



Universiteit
Leiden
The Netherlands

Advancing learned algorithms for 2D X-ray computed tomography

Kiss, M.B.

Citation

Kiss, M. B. (2025, November 7). *Advancing learned algorithms for 2D X-ray computed tomography*. Retrieved from <https://hdl.handle.net/1887/4282439>

Version: Publisher's Version

License: [Licence agreement concerning inclusion of doctoral thesis in the Institutional Repository of the University of Leiden](#)

Downloaded from: <https://hdl.handle.net/1887/4282439>

Note: To cite this publication please use the final published version (if applicable).

Zusammenfassung auf Deutsch: Weiterentwicklung von Lernalgorithmen für zweidimensionale Computertomografie (CT)

Diese Doktorarbeit befasst sich mit der Weiterentwicklung von Lernalgorithmen für zweidimensionale Computertomografie (CT). Dabei handelt es sich um ein bildgebendes Verfahren, das digitale Schnittbilder aus einer Vielzahl an Röntgenprojektionen errechnet. Man könnte es alternativ auch Schichtröntgen nennen. Der Unterschied zu einfachen Röntgenaufnahmen besteht darin, dass man nicht nur durch Objekte oder Körper hindurchsehen kann, sondern auch deren innere Struktur in überlagerungsfreien Querschnitten betrachten kann. Die computergestützte Bildrekonstruktion basiert häufig auf dem Algorithmus der gefilterten Rückprojektion und errechnet den Absorptionsgrad der Röntgenstrahlen für jedes Volumenelement (Voxel) des Objektes. Die Qualität dieser Bildrekonstruktionen hängt dabei stark von der Qualität der einzelnen Röntgenprojektionen ab, aus denen die Querschnitte errechnet werden.

In Kapitel 2 beschäftigen wir uns mit der Aufnahme von CT-Scans zugeschnitten auf Kunstobjekte/Kulturgüter. Die Bildgebung von Kunstobjekten ist zumeist besonders herausfordernd, da diese Objekte häufig aus vielen verschiedenen Materialien mit unterschiedlichen Dichten, Dicken und Größen bestehen. Insbesondere Metallstrukturen in Kunstobjekten können zur mangelhaften Darstellung der Objekte in CT-Scans führen. Dabei spielt insbesondere das kontinuierliche Spektrum der Strahlungsquelle/Röntgenröhre eine entscheidende Rolle. Die hochenergetischen Lichtteilchen – die Röntgenstrahlung – die für den CT-Scan durch das Messobjekt geschickt werden, haben eine statistische energetische Verteilung. Niederenergetische Lichtteilchen werden dabei besonders häufig vom Messobjekt (vor allem von metallischen Strukturen)

absorbiert und können auf der anderen Seite nicht gemessen werden. In der Vorverarbeitung der Röntgenprojektionen führt dies zu Problemen und die errechneten Bildrekonstruktionen zeigen Bildfehler sogenannte Artefakte. Eine Lösung für dieses Problem liegt in der Filtrierung des niederenergetischen Teils des Röntgenspektrums – der niederenergetischen Lichtteilchen – sodass größtenteils höherenergetische Strahlung das Objekt durchdringt. Diese Filtrierung erfolgt durch dünne Metallfolien aus Aluminium, Kupfer oder Zinn von unterschiedlicher Dicke, die auch miteinander kombiniert werden können. Wenngleich diese Filtrierung zu einem durchschnittlich höherenergetischen Spektrum führt, verringert dieser Vorgang auch die Intensität der Strahlung. Ähnlich zu einer Fotografie bei schwachem Licht können die Röntgenaufnahmen demnach schlecht belichtet und verrauscht erscheinen, was sich auch auf die Bildrekonstruktionen auswirkt. Gleichzeitig tragen niederenergetischere Lichtteilchen in der Bildgebung zu einem höheren Kontrastverhältnis bei. Die Herausforderung bei auf Objekte zugeschnittenen CT-Scans ist entsprechend, eine Balance zu finden zwischen genügend starker Filtrierung und ausreichendem Messsignal sowie Kontrastverhältnis in den Bildrekonstruktionen.

In Kapitel 3 nutzen wir unsere Erfahrungen aus Kapitel 2, wie man auf Objekte zugeschnittene und optimierte CT-Scans durchführt, um einen großen Datensatz aufzunehmen. Die Basis von maschinellem Lernen und der Entwicklung von Lernalgorithmen liegt in aussagekräftigen und vielfältigen Daten, von denen die Algorithmen lernen können. Für den Fall von zweidimensionaler CT-Bildgebung sind dies zum einen die rohen Messdaten, eine Vielzahl an Röntgenprojektionen, und zum anderen deren entsprechende Bildrekonstruktionen. Mit dieser Kombination an Daten kann man entsprechend Algorithmen darauf trainieren, Rekonstruktionen der Bilder auf eine gelernte Art und Weise zu errechnen anstatt klassische, mathematische iterative Rekonstruktionsmethoden zu verwenden. Für hochqualitativ erfasste Messdaten ist dies nicht unbedingt von Vorteil, aber wird umso relevanter, wenn die eingehenden Daten nicht ideal sind. Für die Aufnahme dieses Datensatzes überlegten wir uns eine ausgeklügelte Messanordnung mit der wir sowohl hochqualitative als auch eingeschränkte Daten von dem gleichen Objekt erfassen können. Wir entschieden uns dabei dafür zusätzlich Messdaten mit geringer Strahlendosis (sog. low-dose) und damit erhöhtem Bildrauschen aufzunehmen als auch Messdaten, bei denen wir das Röntgenspektrum nicht vorab filterten und die Bildrekonstruktionen demnach starke Bildartefakte aufgrund der spektral unterschiedlichen Absorption (sog. beam-hardening) aufweisen. Dadurch dass wir korrespondierende optimierte als auch unzureichende Messdaten und deren jeweilige Bildrekonstruktionen besitzen, können wir Algorithmen darauf trainieren, diese ineinander umzuwandeln.

In Kapitel 4 untersuchen wir die Fragestellung, ob es ausreicht Lernalgorithmen für Bild-Entrauschen auf künstlich verrauschten Messdaten zu trainieren oder ob es notwendig ist, experimentell verrauschte Messdaten dafür zu verwenden. Dafür paaren wir optimierte „saubere“ Messdaten aus dem Datensatz aus Kapitel 3 mit den korrespondierenden verrauschten „low-dose“ Messdaten und trainieren zwei übliche neuronale Netzwerke (Lernalgorithmen für Bildverarbeitung) um diese ineinander umzuwandeln. Gleichzeitig nehmen wir die sauberen Messdaten als Grundlage um

künstliches Rauschen zu simulieren und auf diese anzuwenden. Auch die simuliert verrauschten Daten werden mit den sauberen Messdaten gepaart und die neuronalen Netzwerke darauf trainiert, diese ineinander umzuwandeln. Wir zeigen in unseren Untersuchungen, dass die neuronalen Netzwerke, die auf den simuliert verrauschten Daten trainiert wurden, besser darin sind, experimentell verrauschte Messdaten zu entrauschen. Wenn das Training aber von Messdaten zu Bildrekonstruktionen erfolgt, ist es besser die neuronalen Netzwerke auf experimentell verrauschten Messdaten zu trainieren. Der Simulationsansatz für das künstliche Rauschen scheint nicht komplex genug zu sein, um nicht-lineare Artefakt-Ursachen wie das oben erwähnte „beam-hardening“ zu erfassen. Entsprechend können die Lernalgorithmen, die diese Artefakte nicht im Verlauf ihres Trainings auf künstlich verrauschten Daten gesehen haben, diese auch nicht im Nachgang entfernen, wenn sie auf experimentell verrauschte Daten angewendet werden.

In Kapitel 5 führen wir eine große Vergleichsstudie von Lernalgorithmen für CT-Bildrekonstruktion auf Basis des Datensatzes aus Kapitel 3 durch. Hierfür nutzen wir die verschiedenen Messdaten des Datensatzes, um standardisierte Rekonstruktionsexperimente zu definieren. Als allgemeiner Vergleichswert nutzen wir für das erste CT-Experiment die vollständigen „sauberen“ Messdaten. Zudem nutzen wir die „sauberen“ Messdaten für sechs weitere CT-Experimente, indem wir zum einen die genutzten Röntgenprojektionen auf nur 120°, 90° bzw. 60° statt 360° limitieren und zum anderen die Anzahl auf 360, 120 und 60 Röntgenprojektionen reduzieren und spärlich auf 360° verteilen. Für die letzten beiden CT-Experimente nutzen wir die verrauschten und Artefakt-behafteten „low-dose“ und „beam-hardening“ Messdaten. Insgesamt werden drei klassische, mathematische Rekonstruktionsmethoden mit zwölf Lernalgorithmen verglichen. Diese sind in vier Kategorien aufgeteilt: Nachbearbeitungs-Netzwerke, ausgerollte/erlernte iterative Verfahren, erlernte Regularisierungsmethoden und Plug-and-Play Methoden. In jeder Kategorie werden drei Algorithmen für alle CT-Experimente verglichen. Die Implementierung der Experimente und Lernalgorithmen erfolgt in einer quelloffenen Code-Sammlung und kann um weitere CT-Experimente und Algorithmen für Vergleichszwecke erweitert werden.

Mit diesen Forschungsstudien konnten wir einen grundlegenden Beitrag für auf Objekte zugeschnittene CT-Scans und die zukünftige, standardisierte Entwicklung und Vergleichbarkeit von Lernalgorithmen für CT-Bildrekonstruktionen leisten.