

Entwicklung eines CT-Expertensystems in Kombination mit einer robotergestützten Automatisierung

Roswitha GIEDL-WAGNER*, Peter HORNBERGER**, Thomas MILLER*,
Susanne MÜLLER*,

* Hochschule Deggendorf, Edlmairstr. 6+8, 94469 Deggendorf, Germany, e-mail:
roswitha.giedl-wagner@hdu-deggendorf.de, thomas.miller@hdu-deggendorf.de,
susanne.mueller@hdu-deggendorf.de

** Wolfgang Pfeiffer Stiftung, Edlmairstr. 6+8, 94469 Deggendorf, Germany, e-mail:
p.hornberger@wolfgang-stiftung-pfeiffer.de

Kurzfassung. Die Computertomographie (CT) stellt ein vielversprechendes Werkzeug für die Bereiche der dimensionellen Messtechnik und der zerstörungsfreien Prüfung dar. Während die CT in der Medizin bereits seit Jahrzehnten erfolgreich eingesetzt wird, konnte sie sich insbesondere im Bereich der dimensionellen Messtechnik erst in den vergangenen Jahren durchsetzen. Die Genauigkeit von Messungen hängt dabei stark von den verwendeten Maschinenparametern ab. Diese werden üblicherweise von einem CT Bediener eingestellt und basieren damit auf dem Hintergrundwissen und den Erfahrungen des Bedieners. Ziel dieser Arbeit ist der Aufbau eines Expertensystems, mit dessen Hilfe der Messprozess weitestgehend automatisiert und optimiert werden kann.

1. Einführung

Die industrielle Computertomographie bietet vor allem im Bereich der Qualitätssicherung viele Vorteile und Anwendungsmöglichkeiten für Unternehmen, sowohl im Bereich der dimensionellen Messtechnik als auch der zerstörungsfreien Prüfung. Um das CT-Gerät effizient in der Qualitätssicherung nutzen zu können, müssen bestimmte Kriterien wie Prozesssicherheit, Reproduzierbarkeit, Wirtschaftlichkeit und die geforderte Qualität der Ergebnisse sichergestellt werden. Diese Aspekte können durch verschiedene Ansätze verbessert bzw. optimiert werden.

Die bis dato bedienerabhängige und zeitaufwendige Vorgehensweise zur Ermittlung der optimalen CT-Parameter ist der erste Ansatz hierzu. Durch Verwendung eines Expertensystems auf der Basis Künstlicher Neuronaler Netze, können die optimalen Einstellwerte für Messungen durch Eingabe charakteristischer Merkmale des Werkstücks automatisch gefunden werden.

Der Aufbau dieses Expertensystems erfolgt in mehreren Schritten: In der ersten Phase werden einfache regelgeometrische Bauteile eines Materials mit unterschiedlichen Parametern tomographiert und das Ergebnis anschließend anhand ausgewählter Merkmale qualifiziert und mit Kennzahlen bewertet. Durch diese Evaluierung können die besten Einstellparameter ermittelt werden und deren Einfluss quantifiziert werden. In den nächsten Schritten wird diese Vorgehensweise auf andere Materialien und letztendlich auf unterschiedliche Geometrien ausgedehnt.

Der zweite Ansatz, der neben der technischen Optimierung auch auf die Steigerung der Wirtschaftlichkeit abzielt, ist die Automatisierung des Systems auf Hardware-Ebene. Ein Bestückungsroboter wird dafür verwendet, jedes zu messende Werkstück im Computertomographen zu platzieren und wieder zu entnehmen. Mit Hilfe eines Filterwechslers kann auch die Wahl der geeigneten Vorfilterung automatisiert werden, und ein externer Rüstplatz wird für die Aufspannung und Zentrierung der Bauteile verwendet.

2. Problemstellung und bisheriger Prozessablauf

Die Vorgehensweise bei der Durchführung einer CT-Aufnahme ist noch mit diversen Umständen behaftet, welche es zu optimieren gilt. Dieser Abschnitt soll einen Überblick über den bisherigen Ablauf geben, und die daraus resultierenden Probleme aufzeigen. Bevor eine Messung gestartet werden kann, müssen einige Schritte durchgeführt werden.

Das Aufspannen des Prüflings ist insbesondere bei hohen Vergrößerungen Maßarbeit. Man muss dafür Sorge tragen, dass das Objekt zentrisch um die Drehachse positioniert wird, damit es aus jeder Ansicht vollständig auf dem Detektor abgebildet werden kann. Die Überprüfung der zentrischen Aufspannung erfolgt bei laufender CT-Anlage, indem man die gewünschte Vergrößerungsstufe anfährt und den Drehtisch manuell rotieren lässt. Sollte das Bauteil aus dem Messbereich driften, muss man es wieder herausnehmen und neu aufspannen. Hiermit können sich lange Rüstzeiten ergeben.

Das Ergebnis einer CT-Messung, hinsichtlich Messgenauigkeit und Bildqualität ist sehr stark vom Anlagenbediener und dessen Erfahrungsschatz abhängig. Eine Vielzahl von Parametereinstellungen, deren Einflüsse und Wechselwirkungen nichttrivial und in der Regel unbekannt sind, müssen vor dem Start einer CT-Aufnahme vorgenommen werden. Dieser Umstand erfordert im Falle ungenügender Messqualität, oft Mehrfachmessungen eines Prüflings.

Die Bestückung der CT-Anlage erfolgt manuell und macht deswegen einen Operator notwendig. Der Wunsch nach einer automatisierten Lösung wird vor allem aus wirtschaftlicher Sicht immer lauter. Zumal die Anlage dann auch in der zweiten und dritten Schicht betrieben werden könnte. Diese enorme Steigerung der Kapazitäten würde den produktionsbegleitenden Maschineneinsatz bei hohen Stückzahlen erleichtern.

3. Optimierung und verbesserter Prozessablauf

Ziel unserer Entwicklungsarbeiten soll eine effizientere Nutzung der CT-Technik hinsichtlich wichtiger Größen wie Wirtschaftlichkeit, Prozesssicherheit, Reproduzierbarkeit und Qualität sein. Dafür werden sowohl hardwarebasierte als auch softwarebasierte Ansatzpunkte in diesem Abschnitt vorgestellt.

3.1 Hardwarebasierte Automatisierung

Das Röntgenspektrum ist bei herkömmlichen Röntgenquellen polychromatisch. Dies verursacht insbesondere bei Materialien höherer Dichte und Ordnungszahl so genannte Strahlaufhärtungsartefakte [1], welche die Bildqualität erheblich mindern. Ein Ansatz zur Reduzierung derartiger Artefakte ist der Einsatz von Strahlenfiltern aus Materialien wie Aluminium, Kupfer oder Zinn mit unterschiedlichen Dicken. Diese Filter werden an der Strahlaustrittsblende der Röntgenquelle positioniert und sorgen dafür, dass niederenergetische Photonen im Röntgenspektrum herausgefiltert werden. Die Photonen werden somit bereits vor Eintreffen am Prüfling gewissermaßen ausselektiert und das




Abbildung 1: *Links:* Automatisches Filterwechselsystem zur Variation des Röntgenspektrums.
Rechts: Externer Rüstplatz zum Aufspannen und Zentrieren.

Spektrum wird aufgehärtet. Dadurch lassen sich Artefakte, welche auf Strahlaufhärtung zurückzuführen sind, reduzieren. Da die Wahl des passenden Filters abhängig von Geometrie und Materialzusammensetzung des Prüfobjektes ist, muss man diese Strahlenfilter manuell vor jeder Messung im Strahlengang anbringen. Eine automatisierte Lösung zur Anwahl des geeigneten Filters wurde vorgenommen (siehe Abbildung 1), was eine Steigerung der Wirtschaftlichkeit zur Folge hat.

Die Aufspannung und Zentrierung der Bauteile erfolgt bisher direkt in der Anlage, was lange Rüstzeiten zur Folge haben kann. Ein System zur zentrischen Aufspannung von Bauteilen außerhalb der Anlage wurde entwickelt (siehe Abbildung 1). Dieses System besteht aus einem Abbild des Drehmanipulators der CT-Anlage und einem Kamerasystem zur Überprüfung der optimalen Aufspannung. Somit erzeugt man zusätzlich Anlagenkapazitäten und macht den Ablauf wirtschaftlicher.



Abbildung 2: *Links:* Der automatisch angesteuerte Roboter beim Bestückungsvorgang.
Rechts: Werkstückträgersystem mit aufgespannten Bauteilen.

Die zu messenden Werkstücke werden auf austauschbaren Trägern befestigt und können so leicht und schnell in der Anlage platziert werden. Die Einbindung eines Roboters zur automatischen Bestückung der CT-Anlage ermöglicht eine enorme Steigerung der Wirtschaftlichkeit bei größeren Stückzahlen (siehe Abbildung 2).

3.2 Softwarebasierte Automatisierung

Die Steuerung der vorgestellten Hardware Komponenten erfolgt über eine eigens entwickelte Bediensoftware.

Eine wesentliche Anforderung von QM-Systemen ist eine lückenlose Dokumentation der Aufträge. Hierfür stellt die Software geeignete Eingabemasken zur Verfügung. Nach Speicherung der Auftragsdaten kann der Benutzer mit Hilfe der Software die Aufspannung der Werkstücke am externen Rüstplatz einstellen und überprüfen. Im nächsten Schritt können die zu messenden Werkstücke zusammen mit ihren Messparametern ausgewählt werden. Die Wahl der Parameter kann dabei entweder manuell oder automatisch erfolgen. Insbesondere lässt sich der Filter automatisch mit Hilfe des entwickelten Filterwechselsystems einstellen. Für den Fall, dass die Parameter automatisch bestimmt werden sollen, kommt ein Künstliches Neuronales Netz zum Einsatz. Im Folgenden soll näher auf diese Methode eingegangen werden.

3.2.1 Künstliche Neuronale Netze

Bei Künstlichen Neuronalen Netzen (KNN) handelt es sich um rechnergestützte Modelle, die von der Funktionsweise des Gehirns inspiriert sind [2]. Ein KNN besteht aus hochgradig vernetzten künstlichen Neuronen, die üblicherweise in Schichten angeordnet sind. Grafisch lässt sich ein solches Netz als gerichteter Graph darstellen (siehe Abbildung 3). Einfache KNNs bestehen oft aus drei Schichten. Die Eingabeschicht empfängt Informationen und übergibt diese über die Verbindungen an die verdeckte Schicht, von welcher sie wiederum zur Ausgabeschicht weitergeleitet werden. Die Verbindungen sind mit numerischen Gewichten versehen, die, zusammen mit der übertragenen Information, die Eingabe des mit ihnen verbundenen Neurons bilden. Künstliche Neuronen bestehen aus einer *Netzeingabe* und einer *Aktivierungsfunktion*. Sie verarbeiten die Eingabe und geben ihre Aktivierung an andere Neuronen weiter.

Ein KNN kann für die Implementierung einer Funktion $f: \mathbf{X} \rightarrow \mathbf{Y}$ verwendet werden, wobei die Kardinalität von $\mathbf{X}$ der Anzahl der Eingabeneuronen, und die Kardinalität von $\mathbf{Y}$ der Anzahl der Ausgabeneuronen entspricht. Bevor ein KNN eingesetzt werden kann, muss es die, den Daten zugrunde liegende, Funktion "erlernen". Dies geschieht in der Trainingsphase, in der dem Netzwerk Daten der Form $(\mathbf{x}, \mathbf{t})$ präsentiert werden. Der Vektor $\mathbf{t}$, auch Targetvektor genannt, bildet die gewünschte Ausgabe für den Eingabevektor $\mathbf{x}$. Unter Einsatz eines Trainingsalgorithmus kann das KNN dann die Funktion, die von den Eingabedaten impliziert wird, erlernen. Dies geschieht durch Minimierung der Abweichungen zwischen den tatsächlichen Netzwerkausgaben $\mathbf{y}$ von den zugehörigen Targetvektoren $\mathbf{t}$ unter Verwendung einer geeigneten Fehlerfunktion.

Die Anzahl der verdeckten Schichten und verdeckten Neuronen des KNN sind im Gegensatz zu der Anzahl von Eingabe- und Ausgabeneuronen nicht durch die Problemstellung bestimmt und kann frei gewählt werden. Die Größe des Netzes muss allerdings sehr sorgfältig festgelegt werden. Einerseits muss es flexibel genug sein, um die Daten passend zu beschreiben. Andererseits darf es auch nicht zu komplex sein, da dadurch die Gefahr einer Überanpassung entsteht. In diesem Fall würde das KNN zwar auf den




Abbildung 3: Ein Künstliches Neuronales Netz bestehend aus vier Schichten.

Trainingsdaten sehr gute Ergebnisse erzielen, nicht aber auf neuen Daten, die dem Netz nicht zuvor präsentiert wurden. Um diesen Effekt zu vermeiden, werden die Daten in eine Trainingsmenge und eine Validierungsmenge unterteilt. Unterschiedliche KNNs werden auf der Trainingsmenge trainiert und danach auf der Validierungsmenge miteinander verglichen. Das Netz, welches am besten auf den Validierungsdaten abschneidet wird ausgewählt. Dieses Verfahren wird als *Kreuzvalidierung* bezeichnet.

3.2.2 Radiale Basisfunktionen Netze

Für die Bestimmung der optimalen Maschinenparameter verwenden wir spezielle KNNs, sogenannte *Radiale Basisfunktionen Netze* (RBF Netze) [2]. Ein solches Netz besteht üblicherweise aus drei Schichten, einer Eingabeschicht I , einer verdeckten Schicht H und einer Ausgabeschicht O . Die Eingabeschicht gibt die externe Eingabe $\mathbf{x}$ unverändert an die verdeckte Schicht weiter. Die Aktivierung $a_j(\mathbf{x})$ wird anschließend für jedes verdeckte Neuron $j \in H$ berechnet, indem die Distanz $d_j(\mathbf{x}) = \|\mathbf{w}_j - \mathbf{x}\|$ zwischen dem Eingabevektor $\mathbf{x} = (x_1, x_2, \dots, x_n)$ und dem Gewichtsvektor $\mathbf{w}_j = (w_{(1,j)}, w_{(2,j)}, \dots, w_{(n,j)})$ der im Neuron eingehenden Verbindungen bestimmt wird. Dieser Distanzwert bildet dann die Eingabe für die radiale Basisfunktion des verdeckten Neurons. In den meisten Fällen wird hierfür die Gauß-Funktion gewählt

$$a_j(\mathbf{x}) = e^{-(d_j^2(\mathbf{x})/r_j^2)}$$

wobei der Parameter r_j als *Radius* und der Gewichtsvektor $\mathbf{w}_j$ als *Zentrum* der Funktion bezeichnet werden. Die Ausgabe des Neurons $k \in O$ entspricht seiner Aktivierung a_k und wird aus der Linearkombination seiner Basisfunktionen berechnet

$$a_k(\mathbf{x}) = \sum_{j=1}^{|H|} w_{(j,k)} \cdot a_j(\mathbf{x})$$

RBF Netze besitzen die Eigenschaft der universellen Approximation, was im Wesentlichen bedeutet, dass sie jede beliebige Funktion mit beliebiger Genauigkeit approximieren können. Des Weiteren können RBF Netze unter Einsatz geeigneter Trainingsalgorithmen viel schneller trainiert werden als andere Arten von ANN [3].

3.2.3 Praktischer Einsatz von RBF Netzen für die Parameterbestimmung

Wie bereits beschrieben wurde, benötigen KNNs Trainingsdaten, also Daten mit bekannten Ausgaben für gegebene Eingaben. Um die optimalen Parameter für Werkstücke bestimmen zu können, muss das RBF Netz also auf Werkstücken trainiert werden, deren beste Parameter bekannt sind. Mit Hilfe dieses Wissens ist es dem System dann möglich, die optimalen Parameter für neue unbekannte Objekte zu ermitteln.

Für die Erzeugung der Trainingsdaten können verschiedene Methoden eingesetzt werden. Eine Möglichkeit besteht in der Durchführung von Messreihen mit anschließender Auswertung von Qualitätskriterien. Daraus lassen sich die besten Messungen und damit die optimalen Parameterkombinationen bestimmen [4]. Eine weitere Methode basiert auf der Idee, dass ähnliche Werkstücke auch ähnliche optimale Parameter besitzen. Um den Grad der Ähnlichkeit zu bestimmen, lassen sich gewisse Eigenschaften aus den Werkstücken extrahieren, die dann miteinander verglichen werden können [5].

Das hier beschriebene Expertensystem verwendet Trainingsdaten, die durch systematische Messreihen gewonnen werden [6]. Dieses Verfahren bietet sich aufgrund der vorhandenen hardwareseitigen Automatisierung an. So ist es möglich, mit Hilfe des Bestückungsroboters Messreihen mit mehreren Werkstücken durchzuführen, ohne dass ein CT Bediener anwesend sein muss. Somit können Trainingsdaten auch über Nacht oder an Wochenenden erzeugt werden.

4. Abschließende Bemerkungen

Durch die in dieser Arbeit vorgestellten Maßnahmen konnte der Prozessablauf im Vergleich zur bisherigen Vorgehensweise erheblich effizienter gestaltet werden (siehe Abbildung 4). Die zeitraubenden Wiederholschleifen wurden eliminiert und die Bedienbarkeit stark erleichtert.

Durch die hardware- und softwaretechnischen Automatisierungsmaßnahmen kann die Nutzung der CT Technik deutlich verbessert werden. Der Bedienereinfluss wird maßgeblich reduziert und die Anlagenkapazitäten werden erhöht. Neben der Steigerung der Reproduzierbarkeit und der Prozesssicherheit, nimmt außerdem die Wirtschaftlichkeit des Gesamtsystems erheblich zu. Selbst unerfahrenen Bedienern wird es ermöglicht qualitativ hochwertige Messungen mit reproduzierbaren Ergebnissen durchzuführen. Unter dem Strich ergibt sich ein deutlich effizienterer Prozessablauf ohne Wiederholschleifen.

Radiale Basisfunktionen Netze werden für die automatisierte Bestimmung der optimalen Maschinenparameter verwendet. In ersten Versuchen konnte bereits anhand einfacher Werkstücke nachgewiesen werden, dass RBF Netze hierfür eine geeignete Methode darstellen. Da ihre Leistung jedoch in hohem Maße von der Anzahl an Trainingsdaten abhängt, wird die weitere Erzeugung dieser Daten zukünftig eine wichtige Aufgabe darstellen. Dabei wird das Hauptaugenmerk auf der Verwendung komplexerer Objekte liegen. Des Weiteren sollen auch andere Methoden aus dem Bereich des Maschinellen Lernens für die Bestimmung der optimalen Parameter untersucht werden.




Abbildung 4: Links: Alter Prozessablauf mit Wiederholschleifen. Rechts: Optimierter Prozessablauf.

Danksagung

Die vorliegende Arbeit wurde von dem BMBF Förderprojekt Nr. 170 72X 10 (Robo-CT) unterstützt. Die Autoren bedanken sich bei der Wolfgang Pfeiffer Stiftung für die Bereitstellung der CT Anlage, sowie bei Andreas Gruber, Peter Landstorfer und Lullus Wellner für ihre tatkräftige Hilfe.

Referenzen

- [1] R.A. Brooks, G. Di Chiro, Beam hardening in x-ray reconstructive tomography, Physics in Medicine and Biology, Vol. 21 (1976), 390.
- [2] C. M. Bishop, Neural Networks for Pattern Recognition, Oxford University Press, USA, 1995.
- [3] O. Buchtala, A. Hofmann, B. Sick, Fast and efficient Training of RBF Networks, in: O. Kaynak, E. Alpaydin, E. Oja, L. Xu (Eds.): Artificial Neural Networks and Neural Information Processing - ICANN/ICONIP 2003 (Joint International Conference ICANN/ICONIP 2003), Lecture Notes in Computer Science 2714, Springer Verlag, Berlin, Heidelberg, New York; pp. 43-51, Istanbul, 26-29 June 2003.
- [4] J. Kastner, C. Heinzl, Genauigkeitsoptimierung der Röntgen-Computertomographie für die Geometriebestimmung und Visualisierung der Messunsicherheit, Proceedings DGZfP annual conference 2009, Münster, Germany, 2009.
- [5] R. Schmitt, C. Niggemann, Method for efficient Identification of Similar Work Pieces for X-Ray Computed Tomography, International Symposium on Digital Industrial Radiology and CT 2011, Berlin, Germany, 2011.
- [6] R. Giedl-Wagner, T. Miller, B. Sick, Determination of Optimal CT Scan Parameters Using Radial Basis Function Neural Networks, Conference on Industrial Computed Tomography (ICT), Wels, 2012