt jedoch. Die Positionierung des Bauteils in horizontaler Richtung zwischen Quelle und Detektor beeinflusst die Vergrößerung des Systems und damit die Auflösung. Eine höhere Auflösung geht jedoch mit unschärferen Projektionen einher [7].

CTs besitzen daher systemimmanente Wechselwirkungen zwischen den Parametern. Es ist daher nicht möglich eine allgemeingültige Parameterkonfiguration zur Vermessung unterschiedlicher Bauteile zu definieren. Messungen müssen daher stets auf das zu untersuchende Bauteil und unter einem bestimmten Ziel wie einer minimalen Messunsicherheit oder Messzeit ausgelegt werden. Die Parametrisierung benötigt daher aktuell große manuelle Aufwände und Expertenwissen [2].

3 Simulation von CT-Messungen

Mit dem vermehrten Einsatz von CTs im industriellen Bereich, geht auch ein immer stärkerer Fokus auf die Simulation

solcher Systeme einher. Innerhalb virtueller CTs werden die komplexen physikalischen Vorgänge durch Simulationsmodelle nachgebildet. Dazu gehören die Strahlerzeugung, die Abschwächung von Strahlen beim Durchleuchten von Bauteilen in Form von CAD-Dateien und die Signalverarbeitung des Detektors. Virtuelle CTs bieten die identischen Parameter zur Messauslegung, die in Kapitel 2 beschrieben wurden. Die zugrunde liegenden Simulationsmodelle benötigen jedoch umfangreiche Konfigurationsaufwände bis realistische Ergebnisse erreicht werden [8, 9]. Es gibt unterschiedliche Ansätze zur Simulation von CTs, folgend liegt der Fokus auf der Simulationssoftware „aRTist“ [8], anhand derer der Aufbau eines virtuellen CTs verdeutlicht wird.

Die Benutzeroberfläche ist in **Bild 1** dargestellt und die Funktionsweise am Beispiel des 30 mm PEEK Probekörper aus [5] veranschaulicht. Die CAD-Datei wird in eine virtuelle Umgebung bestehend aus Röntgenquelle und Detektor positioniert. Zur Erzeugung einer Röntgenprojektion wird ausgehend von der Röntgenquelle ein Strahl zu jedem Pixel des Detektors entsendet und der resultierende Grauwert dieses Pixels mittels der Modelle errechnet. aRTist wurde konfiguriert, um einen vorhandenen CT des Typs „Metrotom 800“ von Zeiss zu simulieren. Die hierfür gewählte Konfiguration ist in **Bild 2** dargestellt.

Zur Validierung der Konfiguration wurde der virtuelle CT anhand des von *Schild* [5] entwickelten Versuchsplan bestehend aus 20 Messungen für das 30 mm PEEK Probebauteil erprobt. Zur Evaluation wurden die durch aRTist erzeugten Rekonstruktionen mithilfe der Software „VG Studio“ anhand der **Bild 3** dargestellten Prüfmerkmale ausgewertet. Als Referenzwert dienen die Dimensionen der CAD-Datei. **Bild 4** zeigt die über alle Versuche gemittelten Abweichungen der Prüfmerkmale. Für das virtuelle CT befinden sich die Abweichungen der Fehler im Bereich von $2,5 \mu\text{m}$ bis $61 \mu\text{m}$, wobei lediglich die Merkmale A1, A2 und A3 eine Abweichung größer als $20 \mu\text{m}$ aufweisen. Für die Rekonstruktion von CAD-Daten kann daher geschlussfolgert werden,

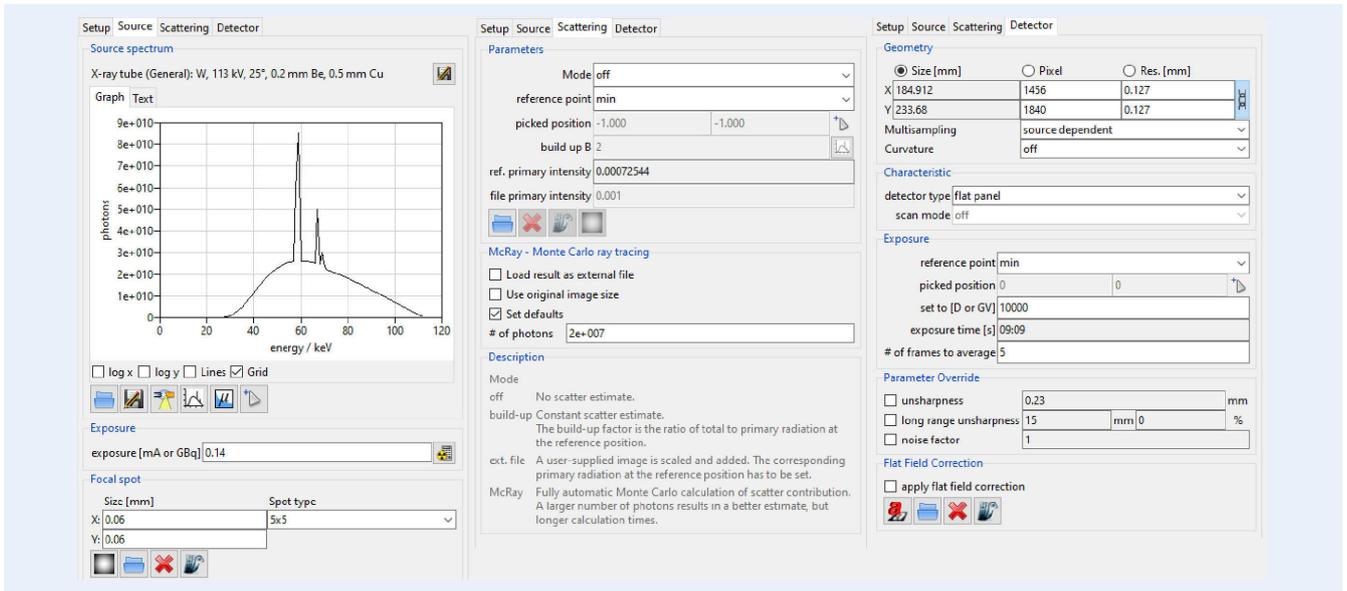


Bild 2. Gewählte Konfiguration zur Simulation eines „Metrotom 800“ von Zeiss innerhalb der Software „aRTist“. Grafik: wbk

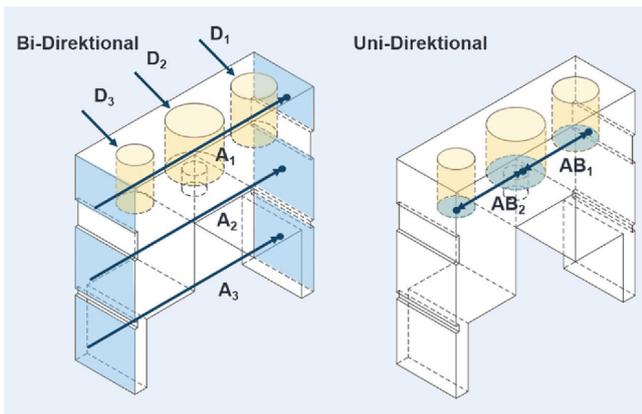


Bild 3. Untersuchte Prüfmerkmale zur Evaluation des virtuellen CTs. Grafik: aus [12, S. 59]

dass aktuelle CT Simulationen den Messvorgang mit geringer Abweichung abbilden, sodass diese für das Erlernen von Messstrategien anwendbar erscheinen.

4 Ein Konzept zur Nutzung von RL zur automatisierten Parametrisierung von CT-Messungen

RL ist ein Teilbereich des maschinellen Lernens, der sich mit der Entwicklung von intelligenten Agenten befasst, die durch Interaktion mit ihrer Umwelt lernen können. Im Gegensatz zu Ansätzen des überwachten Lernens, bei dem ein Agent aus gekennzeichneten Daten lernt oder unüberwachtem Lernen, bei dem ein Agent Muster innerhalb von Datensätzen entdeckt, basiert RL auf dem Prinzip der Verstärkung. Die grundlegende Idee beim RL besteht darin, dass ein Agent in einer bestimmten Umgebung handelt und dabei Belohnungen oder Strafen erhält, abhängig von der Qualität seiner Handlungen. Der Agent versucht im Laufe der Zeit sein Verhalten anzupassen, um Belohnungen zu maximieren und Strafen zu minimieren. Der RL-Agent nimmt den aktuellen Zustand seiner Umgebung wahr und entscheidet, welche Aktion

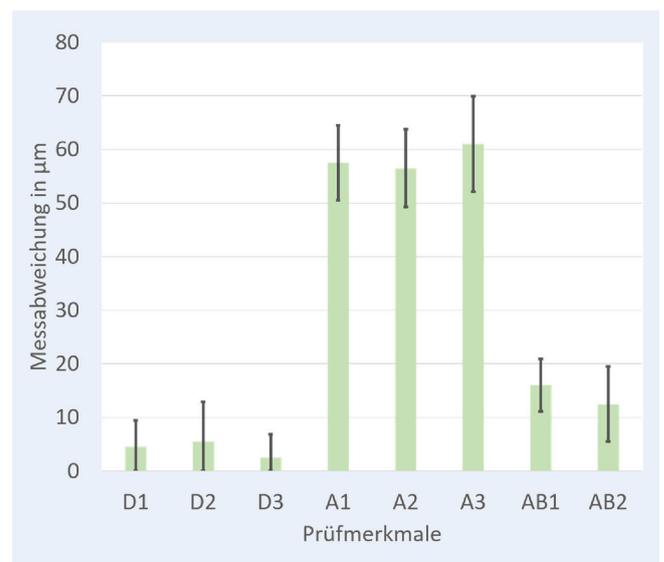


Bild 4. Gemittelte Abweichungen der untersuchten Prüfmerkmale zwischen Rekonstruktion des virtuellen CTs und CAD-Datei gemittelt über alle durchgeführten Messungen mit Darstellung der Standardabweichung. Grafik: wbk

er aus einer Menge möglicher Aktionen ausführen soll. Die Ausführung der Aktion führt zu einer Zustandsänderung seiner Umgebung. Auf Basis dieses Zustandes erhält der Agent eine Belohnung oder Strafe, die seine Leistung bewertet. Basierend auf diesem Feedback passt der Agent seine zukünftigen Entscheidungen an und optimiert seine Handlungsstrategie, um immer bessere Ergebnisse zu erzielen. RL ist so ein leistungsstarkes Werkzeug zur Lösung komplexer Entscheidungsprobleme bei denen genaue Modelle oder Regeln nicht verfügbar sind, benötigt aber aufgrund des Verstärkungsprinzips große Datenmengen [10].

Realistische virtuelle CTs zeigen sich als ideale Datenquelle, um den Einsatz von RL auch auf die Problemstellung der autonomen Parametrisierung von CT-Messungen zu erweitern. Ein Konzept wie dies erreicht werden soll, wird folgend vorgestellt.

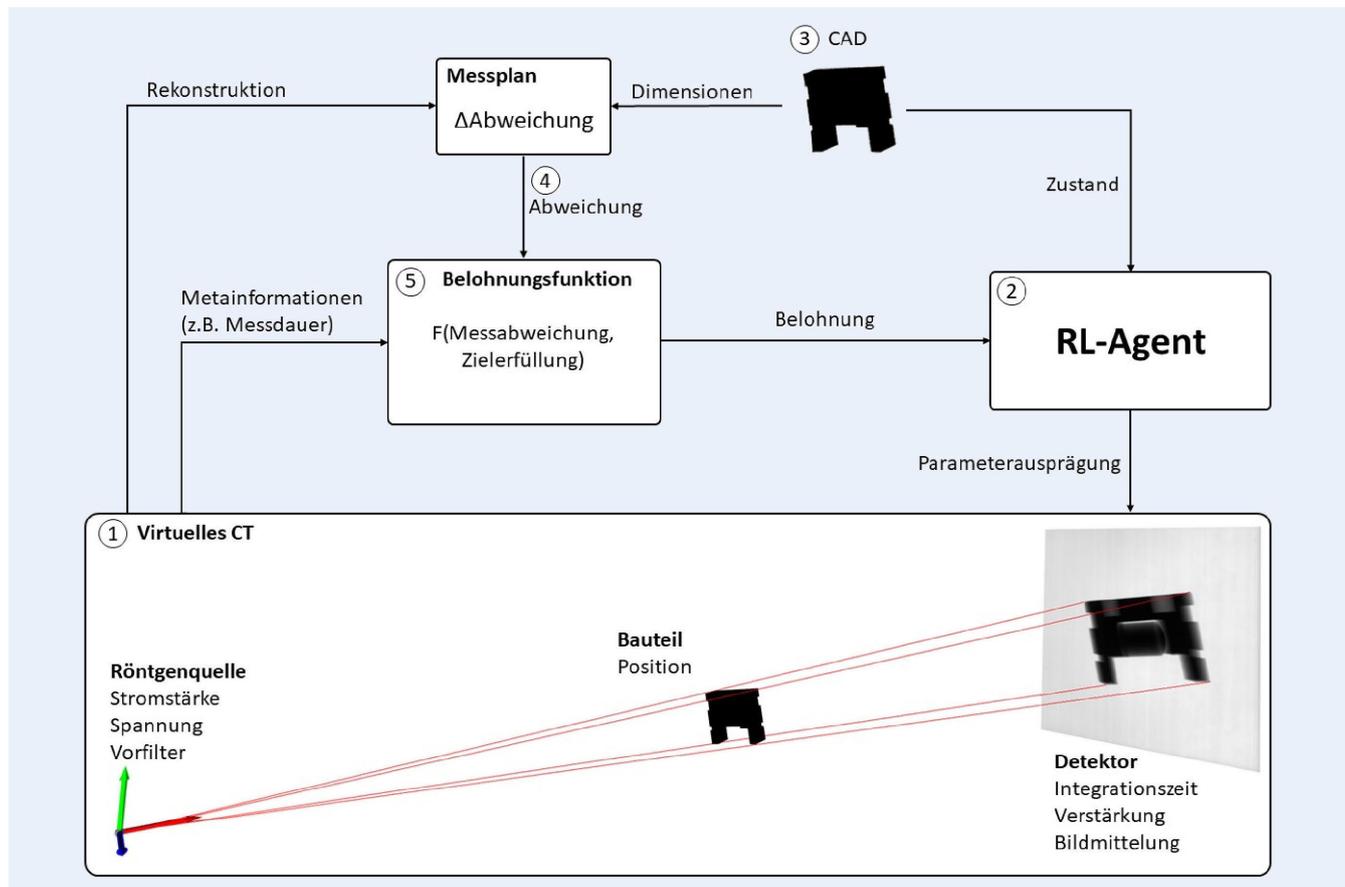


Bild 5. Schematische Darstellung des Konzeptes zum Training von RL-Agenten zur autonomen Parametrisierung von CT Messungen. Grafik: wbk

Das Konzept ist in **Bild 5** schematisch dargestellt. Ein virtuelles CT (1) dient als Basis zur Durchführung von Messungen. Die für die Messung zu definierenden Parameter für Röntgenquelle, Bauteillage und Detektor spiegeln den Aktionsraum des RL-Agenten wieder. Für jeden dieser Parameter definiert der Agent (2) daher einen Wert basierend auf seinem aktuellen Wissensschatz sowie dem aktuellen Zustand, in dem er sich befindet. Da Messungen stets auf das zu untersuchende Bauteil sowie ein bestimmtes Ziel ausgelegt werden, muss ein RL-Agent in der Lage sein, sein erlerntes Wissen auf unterschiedliche Geometrien zu externalisieren. Bei der Auslegung von CT-Messungen kann die zu vermessene Geometrie (3) daher als Zustand gesehen werden, für die eine geeignete Ausprägung an Parametern gefunden werden muss. Um eine Geometrie in eine Machine Learning verständliche Form zu übersetzen hat sich die PointNet Architektur [11] bewährt, die in der Lage ist, die Gestalt von Geometrien in einen Zahlenvektor zu überführen. Ähnliche Geometrien weisen dabei ähnliche Vektoren auf [11]. Da anhand des Vektors nicht nur geometriespezifische Informationen encodiert sind, sondern auch die zugrundeliegende Ähnlichkeit abgeleitet werden kann, zeigt sich ein solcher Vektor als vielversprechende Zustandsinformation, auf dessen Basis ein RL-Agent die Auslegung von Messungen erlernen und generalisieren kann. Zum Erlernen von Messstrategien wird der RL-Agent mit unterschiedlichen Geometrien in Form von solchen Vektoren konfrontiert. Anhand dieser Information definiert der Agent auf Basis seines aktuellen Wissensschatzes eine Ausprägung für jeden der Parameter. Das

virtuelle CT erzeugt eine künstliche Messung basierend auf den getroffenen Einstellungen. Die resultierende Rekonstruktion wird genutzt, um die Abweichung an vorher definierten Prüfmerkmalen zu bestimmen. Hierfür werden die zugrunde liegenden Dimensionen der CAD-Datei verwendet. Diese Abweichungen (4) können in der Belohnungsfunktion (5) als gemittelter Fehler verwendet werden. Je geringer die Abweichung der Rekonstruktion zur CAD-Datei ist, desto höher ist die Belohnung für dessen Handeln. Zusätzlich erlaubt die Bewertung von RL-Agenten anhand einer Belohnungsfunktion das Miteinbeziehen von weiteren Zielgrößen. Beispielsweise kann durch das negative Bewerten der Messzeit innerhalb der Belohnungsfunktion ein Agent darauf trainiert werden möglichst zeitminimale Messungen ausulegen. Die Wichtigkeit der jeweiligen Zielgrößen kann durch eine Gewichtung erfolgen. Anhand des berechneten Belohnungswertes sowie des Zustandes erweitert der Agent seine Wissensbasis und optimiert sein Verhalten. Je nach Messziel ist es daher notwendig individuelle Agenten zu trainieren, die sich in ihrer Belohnungsfunktion unterscheiden. Das Training kann anhand verschiedener RL Algorithmen erfolgen. Für verwandte Probleme der Parametrisierung von robotergeführten Messsystemen hat sich der Soft-Actor Kritik Algorithmus bewährt, weswegen dieser auch für die Parametrisierung von CT-Messungen angewendet werden soll [6]. Nach abgeschlossenem Training kann der Agent zur Parameterauslegung von Messungen genutzt werden, die anschließend auf realen Systemen durchgeführt werden.

5 Limitationen und Ausblick

Industrielle CTs zeigen große Potenziale gegenüber herkömmlicher Messtechnik wie taktile Koordinatenmesstechnik, besonders die zugrunde liegende Komplexität und Messdauer verhindern jedoch den breiten Einsatz als prozessnahe Messsysteme. Die komplizierten physikalischen Wechselwirkungen sowie die Individualität einer jeder Messung verlangen daher umfassendes Expertenwissen und manuelle Aufwände bei der Parametrisierung. RL-Agenten zeigen sich vielversprechend zur autonomen und zielgerichteten Auslegung solcher Parameterkonfigurationen. In diesem Artikel wurde ein Konzept zur Nutzung von RL vorgestellt, mit dem die Durchführung von Messungen automatisiert werden soll. Aufgrund der benötigten großen Datenmenge und Trainingsdauer wird hierfür eine effiziente virtuelle Trainingsumgebung benötigt. Aktuelle Ansätze zur Simulation von CTs ermöglichen Ergebnisse mit geringen Abweichungen im Vergleich zu realen Systemen [8], der Einsatz als virtuelle Trainingsumgebung für RL-Agenten wird jedoch aufgrund der Rechendauer und besonders der fehlenden Optimierung der aktuellen Simulationsumgebungen als Trainingsumgebung für RL-Agenten erschwert. Mit den gewählten Parametern hat das in Kapitel 3 vorgestellte virtuelle CT beispielsweise etwa 60 Minuten pro Messung benötigt. Die benötigte Trainingsdatenmenge kann so noch nicht effizient aufgebracht werden. Ohne eine Laufzeitoptimierung des virtuellen CTs ist das vorgestellte Konzept daher aktuell schwer realisierbar. Für weitere Arbeiten wird daher eine Optimierung der Simulationsumgebung angestrebt.

FÖRDERHINWEIS

Gefördert durch die Deutsche Forschungsgemeinschaft (DFG) – 465978608.

Literatur

- [1] Kruth, J.P.; Bartscher, M.; Carmignato, S. et al.: Computed tomography for dimensional metrology. *CIRP Annals* 60:821–842 (2011). <https://doi.org/10.1016/j.cirp.2011.05.006>
- [2] Buratti, A.; Ben Achour, S.; Isenberg, C. et al.: Frequency-based method to optimize the number of projections for industrial computed tomography. 6th Conference on Industrial Computed Tomography, iCT 2016, Wels, Austria, 9 Feb 2016 – 12 Feb 2016; *Journal of Nondestructive Testing & Ultrasonics* 20(2), (2016). special issue: „6th Conference on Industrial Computed Tomography (iCT) 2016 : 9–12 February 2016, Wels / University of Applied Sciences Upper Austria“ / pages 1–8. <https://doi.org/10.18154/RWTH-2017-10199>
- [3] Carmignato, S.; Dewulf, W.; Leach, R.: *Industrial X-Ray Computed Tomography*. Springer International Publishing, Cham 2018
- [4] Reiter, M.; Heinzl, C.; Salaberger, D. et al.: Study on Parameter Variation of an Industrial Computed Tomography Simulation Tool Concerning Dimensional Measurement Deviations. In: *Proceedings of 10th European Conference on Non-destructive Testing*, 2010
- [5] Schild, L.; Höger, K.; Zanini, F. et al.: Case-based reasoning user support for industrial x-ray computed tomography. *Meas Sci Technol* 34:45403 (2023). <https://doi.org/10.1088/1361-6501/acacba>
- [6] Kaiser, J.-P.; Bolender, M.; Eschner, N. et al.: View-Planning im Remanufacturing/Optical acquisition of products in remanufacturing by view-planning – View-Planning in Remanufacturing. *wt Werkstattstechnik* 111 (2021), 11/12, S. 781–785. <https://doi.org/10.37544/1436-4980-2021-11-12-11>
- [7] Buzug, T.: *Computed Tomography*. Springer: Berlin, Heidelberg 2008
- [8] Wohlgenuth, F., Hausotte, T.: Realistic Simulation of Specific CT-Systems in aRTist 2. In: *Deutsche Gesellschaft für Zerstörungsfreie Prüfung (ed) DGZfP-Jahrestagung 2021: Proceedings*
- [9] Wohlgenuth, F.; Müller, A.M.; Hausotte, T.: Development of a virtual metrological CT for numerical measurement uncertainty determination using aRTist 2. *tm – Technisches Messen* 85 (2018) S. 728–737. <https://doi.org/10.1515/teme-2018-0044>
- [10] Sutton, R.S.; Bach, F.; Barto, A. G.: *Reinforcement Learning: An Introduction*, 2 ed. Adaptive Computation and Machine Learning series. MIT Press Ltd, Massachusetts (2018)
- [11] Qi, C.R.; Su, H.; Mo, K. et al.: PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. *arXiv* 2016
- [12] Schild, L.: *Erzeugung und Verwendung von Anwendungswissen in der industriellen Computertomographie*, 1. Auflage. Forschungsberichte aus dem wbk, Institut für Produktionstechnik Universität Karlsruhe, vol 252. Düren: Shaker 2022



Edwin Blum, M.Sc. 
Foto: Autor

Dr.-Ing. Florian Stamer

Prof. Dr.-Ing. Gisela Lanza

wbk – Institut für Produktionstechnik
Karlsruher Institut für Technologie (KIT)
Kaiserstr. 12, 76131 Karlsruhe
Tel. +49 152 / 39502635
edwin.blum@kit.edu
www.wbk.kit.edu

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons
Namensnennung 4.0 International (CC BY 4.0)