



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).

Samenvatting

This chapter contains a layman's summary of this thesis in Dutch, English, and German. Thanks to Francien Bossema for her help with the summary in Dutch.

Samenvatting in het Nederlands: Ontwikkeling van zelflerende algoritmen voor tweedimensionale computertomografie (CT)

Dit proefschrift behandelt de ontwikkeling van zelflerende algoritmen voor tweedimensionale computertomografie (CT). CT is een beeldvormingsproces dat digitale dwarsdoorsnedes berekent uit een groot aantal röntgenfoto's. Het verschil met eenvoudige röntgenfoto's is dat je niet alleen door objecten of lichamen heen kunt kijken, maar ook hun interne structuur in doorsnedes kunt bekijken zonder dat deze structuren overlappen. De digitale beeldreconstructie is vaak gebaseerd op het gefilterde terugprojectie algoritme, dat de mate van absorptie voor elk volume-element (voxel) van het object berekent. De kwaliteit van deze beeldreconstructies is sterk afhankelijk van de kwaliteit van de individuele röntgenfoto's waaruit de doorsnedes worden berekend.

In hoofdstuk 2 behandelen we het maken van CT-scans van kunstobjecten/culturele artefacten. De beeldvorming van kunstobjecten is meestal bijzonder uitdagend, omdat deze objecten vaak bestaan uit veel verschillende materialen met verschillende dichtheden, diktes en afmetingen. Vooral metaalstructuren in kunstobjecten kunnen leiden tot een slechte visualisatie van de objecten in CT-scans. Het continue spectrum van de stralingsbron/röntgenbuis speelt hier een doorslaggevende rol. De hoogenergetische lichtdeeltjes - de röntgenstraling - die voor de CT-scan door het te meten object worden gestuurd, hebben een statistische energieverdeling. Laag-energetische lichtdeeltjes worden geabsorbeerd door het te meten object (vooral metalen structuren) en kunnen niet aan de andere kant worden gemeten. Dit leidt tot problemen bij de voorbereiding van de röntgenfoto's en de berekende beeldreconstructies vertonen fouten die artefacten worden genoemd. Een oplossing voor dit probleem ligt in het filteren van het laag-energetische deel van het röntgenspectrum - de laag-energetische lichtdeeltjes - zodat vooral hoger-energetische straling het object binnendringt. Deze filtratie wordt uitgevoerd met dunne metaalfolies van aluminium, koper of tin van verschillende diktes, die ook met elkaar gecombineerd kunnen worden. Hoewel deze filtering leidt tot een hoger gemiddeld energiespectrum, vermindert dit proces ook de intensiteit van de straling. Net als bij een foto die bij weinig licht is genomen, kunnen de röntgenbeelden er daardoor slecht belicht en ruisachtig uitzien, wat ook een effect heeft op de beeldreconstructies. Tegelijkertijd dragen lichtdeeltjes met een lagere energie in de beeldvorming bij aan een beter contrast. De uitdaging bij CT-scans van kunstobjecten is daarom om een balans te vinden tussen voldoende sterke filtratie en een voldoende meetsignaal en contrast in de beeldreconstructies.

In hoofdstuk 3 gebruiken we onze ervaring uit hoofdstuk 2 over het uitvoeren van op objecten afgestemde en geoptimaliseerde CT-scans om een grote dataset te verkrijgen. De basis van machinaal leren en de ontwikkeling van zelflerende algoritmen ligt in het verwerven van betekenisvolle en gevarieerde data waarvan de algoritmen kunnen leren. In het geval van tweedimensionale CT-beeldvorming bestaat dit uit de ruwe data (een groot aantal röntgenfoto's) en de bijbehorende beeldreconstructies. Met deze combinatie van gegevens kunnen algoritmen worden getraind om de beelden op een slimme manier te reconstrueren in plaats van klassieke wiskundige iteratieve reconstructiemethoden te gebruiken. Dit is niet noodzakelijk een voordeel voor meetgegevens van hoge kwaliteit, maar wordt relevanter als de verkregen data niet perfect is. Voor het verkrijgen van deze dataset gebruikten we een geavanceerde meetopstelling waarmee we data van zowel hoge als lage kwaliteit van hetzelfde object konden verkrijgen. We besloten om daarvoor data op te nemen met een lage stralingsdosis en dus een verhoogde beeldruis, evenals data waarbij we het röntgenspectrum niet van tevoren hadden gefilterd en waarvan de reconstructies sterke beeldartefacten vertoonden als gevolg van de spectraal verschillende absorptie (de zogeheten beam-hardening). Aangezien we corresponderende hoge kwaliteit en lage kwaliteit opnames en hun respectievelijke beeldreconstructies hebben, kunnen we algoritmes trainen om deze in elkaar om te zetten.

In hoofdstuk 4 onderzoeken we de vraag of het voldoende is om zelflerende algoritmen voor het verwijderen van ruis te trainen op kunstmatig toegevoegde ruis of dat het noodzakelijk is om hiervoor experimentele data die ruis bevat te gebruiken. Voor dit doel koppelen we geoptimaliseerde data uit hoofdstuk 3 aan de corresponderende ruisgevoelige "lage-dosis" data en trainen we twee veel gebruikte neurale netwerken (zelflerende algoritmen voor beeldverwerking) om ze in elkaar om te zetten. Tegelijkertijd nemen we de geoptimaliseerde data als basis om er kunstmatig ruis aan toe te voegen. De gesimuleerde ruis wordt ook gekoppeld aan de geoptimaliseerde data en de neurale netwerken worden getraind om ze in elkaar om te zetten. In het onderzoek laten we zien dat de neurale netwerken die zijn getraind op de gesimuleerde ruis beter zijn in het verwijderen van de ruis op experimentele datasets. Bij het trainen van data direct naar beeldreconstructies is het echter beter om de neurale netwerken te trainen op experimenteel gegenereerde ruis. De simulatie voor kunstmatige ruis lijkt niet complex genoeg om niet-lineaire artefactoorzaken zoals de hierboven genoemde "beam-hardening" vast te leggen. Daarom kunnen de zelflerende algoritmen, die deze artefacten niet zien tijdens hun training op data met kunstmatige ruis, deze achteraf niet verwijderen wanneer ze worden toegepast op experimentele data met ruis.

In hoofdstuk 5 voeren we een groot vergelijkend onderzoek uit naar zelflerende algoritmen voor CT-beeldreconstructie op basis van de dataset uit hoofdstuk 3. Hiervoor gebruiken we de verschillende data om gestandaardiseerde reconstructie-experimenten te definiëren. Als standaard gebruiken we de volledige geoptimaliseerde data van het eerste CT-experiment. Daarnaast gebruiken we deze data voor zes andere CT-experimenten door ten eerste de hoek van de gebruikte röntgenfoto's te beperken tot slechts 120°, 90° en 60° in plaats van 360° en ten tweede het aantal gebruikte foto's te reduceren tot 360, 120 en 60 röntgenfoto's en deze te verdelen over 360°. Voor

de laatste twee CT-experimenten gebruiken we de “low-dose” en “beam-hardening” data die ruis en beam hardening artefacten bevatten. In totaal worden 3 klassieke wiskundige reconstructiemethoden vergeleken met twaalf zelflerende algoritmen. Deze zijn onderverdeeld in vier categorieën: Post-processing netwerken, geleerde iteratieve methoden, geleerde regularisatiemethoden en plug-and-play methoden. In elke categorie worden drie algoritmen vergeleken voor alle CT-experimenten. De implementatie van de experimenten en algoritmen is uitgevoerd met open source code en kan worden uitgebreid met meer CT-experimenten en algoritmen voor vergelijkingsdoeleinden.

Met deze onderzoeksprojecten hebben we een fundamentele bijdrage kunnen leveren aan op objecten afgestemde CT-scans en de toekomstige gestandaardiseerde ontwikkeling en onderlinge vergelijkbaarheid van zelflerende algoritmen voor CT-beeldreconstructie.