

Aus dem Deutschen Krebsforschungszentrum Heidelberg
(Vorstand: Prof. Dr. Michael Baumann, Ursula Weyrich)
Abteilung X-Ray Imaging and CT
(Abteilungsleiter: Prof. Dr. Marc Kachelrieß)

Korrektur von Streustrahlartefakten durch tiefe neuronale
Netze in der klinischen Computertomographie

Inauguraldissertation
zur Erlangung des Doctor scientiarum humanarum (Dr. sc. hum.)
an der
Medizinischen Fakultät Heidelberg
der
Ruprecht-Karls-Universität

vorgelegt von
Julien Frank Josef Erath
aus Nizza (Frankreich)

März 2022

Dekan: Prof. Dr. Hans-Georg Kräusslich

Doktorvater: Prof. Dr. Marc Kachelrieß

Inhaltsverzeichnis

Abkürzungsverzeichnis	1
1 Einleitung	2
2 Grundlagen	7
2.1 Computertomographie	7
2.1.1 Erzeugung von Röntgenstrahlung	7
2.1.2 Interaktion von Röntgenstrahlen mit Materie	9
2.1.3 Detektion von Röntgenstrahlen	13
2.1.4 Klinische Computertomographie	16
2.2 Streustrahlkorrekturen	23
2.2.1 Monte-Carlo	23
2.2.2 Schätzung der Längsstreuung	24
2.2.3 Korrektur der Querstreuung	25
2.3 Neuronale Netze	26
2.3.1 Neuronen	27
2.3.2 Vorwärtsgerichtetes neuronales Netz	28
2.3.3 Faltungsbasierte neuronale Netze	28
2.3.4 Pooling	30
2.3.5 Training von neuronalen Netzen	31
2.3.6 Generalisierung der neuronalen Netze	31

3	Streustrahlkorrektur in der Dual-Source CT durch tiefe neuronale Netze	33
3.1	Material und Methoden	33
3.1.1	Monte-Carlo-Simulation	33
3.1.2	Tiefe neuronale Netze zur Schätzung der Streustrahlung	36
3.1.3	Verlustfunktion	47
3.1.4	Streustrahlsubtraktion	49
3.1.5	Bildrekonstruktion	49
3.1.6	Vergleichsmethode: messbasierte Streustrahlkorrektur	49
3.1.7	Trainingsprozess der neuronalen Netze	50
3.1.8	Methoden zur Auswertung der Streustrahlkorrektur	50
3.2	Ergebnisse	52
3.2.1	Vergleich der Verlustfunktionen	52
3.2.2	Optimierung des Winkelversatzes	54
3.2.3	Korrektur der Längsstreuung in der DSCT	56
3.2.4	Korrektur der Querstreuung in der DSCT	58
3.2.5	Korrektur der Längs- und Querstreuung in der DSCT	61
3.2.6	Korrektur der Längs- und Querstreuung im Dual-Energy CT	62
3.3	Diskussion	66
4	Streustrahlschätzung für grobe Streustrahlraster	71
4.1	Material und Methoden	71
4.1.1	Monte-Carlo-Simulation	71
4.1.2	Deep Scatter Estimation für grobe Streustrahlraster	73
4.2	Ergebnisse	74
4.3	Diskussion	79
5	Schlussfolgerung und Ausblick	81
6	Zusammenfassung	84
	Abbildungsverzeichnis	87

Tabellenverzeichnis	89
Literaturverzeichnis	90
Publikationsliste	104
Curriculum Vitae	106
Danksagung	108
Eidesstattliche Erklärung	109

Abkürzungsverzeichnis

ASG	Anti-scatter grid
CT	Computertomographie
DECT	Dual-Energy CT
DSCT	Dual-Source CT
DSE	Deep Scatter Estimation
EID	Energy-integrating detector
MAE	Mean absolute error
MC	Monte-Carlo
MSE	Mean squared error
PCD	Photon-counting detector
ROI	Region of Interest
SART	Simultaneous algebraic reconstruction technique
SPMAPE	Scatter-to-primary-weighted mean absolute percentage error
SPR	Scatter-to-primary ratio

1 Einleitung

Die röntgenbasierte Computertomographie (CT) stellt heutzutage das bedeutsamste, bildgebende Verfahren in der medizinischen Diagnostik dar. Es handelt sich dabei um eine nicht-invasive Untersuchungsmethode, welche diagnostische Informationen über das Innere des zu untersuchenden Patienten liefert. Im Gegensatz zum konventionellen Röntgen, generiert die CT Schnittbilder des Körpers, ohne dass währenddessen überlagernde anatomische Strukturen maskiert werden. Grundsätzlich können diese CT-Systeme beinahe das ganze Spektrum radiologischer Fragestellungen für sämtliche menschliche Organe abdecken. Überdies können Gewebestrukturen, materialspezifische Kontraste und funktionelle Parameter innerhalb von wenigen Sekunden mit einer submillimetergenauen Ortsauflösung wiedergegeben werden [Schlegel et al., 2018]. Über eine Scanlänge von bis zu zwei Metern werden mehrere tausend Röntgensichten berechnet, welche in der Folge zusammengefasst das CT-Volumen ergeben [Lell et al., 2015]. Diese Bildgebungsmodalität repräsentiert gegenüber der Magnetresonanztomographie eine quantitative, bildgebende Technologie, da die Graustufen, welche als CT-Werte bezeichnet werden, ein numerisches Maß der Dichtewerte darstellen [Schlegel et al., 2018].

Eines dieser Bilddaten akquirierenden Geräte setzt sich aus einer Gantry als Haupteinheit, in der sowohl die Röntgenröhre als auch der Detektor rotieren, und einer höhen- und längenverstellbaren Patientenliege zusammen. Diesbezüglich ergeben sich durch fortlaufende Entwicklungen in Form einer Dual-Source CT (DSCT) weitere Möglichkeiten. So resultieren jeweils zwei in der Gantry verbaute Röntgen-Detektor-Einheiten in einer Verkürzung der effektiven Rotationszeit [Flohr et al., 2006]. Die zeitliche Auflösung wird durch diese Anordnung verdoppelt und ist durch den beträchtlichen Qualitätsgewinn besonders bei der Kardio-CT von großem Vorteil [Matt et al., 2007]. Weiterhin können die

beiden Röntgenröhre-Detektor-Systeme mit unterschiedlichen Energien betrieben werden, sodass ein Dual-Energy CT (DECT) Scan generiert und im klinischen Alltag angewendet werden kann. Eine zusätzliche Möglichkeit spektrale Informationen im Rahmen des CT-Scans zu erhalten, besteht im Einsatz von photonenzählenden Detektoren [Taguchi et al., 2009, Taguchi and Iwanczyk, 2013]. Im Vergleich zu energieintegrierenden Geräten, innerhalb welchen die Energie der Röntgenquanten mittels Szintillatoren in Licht und daraufhin in eine elektrische Ladung umgesetzt sowie per Detektorpixel aufsummiert wird, entfällt bei photonenzählenden Sensoren der Zwischenschritt einer Lichtkonversion. Infolgedessen wird nicht nur die Energiesumme der Photonen ausgelesen, sondern jedes einzelne Röntgenquant gezählt und die spektralen Informationen sämtlicher Photonen verarbeitet [Taguchi et al., 2011, Klein et al., 2020, Nikl, 2006]. Deswegen erfolgt bei diesem Detektor keinerlei Elektronikrauschen mehr, wodurch letztendlich Bilddaten mit verbesserter Qualität entstehen [Pourmorteza et al., 2018, Lell and Kachelrieß, 2020]. Darüber hinaus kann die Dosis und damit die Strahlenbelastung mittels dieser Technologie weiter reduziert werden [Taguchi et al., 2009].

Im Allgemeinen verfolgen die anhaltenden Forschungen im Bereich der CT-Geräte das Ziel, die zu applizierende Strahlendosis für den Patienten so gering, wie nur möglich zu halten [Callahan, 2011] und zeitlich hochpräzise sowie hochauflösende Datensätze für klinische Diagnostiken zu generieren.




Abbildung 1.1: Einfluss der Streustrahlartefakte in einem Dual-Source CT. Von Links nach Rechts: Rekonstruiertes CT-Bild ohne Streustrahlartefakte, mit Längsstreuung, mit Querstreuerung und mit beiden Streuungsartefakten. $C = 40$ HU, $W = 300$ HU

Zur Erlangung einer akkuraten Bildqualität muss allerdings berücksichtigt werden, dass es in dieser Bildgebungsvariante zu einer Diskrepanz der abgebildeten Schwächungswerte von der tatsächlich im Untersuchungsvolumen enthaltenen Abschwächung kommen kann. Diesen Unterschieden liegen diverse Ursachen wie exemplarisch patientenverursachte oder physikalische Artefakte zugrunde. Erstere können beispielsweise durch Patientenbewegungen während des Scanvorgangs, wie Atmung oder die allgemeine Herzbewegung, zustande kommen [Alkadhi et al., 2013]. Physikalische Artefakte entstehen dagegen etwa durch zu groß registrierte Intensitätswerte im Zuge der Strahlaufhärtung [Brooks and DiChiro, 1976] oder durch Streustrahlung [Rührnschopf and Klingenberg, 2011b, Rührnschopf and Klingenberg, 2011a], bei der ein Röntgenquant vom Untersuchungsobjekt nicht absorbiert, sondern gestreut und somit in seiner Richtung abgelenkt wird. Das führt wiederum dazu, dass ein Detektorpixel auch auf dem Weg von der Röntgenröhre am Patienten gestreute Röntgenquanten erfasst [Glaser-Gallion and Stolzmann, 2011]. Ein Sonderfall tritt im Hinblick auf die DSCT ein, da das System, wie bereits im obigen Abschnitt erwähnt, mit zwei Röntgenröhren-Detektoren-Einheiten ausgestattet ist. Hierbei entsteht zusätzlich zur Längsstreuung, wobei das Röntgenquant im Patienten gestreut und in dem der jeweiligen Röntgenröhre entsprechenden Detektor gemessen wird, die Querstreuung. Demgegenüber wird dabei die gestreute Strahlung in dem Detektor erfasst, welcher nicht der ursprünglichen Röntgenquelle zugeordnet ist [Petersilka et al., 2010, Bruder et al., 2008]. Zur Verminderung der aus der herkömmlichen Richtung abgelenkten Strahlung werden in klinischen CT-Geräten Streustrahlraster (engl.: „Anti-scatter grid (ASG)“) verwendet. Nichtsdestotrotz ist der zusätzliche Einsatz einer integrierten Software zur Streustrahlkorrektur unabdingbar, da nur auf diese Weise mögliche Streustrahlartefakte im rekonstruierten CT-Bild effizient vermieden werden können [Bruder et al., 2008, Petersilka et al., 2008]. Unkorrigiert kann die Streustrahlung zu deutlichen Streustrahlartefakten im rekonstruierten CT-Bild führen (Abbildung 1.1).

In den vergangenen zehn Jahren kam es zu enormen Fortschritten in der Entwicklung und Nutzung des maschinellen Lernens, die im Wesentlichen auf drei verschiedenen

Faktoren basieren. Einerseits zählen dazu die Fortschritte auf dem Gebiet des „Deep Learnings“, was eine Art des maschinellen Lernens beinhaltet und mittels welchem komplexe Funktionen aus Rohdaten extrahiert werden können. Andererseits stehen moderne Grafikkarten mit deutlich verbesserter Rechenleistung auf dem Markt zur Verfügung und schließlich liegen große Datensätze zum Trainieren dieser Algorithmen bereit [Esteva et al., 2021]. Dieser Trend spiegelt sich auch in der Forschung der medizinischen Diagnostik wieder. Wie in Abbildung 1.2 zu erkennen ist, führte dies zu einem rasanten Anstieg von publizierten Werken zum Thema des „Deep Learnings“ nicht nur im Bereich der allgemeinen Medizin, sondern auch auf dem Gebiet der Computertomographie. In Bezug darauf stellte die erste Anwendung innerhalb der medizinischen Diagnostik die schnelle und präzise Segmentierung von biomedizinischen Bilddaten durch ein tiefes, faltungsbasiertes neuronales Netz von Ronneberger et al. [Ronneberger et al., 2015] dar. Inzwischen dienen die neuronalen Netze in der Computertomographie nicht mehr lediglich der Analyse von Datensätzen, sondern weiterhin zur Optimierung der rekonstruierten CT-Bilder. Ferner finden die neuronalen Netze Anwendung zum Entrauschen der gewonnenen Bilddaten [Kang et al., 2017, Chen et al., 2017, Zheng et al., 2016, Wolterink et al., 2017], zur Korrektur von physikalischen Artefakten [Maier et al., 2018, Zhang and Yu, 2018, Maier et al., 2021] oder zur Bildregistrierung [Kearney et al., 2018].




Abbildung 1.2: Entwicklung der medizinischen Publikationen in Bezug auf das „Deep Learning“ oder „Machine Learning“ (links) sowie im Zusammenhang mit „CT“ oder „Computed Tomography“ (rechts) [Biotechnology, 2021].

In der vorliegenden Arbeit wird die Entwicklung und Validierung einer Korrektur von Streustrahlartefakten mithilfe neuronaler Netze präsentiert mit dem Ziel, die resultie-

rende Bildqualität in der klinischen CT zu optimieren. Das Augenmerk wurde hierbei insbesondere auf die Korrektur der im Zuge des DSCT entstehenden Streustrahlartefakte gelegt, wobei das angewandte Verfahren auch mit bereits existierenden Methoden verglichen wurde. Darüber hinaus erfolgte eine Erweiterung der bestehenden Algorithmen zur Streustrahlkorrektur, um sie außerdem mit groben Streustrahlrastern, wie bei photonenzählenden Detektoren, anwendbar zu machen.

2 Grundlagen

2.1 Computertomographie

Die diagnostische Bildgebung der CT basiert auf der gewebespezifischen Abschwächung von Röntgenstrahlung. Im folgenden Abschnitt werden diesbezüglich die physikalischen Prinzipien der CT zusammengefasst. Im ersten Schritt wird die Erzeugung von Röntgenstrahlen vorgestellt und außerdem werden auch deren spektrale Eigenschaften beschrieben. Darüber hinaus werden verschiedene Interaktionen der Röntgenstrahlen mit Materien geschildert. Anschließend wird die Erfassung dieser elektromagnetischen Wellen mit energieintegrierenden und photonenzählenden Detektoren erläutert. Ferner erfolgt eine Darstellung der technischen Grundlagen eines klinischen CT-Systems, einschließlich der Dual-Source CT. Dieses Wissen soll insbesondere das Fundament zum Verständnis der für die Streustrahlkorrektur relevanten physikalischen Eigenschaften und Zusammenhänge legen. Ausführliche Erläuterungen zur Erzeugung von Röntgenstrahlen, der Interaktion mit Materie und ihrer Detektion finden sich in ausgiebiger Literatur [Mahesh, 2013, Brooks and DiChiro, 1976, Buzug, 2008, Krieger, 2004, Carlsson, 1999, Samei and J., 2019].

2.1.1 Erzeugung von Röntgenstrahlung

Röntgenstrahlen stellen elektromagnetische Wellen mit einer Länge zwischen 1 nm und 1 pm [Meschede, 2002] dar. Dies entspricht wiederum einer Photonenergie im Bereich von 100 eV bis hin zu mehreren MeV. Röntgenstrahlung lässt sich im elektromagnetischem Spektrum zwischen ultraviolettem Licht und der Gammastrahlung einordnen.

Ihre Entstehung fußt auf der abrupten Abbremsung von Elektronen mit einer hohen kinetischen Energie [Seibert, 2004]. In diesem Zusammenhang werden in einer Vakuumröhre Elektronen durch Glühemission aus einer Kathode gelöst und daraufhin durch die angelegte Röhrenspannung U_R zwischen der Kathode und der Anode mit hoher Energie in Anodenrichtung beschleunigt [Carlsson, 1999]. Die Abbremsung der Elektronen im Coulomb-Feld der Atome des Anodenmaterials hat zur Folge, dass die Elektronen kinetische Energie verlieren und auf diese Weise Bremsstrahlung erzeugen [Seibert, 2004]. Auf der anderen Seite kann charakteristische Strahlung entstehen, wenn Elektronen aus der inneren Schale der Atome des Anodenmaterials herausgeschlagen werden und das entstehende Loch durch negativ geladene Elementarteilchen höherliegender Elektronenschalen wieder aufgefüllt wird [Meschede, 2002]. Die auf der Anode entschleunigten Elektronen geben in Abhängigkeit vom Ablenkwinkel eine unterschiedliche Menge an Energie in Form von Bremsstrahlung ab, wodurch sich letztendlich das kontinuierliche Röntgenspektrum ergibt [Oppelt, 2006]. Die Umwandlung kinetischer Energie in Röntgenstrahlung erfolgt mit einem sehr niedrigen Wirkungsgrad, da der Großteil dieser Bewegungsenergie in Wärme umgewandelt wird [Kalender, 2005]. Aus diesem Grund muss die Röntgenröhre ständig gekühlt werden, unterdessen in der klinischen CT zwischen einer direkt und indirekt gekühlten Röntgenröhre unterschieden werden kann [Schlegel et al., 2018]. Die kinetische Energie E_{kin} der dabei erzeugten Röntgenstrahlung ist abhängig von der Röhrenspannung U_R , der Elementarladung e und lässt sich angeben als:

$$E_{\text{kin}} = e \cdot U_R. \quad (2.1)$$

$$(2.2)$$

In der klinischen Computertomographie werden typischerweise Röhrenspannungen im Bereich von 70 kV bis 150 kV gewählt. Die Dosis sollte dabei möglichst niedrig gehalten werden, sodass beispielsweise bei einem Scan von einem Kind oder einem sehr schlanken

Patienten eine geringere Spannung, wie 70 kV vorgezogen werden würde [Schlegel et al., 2018].

2.1.2 Interaktion von Röntgenstrahlen mit Materie

Allgemein kann die Interaktion von Röntgenstrahlen mit Materie mit dem Lambert-Beer'schen Gesetz beschrieben werden:

$$N = N_0 e^{-\mu d}. \quad (2.3)$$

N_0 kennzeichnet die initial ungeschwächte Photonenzahl vor dem Objekt und N die Menge der Photonen der Röntgenstrahlen hinter dem Objekt mit der Dicke d und dem Absorptionskoeffizienten μ . Dieser Koeffizient μ ist dabei abhängig von der Energie E und der Kernladungszahl Z . Die gescannten Patienten in der Computertomographie bestehen aus mehreren, unterschiedlich gewichteten Substanzen, weswegen μ in Abhängigkeit von der Position r innerhalb des untersuchten Objekts variiert [Carlsson, 1999]. Bei CT-Scans heterogener Objekte, worunter demnach exemplarisch ein menschlicher Patient fällt, ist $\mu = \mu(E, r)$ und die Gleichung (2.3) verallgemeinert sich zu:

$$N(E, L) = N_0(E) e^{-\int_L dl \mu(E, r)}. \quad (2.4)$$

Dabei bezeichnet L den Weg einer abgegebenen Röntgenstrahlung durch das Volumen, was derjenigen Linie entspricht, entlang welcher das Linienintegral in Gleichung (2.4) gezogen wird.

In der medizinischen Computertomographie findet der Energiebereich zwischen 20 und 150 keV Verwendung [Samei and J., 2019], indessen der Abschwächungskoeffizient insgesamt als Summe folgender physikalischer Effekte beschrieben werden kann: Beiträge des Photoeffekts μ_p , der Compton-Streuung μ_c und der Rayleigh-Streuung μ_r (Abbildung 2.1):

$$\mu = \mu_p + \mu_c + \mu_r. \quad (2.5)$$

Darauf Bezug nehmend, erfolgt im kommenden Abschnitt eine kurze Erläuterung der physikalischen Grundlagen des Photoeffekts, der Compton-Streuung sowie der Rayleigh-Streuung.

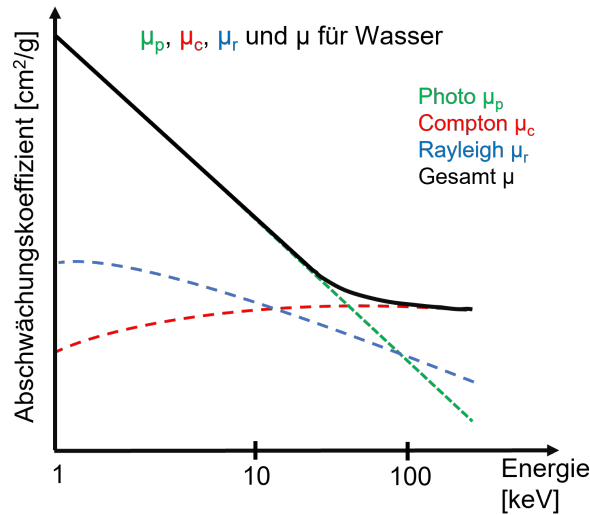


Abbildung 2.1: Zusammensetzung des vollständigen Abschwächungskoeffizienten μ aus dem Photoeffekt μ_p , der Compton-Streuung μ_c und der Rayleigh-Streuung μ_r für Wasser. Ersterer dominiert hierbei für niedrige Energien bis etwa 30 keV, während für höhere Energie die Compton-Streuung überwiegt. Die Rayleigh-Streuung hingegen leistet einen geringeren Beitrag zum gesamten Abschwächungskoeffizienten μ .

Photoeffekt

Der Photoeffekt kennzeichnet die Wechselwirkungen eines Photons mit einem Hüllenelektron unter der zeitgleichen Emission eines freien Elektrons. Im Zuge dieses Prozesses wird die Energie E des Photons vollständig absorbiert [Pratt et al., 1973]. Dabei dient ein Teil zur Überwindung der Bindungsenergie zwischen Atom und Elektron, während der übrige Anteil als kinetische Energie auf das Elektron übertragen wird [Cullen et al., 1997]. Der Photoeffekt tritt vor allem bei niedrigen Energien und hohen Ordnungszahlen auf [Krieger, 2004], wobei die Wahrscheinlichkeit bei lediglich geringfügig kleinerer Bindungsenergie gegenüber der Photonenergie am höchsten ist. Demgegenüber kann kein Photoeffekt stattfinden, wenn die Bindungsenergie größer als die Energie des Photons ist. Dieser physikalische Vorgang wird durch den Absorptionskoeffizienten μ_p definiert

und ist dazu abhängig von der Dichte ρ , der Ordnungszahl Z und der Atommassenzahl A . Weiterhin ist der Photoeffekt proportional zu:

$$\mu_p \propto \rho \frac{Z^4}{AE^3} \quad (2.6)$$

$$\mu_p \propto \rho \frac{Z^3}{E^3} \quad \left(\text{mit } \frac{Z}{A} \approx \frac{1}{2}\right). \quad (2.7)$$

Diesbezüglich besteht innerhalb der Gleichung (2.7) die Annahme, dass in leichten Atomen das Verhältnis der Ordnungszahl und der Atommassenzahl ungefähr konstant ist [White, 1977]. Daraus folgt, dass mit steigender Ordnungszahl Z die Wahrscheinlichkeit eines Photoeffekts zunimmt, da Hüllenelektronen durch eine höhere Kernladung stärker an den Kern gebunden werden [Krieger, 2004]. Weil sich das menschliche Körpergewebe in der medizinischen Computertomographie hauptsächlich aus Elementen mit niedrigen Ordnungszahlen zusammensetzt, ist die Wahrscheinlichkeit einer Interaktion sehr gering, da die inneren Elektronen eine sehr geringe Bindungsenergie aufweisen [Seibert and Boone, 2005].




Abbildung 2.2: Verschiedene Interaktionen von Röntgenstrahlung mit Materie, darunter der Photoeffekt (A), die Compton-Streuung (B) sowie die Rayleigh-Streuung (C).

Compton-Effekt

Wenn die Energie des Photons erheblich die Bindungsenergie des Elektrons übersteigt, wird die Energie des Stoßes auf das Elektron der äußeren Schale übertragen. Es folgt

eine Herauslösung des Elektrons aus der äußeren Elektronenhülle [Krieger, 2004], infolgedessen dieses Elektron sowie das gestreute Photon in einem definierten Winkel weiterfliegen (Abbildung 2.2). Dieser Streuungseffekt wird als Compton-Effekt bezeichnet und verläuft im Gegensatz zur Rayleigh-Streuung nicht verlustfrei ab. Die Energie des gestreuten Photons wird dabei von E_γ reduziert zu:

$$E'_\gamma = E_\gamma \frac{1}{1 + \frac{E_\gamma}{m_e c^2} (1 - \cos \theta)}. \quad (2.8)$$

Dies führt anschließend zu einem Anstieg der Wellenlänge des Photons:

$$\lambda' = \lambda + \lambda_c (1 - \cos \theta). \quad (2.9)$$

Dabei stellt $\lambda_c = \frac{h}{m_e c}$ die Compton-Wellenlänge des Elektrons und m_e die Masse des Elektrons dar. Die Wellenlänge verändert sich dementsprechend nach der Streuung zu:

$$\Delta\lambda = \lambda' - \lambda \quad (2.10)$$

$$= \lambda_c (1 - \cos \theta). \quad (2.11)$$

Der Querschnitt der Compton-Streuung kann dargestellt werden als:

$$\sigma_{\text{Compton}} \approx \rho \cdot \frac{Z}{A} \cdot \frac{1}{E_\gamma^n}. \quad (2.12)$$

Dieser Querschnitt wird durch die Dichte ρ , die Ordnungszahl Z und die Atommassenzahl A bestimmt [Krieger, 2004]. Da Z und A nahezu linear verlaufen, beruht die Differenzierung im Hinblick auf verschiedene Materialien lediglich auf den unterschiedlichen Dichten ρ . Der Exponent n liegt im Bereich $n \in [0, 5; 1]$ und zeigt, dass die Energieabhängigkeit der Compton-Streuung wesentlich geringer ist als die des photoelektrischen Effekts [Krieger, 2004].

Rayleigh-Streuung

In Anbetracht der Rayleigh-Streuung interagiert das einfallende Photon mit einem gebundenen Elektron, während das gestreute Photon die gleiche Energie wie das einfallende Photon besitzt [Samei and J., 2019]. Lediglich die Richtung des Photons wird um ein Geringes geändert, wie es in Abbildung 2.2 illustriert ist. Der Rayleigh-Effekt tritt mit steigender Ordnungszahl und fallender Energie mit verstärkter Wahrscheinlichkeit ein. Der lineare Schwächungskoeffizient μ_r ist dabei an die Dichte ρ , die Ordnungszahl Z und die Energie der Photonen E gebunden:

$$\mu_r \propto \rho \cdot \frac{Z}{E^2}. \quad (2.13)$$

2.1.3 Detektion von Röntgenstrahlen

Die Detektion von Röntgenstrahlen beruht auf deren Abschwächung im Detektormaterial und der anschließenden Umwandlung dieser Energie in ein elektrisches Signal, das daraufhin weiterverarbeitet werden kann. In diesem Zusammenhang ist ein energieintegrierender Detektor mit indirekter Umwandlung von einem photonenzählenden Detektor mit direkter Umwandlung der einfallenden Röntgenquanten abzugrenzen (Abbildung 2.3).

Energieintegrierende Detektoren

In einem energieintegrierenden Detektor (engl.: „Energy-integrating detector (EID)“) erfolgt eine Umwandlung der eintreffenden Röntgenstrahlen in optische Photonen, die anschließend von einem Photomultiplier oder einer Photodiode erfasst werden [Nikl, 2006]. In der medizinischen CT werden für diese, zumeist aus $\text{Gd}_2\text{O}_2\text{S}$ bestehende Detektoren Szintillatoren verwendet [Shefer et al., 2013]. Da die Röntgenstrahlen im ersten Schritt in Photonen sichtbaren Lichts umgesetzt werden, wird diese Detektorart auch als indirekt konvertierender Detektor bezeichnet. Der Szintillator ist mit einer reflektierenden Schicht ausgestattet, um zu verhindern, dass die optischen Photonen in einem anderen Pixel registriert werden.




Abbildung 2.3: Schematischer Aufbau eines konventionellen, szintillatorbasierten, energieintegrierenden Detektors (indirekte Umwandlung) sowie demgegenüber eines photonenzählenden Detektors auf Halbleiterbasis (direkte Umwandlung).

Wie in Kapitel 2.1.2 bereits erläutert, kommt es im Rahmen der Interaktion der Strahlen mit Materie zu Streueffekten. Insbesondere der Compton-Effekt kann in massiven Streustrahlartefakten im rekonstruierten CT-Bild resultieren. Um diese Streustrahlung zu reduzieren, befindet sich an der Oberfläche des Detektors ein parallel zur Strahlung ausgerichtetes und in der Regel aus einem Material mit hoher Dichte, wie beispielsweise Wolfram bestehendes Streustrahlraster. Ergänzend hierzu, ist jedes Pixel bei diesem Detektorsystem von Lamellen umgeben. Aufgrund des innerhalb der klinischen CT auftretenden hohen Röntgenflusses, summiert der Detektor das Signal über eine bestimmte Messzeit. Das Signal ist daher proportional zu den Energien der über die Zeit einfallenden Röntgenphotonen [Nikl, 2006].

Photonenzählende Detektoren

Im Gegensatz zu EID werden für photonenzählende Detektoren (engl.: „Photon-counting detector (PCD)“) Halbleitersensoren eingesetzt, worunter in der Regel Cadmiumtellurid (CdTe) oder Cadmium-Zink-Tellurid (CZT) fallen [Schlegel and Bille, 2008]. Die Röntgenstrahlen werden innerhalb dieser Halbleiterschicht direkt in elektrische Ladun-

gen umgesetzt. Wie in Abbildung 2.3 veranschaulicht, werden diese Ladungen durch die angelegte Hochspannung zu den Ausleseelektroden hin bewegt. Überdies sind die freigesetzten Ladungen dabei direkt proportional zur Energie des Photons [Amato et al., 2020]. Gegenüber der indirekten Umwandlung (siehe EID), sind photonenzählende Detektoren in der Lage einzelne Photonen gesondert zu messen. Die erfassten Photonen werden außerdem in verschiedene Energiebereiche (engl.: „bins“) eingeteilt, weshalb photonenzählende Detektoren einen Zugewinn an spektralen Informationen im Zuge eines Scans generieren können [Taguchi et al., 2009, Lell and Kachelrieß, 2020].

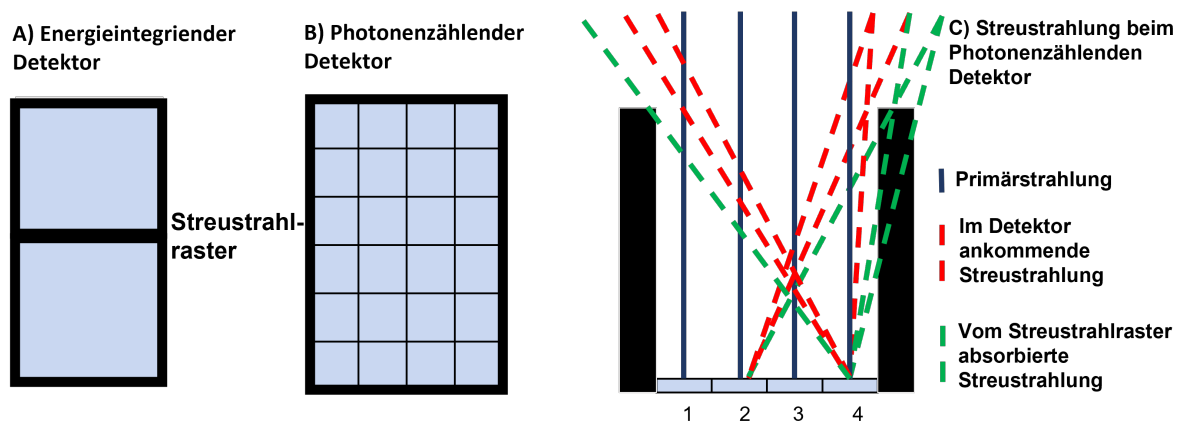


Abbildung 2.4: Vergleich der Streustrahlraster bei einem energieintegrierenden (A) und photonenzählenden (B) Detektor. Bei Ersterem befinden sich mehrere Pixel zwischen den Lamellen des Streustrahlrasters, was zu einer Veränderung der Streustrahlintensität (C) zwischen zwei benachbarten Pixeln führen kann.

Um zu umgehen, dass mehrere Photonen als ausschließlich ein Signal erfasst werden („Pile-Up“ Effekt), sind kleinere Pixelgrößen sowie äußerst schnelle Auslesegeschwindigkeiten vonnöten [Taguchi et al., 2011, Taguchi et al., 2010, Leng et al., 2018]. Allerdings führen diese kleineren Pixelgrößen dazu, dass im Gegensatz zu den EID nicht jeder Detektorpixel von Lamellen des Streustrahlrasters direkt umgeben wird, sondern sich mehrere Pixel zwischen den Lamellen des Streustrahlrasters befinden. Dies bewirkt wiederum, dass benachbarte Pixel unterschiedlich starke Streustrahlintensitäten aufnehmen (Abbildung 2.4). Durch diesen Effekt erfährt die sonst niederfrequente Streustrahlung eine hochfrequente Intensitätsveränderung der im Detektor ankommenden Streustrahlung.

lung, wodurch schlussendlich ein Moiré-artiger Effekt in den rekonstruierten CT-Bildern auftreten kann (Abbildung 2.5).




Abbildung 2.5: Vergleich der Streustrahlartefakte bei einem Detektor mit einem feinen Streustrahlraster (energieintegrierender Detektor) und einem groben Streustrahlraster (photonenzählender Detektor). Durch das Nutzen von groben Streustrahlrastern kommt es zum Moiré-Effekt. Relevante Parameter der rekonstruierten Bilder: $C = 40$ HU, $W = 300$ HU, Differenzen zum Referenzbild: $C = 0$ HU, $W = 50$ HU.

2.1.4 Klinische Computertomographie

Im Zuge eines klinischen CT-Scans wird die Schwächung durch den Patienten aus einer Vielzahl von Winkeln ermittelt, so dass sich $\mu(r)$ aus der Gleichung (2.4) berechnen lässt. Die Gantry rotiert währenddessen mit hoher Geschwindigkeit um den Patienten. Damit innerhalb einer verkürzten Zeit ein größerer Scanbereich erfasst werden kann, werden die meisten klinischen Computertomographien mit einer spiralförmigen Fokusbahn durchgeführt [Kalender, 2005]. Der sich daraus ergebende Pitchfaktor kann dargestellt werden als:

Gewebeart, Organ	CT-Werte
Luft	-1000 HU
Lunge	-900 HU bis -500 HU
Fett	-100 HU bis -70 HU
Wasser	0 HU
Blut	30 HU bis 60 HU
Leber	40 HU bis 70 HU
Knochen (spongiös)	70 HU bis 350 HU
Knochen (kortikal)	350 HU bis 2000 HU

Tabelle 2.1: Tabellarische Übersicht verschiedener CT-Werte für diverse Gewebe und Organe bei einer Spannung von 120 kV (modifiziert nach [Schlegel et al., 2018]). Individuelle Faktoren führen zu einer gewissen Variationsbreite dieser numerischen Angaben.

$$p = \frac{d}{M \cdot S}. \quad (2.14)$$

Hierbei bezeichnet d den Tischvorschub pro Umlauf, M die Zahl der erfassten Detektorzeilen und S die gewählte Schichtdicke. Im Allgemeinen bildet die klinische Computertomographie die Verteilung des linearen Schwächungskoeffizienten μ in Form von Graustufen ab. Da Wasser dem dominierenden Material in einem menschlichen Patienten entspricht, werden die Schwächungskoeffizienten relativ zu Wasser dargestellt. Der CT-Wert ist definiert als:

$$CT(r) = 1000 \text{ HU} \cdot \frac{\mu(r) - \mu_{\text{Wasser}}}{\mu_{\text{Wasser}}}. \quad (2.15)$$

Daraus resultiert, dass in klinischen CT-Systemen Wasser einen Wert von 0 Hounsfield Units (HU) und Luft eine CT-Zahl von -1000 HU einnimmt. Da sich der lineare Schwächungswert annähernd proportional zur Massendichte verhält, kann der beschriebene CT-Wert auch als Dichtewert des untersuchten Materials interpretiert werden [Schlegel et al., 2018]. Einen Überblick spezifischer CT-Werte für verschiedene Gewebe und Organe gibt die Tabelle 2.1 wieder.

Strahlendosis

Grundsätzlich ist zu beachten, dass CT-Untersuchungen mit einer potenziell schädlichen Strahlendosis im Rahmen der Durchführung einhergehen. Auch wenn der Nutzen der gewonnenen Zusatzinformationen einer CT-Diagnostik den statistischen Gesundheitsnachteil der Strahlenbelastung auf individueller Ebene bei weitem übersteigt, trägt diese Bildgebungsmodalität zu mehr als der Hälfte der gesamten Kollektivdosis aus Röntgenuntersuchungen bei [Hunold et al., 2003, Bundesamt für Strahlenschutz (BfS), 2013]. Durch die Einführung neuartiger und innovativer CT-Geräte konnte die Dosis im letzten Jahrzehnt jedoch deutlich gesenkt werden. Während vor 20 Jahren klassische CT-Untersuchungen üblicherweise mit 5 bis 30 mSv (vgl. [Schlegel et al., 2018]) angefertigt wurden, erfolgen die Scans heutzutage mit deutlich reduzierten Millisievert [Pantos et al., 2011]. Prinzipiell lassen sich die Risiken einer Strahlenbelastung erst bei einem Vielfachen von CT-Dosiswerten nachweisen [Feinendegen, 2005]. Durch die infolge der applizierten Strahlendosis verbundenen Risiken muss letztendlich bei jeder radiologischen Bildgebungsvariante zwischen dem eigentlichen diagnostischen Nutzen für den Patienten und der Gefährdung und den damit einhergehenden potenziellen Gesundheitsschäden abgewogen werden. Daher besteht eine aktuelle Forschungsfrage in der Optimierung der Strahlenbelastung, damit die Dosis so niedrig wie möglich gehalten werden kann (ALARA-Prinzip: „As low as reasonably achievable.“) [Bundesamt für Strahlenschutz (BfS), 2013]. Mittlerweile finden zahlreiche Techniken zur Reduktion der Dosis in den modernen CT-Geräten Anwendung.

Dual-Source CT

Um die Aufnahmezeit je Scan zu verringern und damit dessen zeitliche Auflösung zu verbessern, wurde im Jahre 2005 die DSCT eingeführt [Petersilka et al., 2008, Flohr et al., 2008]. DSCT-Scanner bestehen aus zwei versetzten Messsystemen und sind weiterhin mit zwei Röntgenstrahlern sowie zwei Mehrschicht-Detektorbänken ausgestattet (Abbildung 2.6), die in Abhängigkeit vom Gerätetyp um einen Winkel von 90 oder 95

Grad gegeneinander versetzt sind [Brüning et al., 2008]. Ein Messsystem bildet dabei das vollständige Messfeld in Höhe von 50 cm ab, wohingegen das andere System ein kleineres Messfeld von 35,5 cm (SOMATOM Force, Siemens Healthineers, Forchheim, Deutschland) umfasst.




Abbildung 2.6: Illustration eines Dual-Source CT Scanners (Somatom FORCE, Siemens Healthineers, Forchheim, Deutschland), welcher mit zwei Röntgenstrahlern und zwei Detektoren ausgestattet ist. Die beiden Messsysteme sind um einen Winkel von 95° gegeneinander versetzt innerhalb der Gantry angeordnet. Der Detektor A bildet das komplette Messfeld von 50 cm ab, wogegen der Detektor B ein Messfeld von 35,5 cm abdeckt.

Die Integration zweier simultaner Messsysteme führt zu einer Verdopplung der zeitlichen Auflösung (66 ms), was sich insbesondere bei zeitkritischen Anwendungen, wie exemplarisch Kardio-CTs als äußerst vorteilhaft erweist [Petersilka et al., 2008, Flohr et al., 2008, Flohr et al., 2015, Kachelrieß et al., 2006]. Eine zu niedrige zeitliche Auflösung äußert sich nicht nur in Bewegungsartefakten der CT-Bilder, sondern auch in unscharfen Abbildungen kleinerer Strukturen. Besonders zur Bewertung kleinerer Koronararterien-

Kalzifizierungen ist eine hohe zeitliche Auflösung der DSCT unerlässlich, da diese allgemein in reduzierten Bewegungsartefakten und verringerten Bildgenauigkeiten resultiert [Alkadhi et al., 2013, Flohr et al., 2006]. Diesbezüglich zeigen zahlreiche Studien, dass die Untersuchung der Koronararterien und damit die Diagnostik von Kalzifikationen auch bei Patienten mit höheren oder unregelmäßigen Herzfrequenzen in sehr guter Qualität möglich ist [Matt et al., 2007, Achenbach et al., 2006, Johnson et al., 2006, Alkadhi et al., 2013].

Durch den Gebrauch der DSCT kann der Pitchfaktor auf bis zu 3.4 erhöht werden [Hausleiter et al., 2009, Achenbach et al., 2010, Johnson et al., 2006]. Im Zuge dessen können auch Routineprotokolle mit sehr hoher Untersuchungsgeschwindigkeit durchgeführt werden. Außerdem erlauben die beiden Röntgenröhren auch einen Betrieb mit unterschiedlichen Röhrenspannungen und Stromstärken, weshalb sich zudem Zwei-Spektren CT (engl.: „Dual-Energy CT“)-Bilder erzeugen lassen [Brüning et al., 2008]. Dieses technologische Konzept ist besonders bei Bauch- und Beckentraumata hilfreich [Wortman et al., 2018, Krauss et al., 2011], wobei die Aufnahmen durch ein Messsystem mit einer niedrigen Spannung und dagegen durch die andere Einheit mit einer hohen Spannung generiert werden. Mittels dieser Röntgendiagnostik können virtuelle Nativbilder (engl.: „Virtual non-contrast imaging“) generiert werden [Faby et al., 2015], indem aus den mit Kontrastmitteln aufgenommenen CT-Bildern das Jod digital subtrahiert wird und so auf einen zusätzlichen Nativ-CT-Scan verzichtet werden kann [Krauss et al., 2011]. Darüber hinaus bietet die Dual-Energy CT durch eine Iodgabe (engl.: „Iodine-Maps“) die Möglichkeit die Kontrastmittelmenge in Form von Quantifizierungsbildern zu visualisieren [Faby et al., 2015]. In Abbildung 2.7 sind mögliche Rekonstruktionsvarianten der Dual-Energy CT-Aufnahmen dargestellt.

Die Applikation von zwei simultanen Messsystemen bei der DSCT bewirkt zwei unterschiedliche Streuungsprozesse (Abbildung 2.8). Wie bei einem Single-Source-Scan, wird auf der einen Seite die bereits geläufige Längsstreuung verursacht, bei welcher es sich um gestreute und innerhalb des gleichen Messsystems detektierte Röntgenquanten handelt (beispielsweise Streuung von Photonen aus Röntgenröhre A im Patienten sowie Erfassung im Detektor A). Auf der anderen Seite tritt bei einem DSCT-Scan die

Dual-Energy CT




Abbildung 2.7: Die material- und energieabhängigen Abschwächungen werden bei der Dual-Energy CT zur Materialzerlegung und Charakteristik genutzt. Die gewonnenen Informationen können im Rahmen der Nachbearbeitung zur Erzeugung virtueller Nativbilder, monoenergetischer Bilder [Maaß et al., 2011] oder zur Quantifizierung von Kontrastmitteln [Faby et al., 2015] verwendet werden.

Querstreueung auf, wobei allerdings die gestreuten Photonen im anderen Messsystem detektiert werden (exemplarisch Streueung von Photonen aus Röntgenröhre A im Patienten sowie Erfassung im Detektor B). Um die Vorwärts-Streustrahlung zu reduzieren, werden Streustrahlraster eingesetzt. Dennoch ist eine zusätzliche Streustrahlkorrektur im Hinblick auf ein DSCT erforderlich, um die durch Streustrahlung hervorgerufenen, möglichen Bildartefakte zu korrigieren [Bruder et al., 2008, Petersilka et al., 2010].




Abbildung 2.8: Visualisierung der Streuungsprozesse in einem Dual-Source CT, worunter die Längsstreuung (z.B. Photonen von der Röntgenröhre A, die innerhalb des Patienten gestreut und in Detektor A gemessen werden) und die Querstreueung (z.B. Photonen werden von der Röntgenröhre B emittiert, die durch die Streueung im Patienten im Detektor A gemessen werden) fallen.

2.2 Streustrahlkorrekturen

Im Allgemeinen existieren zur Korrektur von Streustrahlung zwei verschiedene Möglichkeiten, wozu einerseits die Minimierung der ursprünglichen Streustrahlentstehung und andererseits die Korrektur des bereits im Detektor hervorgerufenen Streustrahlsignals zählen. Um der Messung einer abgelenkten Strahlung entgegenzuwirken, kann eine spezielle Hardware durch den Einsatz eines Kollimators oder eines Streustrahlrasters (vgl. Kapitel 1) appliziert werden. Diesbezüglich kann die resultierende, gestreute Strahlung ferner auch mithilfe einer entsprechenden Software berechnet werden, indem beispielsweise die Primärstrahlung (engl.: „Primary modulation“) moduliert wird oder Strahlungsblocker (engl.: „Beam blocker“) zur Unterscheidung von Streu- und Primärstrahlung eingesetzt werden. Eine weitere Alternative stellt die Nutzung empirischer, physikalischer oder konsistenzbasierter Modelle zur Annäherung an die Röntgenstrahlstreuung dar [Ohnesorge et al., 1999a, Baer and Kachelrieß, 2012]. Eine ausführliche Beschreibung sowie ein Vergleich der verfügbaren Korrekturmöglichkeiten der Längsstreuung findet sich in den entsprechenden Referenzen [Rührnschopf and Klingenberg, 2011a, Rührnschopf and Klingenberg, 2011b, Swindell and Evans, 1996, Ohnesorge et al., 1999b, Love and Kurger, 1987, Rinkel et al., 2007, Li et al., 2008, Sun and Star-Lack, 2010]. Der anschließende Abschnitt behandelt die verschiedenen Optionen zur Verbesserung der Streustrahlung bei einem DSCT-Scan.

2.2.1 Monte-Carlo

Die Anwendung der Monte-Carlo (MC)-Methode lässt äußerst exakte Streustrahlverteilungen zu, kann allerdings aufgrund der langen Laufzeit nicht im klinischen Routinealltag eingesetzt werden. Prinzipiell zielt die Simulation darauf ab, den Erwartungswert einer bestimmten (stochastischen) Größe Q durch Zufallszahlen zu schätzen:

$$E(Q) = \int q p(q) dq. \quad (2.16)$$

Dabei stellt $p(q)$ die Wahrscheinlichkeitsdichtefunktion der Zufallsvariablen Q dar, welche wiederum die Wahrscheinlichkeit angibt, Q zu finden in $[q, q + dq]$:

$$p(q) dq = P[q < Q < q + dq] \quad \text{mit } p(q) \geq 0 \text{ und } \int p(q) dq = 1. \quad (2.17)$$

Der Monte-Carlo-Ansatz entspricht der Erzeugung von nach $p(q)$ verteilten Zufallszahlen Q [Andreo, 1991, James, 1980]. Die interessierende Variable Q kann hierbei die Anzahl der den Detektor erreichenden Photonen beziehungsweise die im Detektor deponierte Energie beschreiben, wobei die Wahrscheinlichkeitsdichte $p(q)$ jedoch in der Regel unbekannt ist. Die Simulation einzelner Photonen (Zufallsbewegung, engl.: „Random Walk“) von der Quelle zum Detektor entsprechend der physikalischen Wechselwirkungswahrscheinlichkeiten ist eine Option die im Detektor ankommenden, gestreuten Photonen Q zu berechnen [Salvat et al., 2001, Zaidi and Ay, 2007].

2.2.2 Schätzung der Längsstreuung

Kernbasierte Streustrahlschätzungen präsentieren eine weniger zeitintensive Alternative im Vergleich zu Monte-Carlo-Simulationen [Rührnschopf and Klingenberg, 2011a, Rührnschopf and Klingenberg, 2011b], wobei sich in diesem Zusammenhang zwei verschiedene Arten der Algorithmen voneinander abgrenzen lassen. Erstere schätzt dabei die Streustrahlung als eine Kombination der Integrale der Quelle und der Ausbreitung der Streuung [Swindell and Evans, 1996, Ohnesorge et al., 1999b, Love and Kurger, 1987, Rinkel et al., 2007]. Diesbezüglich beschreibt dabei der Quellenterm die Streuung, die aus einem vereinfachten Modell abgeleitet wird (z.B. ledigliche Berücksichtigung der Streuung erster Ordnung entlang der Primärstrahlung). Demgegenüber gibt der Ausbreitungsterm die örtliche Streuung der Photonen wieder und erfolgt durch eine Kalibrierung mittels einer Monte-Carlo-Simulation oder Messung [Maier et al., 2018]. Letztendlich ergibt eine Multiplikation dieser beiden eben erwähnten Größen die Streustrahlverteilung für einen einzelnen Röntgenstrahl, welche durch die Integration über alle Röntgenstrahlen vervollständigt werden kann.

Eine mögliche Alternative zu diesen analytischen Modellen bietet die Nadelstrahl (engl.: „Needle-beam“)-MC-Simulation von einfachen Geometrien, wie exemplarisch Zylinder bis hin zu Ellipsen mit verschiedenen Größen [Li et al., 2008, Sun and Star-Lack, 2010]. Die Streustrahlintensitäten werden währenddessen in simulierten Lookup-Tabellen gespeichert. Damit für eine bestimmte Messung die Streustrahlverteilung ermittelt wird, kann für jeden Detektorpixel ein entsprechender Wert der Lookup-Tabellen zugewiesen werden. Die kernbasierten Streustrahlschätzungen gehen mit einer sehr kurzen Rechenzeit einher und sind so in Echtzeit anwendbar. Der Nachteil dieser Methoden besteht darin, dass diese mit einer reduzierten Genauigkeit im Vergleich zu einer MC-Simulation verbunden sind. Ergänzend hierzu, sind außerdem vorab verschiedene Messungen oder Simulationen zur Kalibrierung der offenen Parameter notwendig.

Ein weiteres alternatives, sehr vielversprechendes Verfahren stellt der damit einhergehende Einsatz neuronaler Netze bereit. Im Hinblick darauf haben Maier et al. [Maier et al., 2018, Maier et al., 2019b] zur Korrektur der Längsstreuung die „Deep Scatter Estimation (DSE)“, ein tiefes faltungsbasiertes neuronales Netz, entwickelt. Die DSE wird mithilfe einer Projektion mit simulierten oder gemessenen Streustrahlverteilungen dazu trainiert, die zugehörige Streustrahlverteilung zu bestimmen und weist zudem eine U-Netz ähnliche Architektur auf [Erath et al., 2019]. Diese Architektur wurde ursprünglich für die Bildsegmentierung entwickelt und basiert daher auf einem vollständig faltungsbasierten neuronalen Netz [Ronneberger et al., 2015]. Die DSE führt zu einer sehr genauen und schnellen Streustrahlschätzung [Maier et al., 2019b].

2.2.3 Korrektur der Querstreuung

Petersilka et al. [Petersilka et al., 2010] stellten zwei verschiedene Ansätze im Rahmen der Korrektur von Querstreuung für die Dual-Source CT bereit. Die erste, modellbasierte Methode setzt voraus, dass die Querstreuung hauptsächlich an der Oberfläche des Patienten abgelenkt wird. Die relevanten Oberflächeneigenschaften des Patienten werden dabei aus dem Sinogram extrahiert. Die Korrektur der Streustrahlung erfolgt dabei mit einer zuvor erstellten Lookup-Tabelle, die aus verschiedenen Querstreuveilungen

einer Vielzahl von mit unterschiedlichen Eigenschaften behafteten Objekten besteht. Im Gegensatz dazu steht das messbasierte Verfahren, bei dem sich zusätzliche Sensoren außerhalb der Penumbra des Fächerstrahls in der z-Richtung befinden. Diese Sensoren sind an beiden Detektoren A und B lokalisiert und werden für eine direkte Messung der Längs- und Querstreuung während des Scans genutzt [Petersilka et al., 2010]. Die geschätzten Streustrahlintensitäten werden dabei direkt von den gemessenen Rohdaten subtrahiert. Das Prinzip dieser Methode besteht darin, dass außerhalb des direkten Fächerstrahls vorkommende Strahlung als Streustrahlung angenommen wird [Siewerdsen et al., 2006]. Eine weitere messbasierte Verfahrensweise wurde von Ren et al. [Lei et al., 2016] vorgestellt, bei der vor dem Patienten ein Raster zur Reduktion der Streustrahlung binnen des Scans verwendet wird. Die Projektionsdaten werden im ungeblockten Bereich vermessen, während die Streustrahlung im geblockten Areal der Projektion erfasst und für die Streuungskorrektur benutzt wird [Lei et al., 2016]. Auch wenn die modellbasierte Korrektur keine gesonderte Hardware benötigt, sollte dennoch die verminderte Genauigkeit in einigen Situationen gegenüber der messbasierten Korrektur beachtet werden. Diese erfordert jedoch eine zusätzliche Hardware beziehungsweise Sensoren, was wiederum in gesteigerten Kosten resultiert.

2.3 Neuronale Netze

Algorithmen des maschinellen Lernen werden im Allgemeinen darauf trainiert, anhand eines gewissen Datensatzes automatisch eine Entscheidung zu treffen. Zum Erlernen dieser Entscheidungen werden die Algorithmen trainiert, aus einem Datensatz Merkmale zu extrahieren und so gewisse Muster zu erkennen. Das neuronale Netz versucht anhand der extrahierten Eigenschaften einen Automatismus zu entwickeln, der in der Lage ist, eine eindeutige und vollständige Merkmalsdarstellung zu generieren [Maier et al., 2019a]. Da für verschiedene Anwendungen jeweils diverse Merkmale von Bedeutung sind, ist eine Verallgemeinerung einer anständigen Extraktion äußerst kompliziert. Weil in der vorliegenden Arbeit neuronale Netze zur Korrektur der Streustrahlung eingesetzt werden, wird im Folgenden auf die Grundlagen von künstlichen neuronalen Netzen eingegangen.

2.3.1 Neuronen

Künstliche neuronale Netze sind in der Verarbeitung und dem Speichern von Informationen der Funktionsweise des menschlichen Gehirns nachgebildet [Flaton et al., 1995], wobei dort jedem Neuron Eingangssignale von den Dendriten weitergeleitet werden. Sobald die Summe dieser Eingangssignale einen bestimmten Schwellenwert überschreitet, aktiviert das Neuron ein Aktionspotential, welches anhand seiner Axone übertragen wird und außerdem über Synapsen mit den Dendriten danebenliegender Neuronen verbunden ist. Die fundamentale Einheit eines künstlichen neuronalen Netzes repräsentiert ein Neuron, das mittels einem Bias b und einem Gewichtungsvektor $w = (w_0, w_1, \dots, w_n - 1)$ eine Entscheidung mit der nicht-linearen Funktion $h(x)$ trifft [Maier et al., 2019a]:

$$\hat{f}(x) = h(w^\top x + b) \quad (2.18)$$

Ein einzelnes Neuron kann bereits eine Klassifikation für eine Entscheidung bereitstellen, dabei können das Minimum und Maximum jeweils als Entscheidung verschiedener Klassen interpretiert werden. Beispiele für solche Aktivierungsfunktionen sind die Sigmoidfunktion und der Tangens hyperbolicus (\tanh). Jedoch können mit einzelnen Neuronen lediglich lineare Lösungsansätze generiert werden [Maier et al., 2019a]. Durch die Verknüpfung von mehreren Neuronen steigern sich die Fähigkeiten der neuronalen Netze erheblich. Diesbezüglich konnte gezeigt werden, dass die Neuronen einer einzelnen Schicht jede kontinuierliche Funktion $f(x)$ annähern können [Cybenko, 1989], wobei sich eine Schicht des Netzes als Linearkombination von N einzelnen Neuronen mit v_i Gewichten darstellen lässt [Maier et al., 2019a]:

$$\hat{f}(x) = \sum_{i=0}^{N-1} v_i h(w_i^\top x + b_i). \quad (2.19)$$

Die Differenz zwischen der gesuchten $f(x)$ und der approximierten Funktion $\hat{f}(x)$ wird begrenzt durch [Maier et al., 2019a]:

$$|f(x) - \hat{f}(x)| < \epsilon. \quad (2.20)$$

Eine steigende Zahl an Neuronen geht mit einem reduzierten Unterschied dieser Differenz ϵ für monotone, stetige und begrenzte Funktionen einher [Maier et al., 2019a, Hornik, 1991].

2.3.2 Vorwärtsgerichtetes neuronales Netz

Die einfachste Grundstruktur aus verschiedenartig kombinierten Neuronen umfasst ein sogenanntes vorwärtsgerichtetes Netz (Abbildung 2.9). Dieses weist eine Eingabe- und eine Ausgabeschicht zur Weiterleitung der Informationen auf und besteht indessen aus unterschiedlichen und sich aus Reihen von Neuronen zusammensetzenden Schichten [Hornik, 1991]. Diese zwischen der Eingabe- und Ausgabeschicht befindlichen Bereiche werden auch als verborgene Schichten (engl.: „Hidden Layers“) bezeichnet und sind für die Modulierung der rechnerbasierten Problemlösung zuständig. Im Hinblick auf ein vorwärtsgerichtetes Netz erfolgt lediglich eine Übertragung der Informationen in eine Richtung und zwischen zwei benachbarten Schichten, welche dabei zumeist so verarbeitet sind, dass jedes Neuron einer Schicht mit den jeweiligen Neuronen der vorherigen und folgenden Schicht verknüpft ist. Wenn im weiteren Verlauf zwischen zwei Schichten sämtliche Neuronen miteinander verbunden sind, handelt es sich um vollständig verbundenes neuronales Netz (engl.: „Fully Connected Neural Network“). Die Ausgabe eines Neurons enthält den Wert seiner Aktivierungsfunktion, die sich aus der gewichteten Summe der Eingabe und des Bias ergibt. Überdies werden die Gewichte der anzupassenden Parameter dabei so optimiert, dass das Netz eine vordefinierte Anwendung erfüllt.

2.3.3 Faltungsbasierte neuronale Netze

Wie im einleitenden Kapitel 1 beschrieben, kam es innerhalb der letzten zehn Jahre zu einer zunehmenden Popularität von auf Deep Learning basierenden Methoden. Ein Großteil dieser Modelle beruht dabei im Gegensatz zu anderen Techniken des maschinellen Lernens auf faltungsbasierten neuronalen Netzen (engl.: „Convolutional Neural Networks“ (CNNs)). Ähnlich zur menschlichen visuellen Wahrnehmung, werden die Merkmale hierbei nicht ganzheitlich extrahiert, sondern es erfolgt eine hierarchisch geordnete




Abbildung 2.9: Beispiel eines vorwärtsgerichteten neuronalen Netzes, welches dabei aus einer Eingabeschicht, gefolgt von mehreren verborgenen Schichten und einer Ausgabeschicht besteht. Die Eingabeschicht leitet die Eingangsdaten x_1 , x_2 und x_3 an die nächste Schicht weiter. Die Neuronen sind hierbei jeweils mit allen Neuronen der folgenden Schicht verbunden. Bei einem vorwärtsgerichteten neuronalen Netz werden die Informationen ausschließlich in eine Richtung transportiert, sodass die Ausgabeschicht folglich die Ergebnisse y_1 und y_2 übermittelt.

Analyse regionaler Informationen [Erickson et al., 2017]. Dies lässt einerseits deutlich effizientere Trainingsprozesse zu und andererseits werden auch überlegene Ergebnisse in den verschiedensten Anwendungen gewonnen [Lu et al., 2017].

CNNs sind dabei aus einzelnen Neuronen aufgebaut, welche eine Linearkombination ihrer Eingaben berechnen und einen Bias hinzufügen [Krizhevsky et al., 2012]. Der Unterschied zu dem vorherigen Beispiel mit einer Verknüpfung jedes Neurons mit sämtlichen Neuronen einer vorherigen und einer folgenden Schicht besteht darin, dass die Neuronen bei CNNs nur Merkmale aus jeweils einer kleineren Region, dem rezeptiven Feld, extrahieren. Die resultierende Informationsgewinnung über das geringfügigere Areal wird über alle Pixelpositionen x, y im Bild durchgeführt, währenddessen die Gewichte sowie der Bias konstant bleiben. Dies führt zur Entstehung einer Merkmalskarte $M_{x,y}$ (engl.: „Feature map“), für welche eine diskrete Faltung mit einem Faltungskern $K_{i,j}$, wobei die Gewichte den Einträgen und die Größe dem rezeptiven Feld entsprechen, und einem Eingangsbild $E_{x,y}$ charakteristisch sind:

$$M(x, y) = h((K * E)_{x,y} + w_0) = h\left(\sum_{i,j} K_{i,j} E_{x-i,y-j} + b_0\right). \quad (2.21)$$

Hierbei bezeichnet h die Aktivierungsfunktion und b_0 wiederum den Bias. Diese durch das vollständige Eingangsbild verschobene Faltung erlaubt eine Extraktion verschiedener Bildmerkmale. Üblicherweise wird für eine Eingabe und eine bestimmte Schicht des Netzes nicht nur ein Merkmal herangezogen, sondern eine Vielzahl von Attributen mit unterschiedlichen Arten von Eigenschaften. Wenn als Eingang U verschiedene Merkmalskarten vorliegen und F verschiedene Filter angewendet werden sollen, entsprechen die Ausgaben der f -ten Merkmalskarten:

$$M(f, x, y) = h\left(\sum_{u=1}^U (K_{f,u} * E_u)_{x,y} + b_{0,f}\right). \quad (2.22)$$

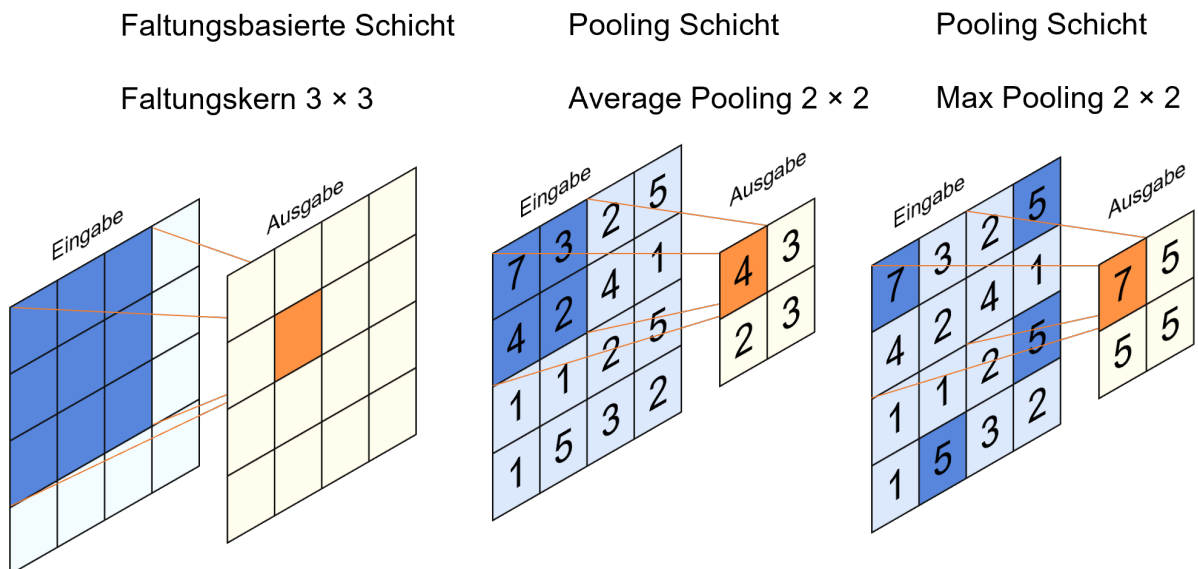


Abbildung 2.10: Darstellung der relevantesten Schichten innerhalb eines faltungsbasierten neuronalen Netzes.

2.3.4 Pooling

Zur Reduzierung der räumlichen Dimensionen der Eingabe und gleichzeitigen Vergrößerung des rezeptiven Feldes werden Pooling-Schichten eingesetzt, welche oftmals in CNNs zwischen zwei aufeinanderfolgenden Faltungsschichten eingearbeitet werden [Schirrmacher et al., 2017]. Im Zuge des Poolings werden jeweils mehrere Pixel innerhalb des rezeptiven Feldes durch eine zusammenfassende Statistik (Abbildung 2.10) ersetzt, was

durch Mittelwertbildung (Average-Pooling) oder durch die Wahl des maximalen Werts (Maximal-Pooling) erfolgen kann. Da es sich bei einem Pooling um eine nicht trainierbare Operation handelt, kann alternativ eine schrittweise Faltung ausgeführt werden. Wie im letzten Kapitel beschrieben, wird dabei eine Faltung mit einer Schrittweite von s realisiert und so ein Pooling von $s \times s$ bewirkt. Durch die zusätzlichen Parameter kann während des Trainingsprozesses die geeignetste Statistik erworben werden.

2.3.5 Training von neuronalen Netzen

Die Suche nach den optimalen Gewichten und Bias zur Generierung der zugehörigen Ausgabe von der Eingabe wird als Training der neuronalen Netze bezeichnet. Um die bestmöglichen Parameter zu bestimmen, ist die Definition einer Verlustfunktion (engl.: „Loss function“) vonnöten, welche die Genauigkeit der aktuellen Ausgabe des Netzes in Bezug auf den Referenzwert wiedergibt. Im Zuge dessen erfolgt eine Optimierung dieser Funktion unter Verwendung des Gradientenabstiegs. Zumeist findet dabei der mittlere absolute Fehler (engl. Mean absolute error (MAE)) Verwendung, welcher der pixelweisen, absoluten Differenz zwischen der Ausgabe $\hat{y} = \hat{f}(x)$ und dem Referenzwert y , gemittelt über alle Pixel, entspricht:

$$L_1(y, \hat{y}) = \frac{1}{N} \sum_n^N | \hat{y}_n - y_n | . \quad (2.23)$$

Ein weiteres Exempel umfasst den mittleren quadratischen Fehler, der determiniert ist als die pixelweise, quadratische Differenz zwischen der Ausgabe $\hat{y} = \hat{f}(x)$ und dem Referenzwert y , gemittelt über alle Pixel:

$$L_2(y, \hat{y}) = \frac{1}{N} \sum_n^N (\hat{y}_n - y_n)^2 . \quad (2.24)$$

2.3.6 Generalisierung der neuronalen Netze

Eine mit dem Trainieren von neuronalen Netzen einhergehende Schwierigkeit besteht darin, eine geeignete Annäherung einer Funktion zu finden, welche hierbei nicht nur für

den Trainingsdatensatz, sondern auch für weitere Datensätze zutrifft und in der Folge eine Verallgemeinerung zulässt. Diese Eigenschaft wird als Generalisierung der neuronalen Netze bezeichnet und geht damit einher, die Verlustfunktion für möglichst viele Datensätze gering zu halten. In Anbetracht dessen kann zwischen einer Unteranpassung (engl.: „Underfitting“) und einer Überanpassung (engl.: „Overfitting“) unterschieden werden, wobei Erstere auftritt, wenn die Verlustfunktion nicht einmal für den Trainingsdatensatz optimiert werden kann. Demgegenüber beinhaltet eine Überanpassung lediglich eine Anpassung des Modells an den Trainingsdatensatz, wodurch bei anderen Datensätzen hohe Werte in der Verlustfunktion resultieren. Im Zuge einer Unteranpassung des Modells können die Schichten der Neuronen oder auch die Anzahl der Neuronen pro Schicht erhöht werden, sodass eine Vergrößerung der trainierbaren Parameter folgt. Des Weiteren kann eine Überanpassung durch die Zunahme von Daten in den Trainingsdatensatz oder mittels künstlicher Datenerweiterung (engl.: „Data augmentation“), beispielsweise durch Transformation der Daten vermieden werden. Eine weitere Möglichkeit eine Überanpassung zu umgehen, stellt die sogenannte Dropoutmethode dar, innerhalb welcher einzelne Neuronen der Schichten in jeder Epoche ausgeschaltet und damit für den Berechnungsschritt nicht berücksichtigt werden. In der nächsten Epoche folgt eine erneute Aktivierung dieser Neuronen, während andere Neuronen ausgeblendet werden. Am Ende des Trainings findet wieder eine Aktivierung sämtlicher, vorhandener Neuronen statt, sodass einer Überanpassung an den Trainingsdatensatz erfolgreich entgegengewirkt wird.

3 Streustrahlkorrektur in der Dual-Source CT durch tiefe neuronale Netze

3.1 Material und Methoden

Das folgende Kapitel präsentiert ein neuartiges Verfahren zur Streustrahlkorrektur in der Dual-Source CT mithilfe künstlicher, neuronaler Netze. Um die dafür erforderlichen Trainings- und Validierungsdaten zu generieren, wird eine Monte-Carlo-Simulation durchgeführt. Anschließend werden die durch unterschiedliche Ein- und Ausgaben variierbaren Netzwerkarchitekturen beschrieben, woraufhin entsprechende Verlustfunktionen zum Training der neuronalen Netze vorgestellt werden. Schlussendlich wird die Anwendung der Streustrahlkorrektur und im Zuge dessen die Rekonstruktion sowie die Auswertung der korrigierten CT-Bilder dargestellt. Die angewandten Methoden wurden im Laufe dieser Forschungsarbeit bereits auf Konferenzen vorgestellt und in Publikationen veröffentlicht [Erath et al., 2021b, Erath et al., 2019, Erath et al., 2020, Vöth, 2019, Vöth et al., 2019, Erath et al., 2021a, Erath et al., 2022].

3.1.1 Monte-Carlo-Simulation

Zum Trainieren und Validieren der neuronalen Netze sind Streustrahlverteilungen vonnöten, welche mittels MC-Simulationen oder Messungen erzeugt werden können [Erath et al., 2019]. Durch das Auslassen einer Röntgenquelle und damit einhergehend die Ver-

messung des nicht bestrahlten Detektors kann die Querstreuung direkt gemessen werden. Im Gegensatz dazu kann die Längsstreuung mithilfe sogenannter „Split Scans“ ermittelt werden. Hierbei werden die Daten jeweils mit der größten und kleinsten möglichen Kollimierung erfasst, wobei Letztere nahezu keine Längsstreuung hervorruft. Dies führt dazu, dass die Differenz dieser beiden Messwerte näherungsweise die Längsstreuung ergibt.

Da diese Methodik aufgrund der damit verbundenen Strahlenbelastung nicht am Patienten angewendet werden kann, werden die Streustrahlverteilungen mit einer MC-Simulation generiert (vgl. Abschnitt 2.2.1).

Zu Beginn wird dazu eine Photonenenergie E aus dem vorgefilterten Tucker-Spektrum entnommen. Daraufhin folgt unter Berücksichtigung des Lambert-Beer'schen Gesetzes eine Wegberechnung des jeweiligen Photons zum ersten Wechselwirkungspunkt. Dort werden die Interaktionen in Abhängigkeit vom Material und der Photonenenergie E entsprechend den Beiträgen zum vollständigen Abschwächungskoeffizienten, worunter die Compton-Streuung, der photoelektrische Effekt und die Rayleigh-Streuung fallen, simuliert. Während das Photon gestreut wird, kann der Streuwinkel aus dem differentialen Querschnitt des Streuungseffekts bei der Energie E bestimmt werden. Währenddessen wird die Bewegungsrichtung und Energie des Photons entsprechend aktualisiert. Anschließend wird der Weg zum nächsten Wechselwirkungspunkt und damit verbunden die Korrelationen simuliert. Diese Verfahrensweise wird fortgesetzt, bis das Photon letztendlich den photoelektrischen Effekt erfährt oder den Patienten verlässt und so vom Detektor erfasst werden kann.

Zur Optimierung der MC-Simulation werden sogenannte Varianzreduzierungstechniken eingesetzt [Mainegra-Hing and Kawrakow, 2010]. Im Hinblick darauf, wird unter anderem eine Photonenaufspaltung vorgenommen, sodass zu diesem Zweck verschiedene Kopien eines im Wechselwirkungsprozess befindlichen Photons mit der gleichen Bewegungsrichtung und Energie, allerdings mit reduzierter Gewichtung, erstellt werden. Die folgenden Interaktionen der gespaltenen Photonen werden unabhängig voneinander simuliert.

Die Geometrie der Simulation ist an den Dual-Source CT Scanner SOMATOM Force (Siemens Healthineers, Forchheim, Deutschland) adaptiert. Die vollständigen Spezifi-

Tabelle 3.1: Technische Spezifikationen der simulierten DSCT (Messsystem A).

Simulierte DSCT-Geometrie	
Kollimation in Längsrichtung am Drehzentrum	70.2 mm
Durchmesser des Messfeldes	500 mm
Detektorform	Zylindersegment
Anzahl der Detektorzeilen	96
Anzahl der Detektorspalten	920
Abstand der Röntgenröhre zum Drehzentrum	595 mm
Abstand des Drehzentrums zum Detektor	490.6 mm
Winkel zwischen beiden Messsystemen	95°
Art des Streustrahlrasters	2D

kationen sind in der Tabelle 3.1 aufgelistet. Die Streustrahlung wird für Detektor A simuliert, welcher die Längsstreuung der Röntgenröhre A sowie die Querstreuung der Röntgenröhre B empfängt. Die für die MC-Simulation notwendige Verteilung des Abschwächungskoeffizienten wird aus klinischen Ganzkörper-CT-Daten gewonnen, wobei angenommen wird, dass sich die Patienten aus insgesamt vier verschiedenen Materialien beziehungsweise Substanzen (Luft, Fettgewebe, Weichgewebe und Knochen) zusammensetzen. Basierend auf CT-Schwellwerten, wird weiterhin jedem Voxelpunkt ein Material zugeordnet. Die Simulation der dazugehörigen Primärstrahlung erfolgt durch eine polychromatische Vorwärtsprojektion, während die Intensitäten der Quer- und Längsstreuung mithilfe der MC-Simulation bestimmt werden. Im Zuge dessen werden außerdem die Röntgenenergiespektren mit dem semi-empirischen Modell von Tucker et al. [Tucker et al., 1991] simuliert.

Insgesamt werden von 22 Patienten CT-Scans an 14 verschiedenen z-Positionen simuliert, wovon 14 für das Training der neuronalen Netze, zwei als Validierungsdaten während des Trainings und die anderen sechs zum anschließenden Testen der neuronalen Netze verwendet werden. Die Streustrahlung wird dabei jeweils im Abstand von zehn Grad simuliert. Daraus resultieren 7056 gepaarte Daten für das Training, 1008 für die Validierung und 3024 zum Testen der trainierten Netze. Da die Querstreuung besonders an der Oberfläche des Patienten aufkommt, ist es von wesentlicher Bedeutung, in die Trainings- und Validierungsdaten Patienten und z-Positionen mit unterschiedlichen Oberflächen aufzunehmen. Damit eine möglichst große Vielfalt in jenen Datensätzen




Abbildung 3.1: Beispielsinogramme eines Patientenscans [Erath et al., 2021b]. Der Fächerwinkel verläuft entlang der horizontalen Achse; die vertikale Achse stellt die Richtung des Projektionswinkels dar. a) Die logarithmische Abschwächung $p = -\ln(I/I_0)$ wird für die Eingabe der neuronalen Netzes verwendet. $C = 0,25$, $W = 0,5$ b) Längsstreuungsinogramm desselben Patientenscans. $C = 6 \times 10^{-4}$, $W = 6 \times 10^{-4}$ c) Entsprechende Querstreuintensität. $C = 6 \times 10^{-4}$, $W = 6 \times 10^{-4}$ d) Verhältnis der Streustrahlung zur Primärstrahlung. $C = 0,05$, $W = 0,05$.

gewährleistet werden kann, werden darüber hinaus verschiedene klinische Situationen und damit Fragestellungen berücksichtigt. Dazu gehört beispielsweise der Einsatz von Kontrastmittel oder auch der Umstand, dass es einigen Patienten (z.B. Traumafälle in einem Notfall-CT) während des Scans nicht möglich ist, die Arme über den Kopf zu heben. Dies hat schließlich einen Einfluss auf die Streustrahlverteilung und wirkt sich damit auch auf die Bildqualität aus [Kahn et al., 2014]. Diesbezüglich ist in Abbildung 3.1 ein Beispiel der simulierten Primär- und Streustrahlung veranschaulicht.

3.1.2 Tiefe neuronale Netze zur Schätzung der Streustrahlung

Durch die MC-Simulation der Streustrahlverteilungen und die Vorwärtsprojektionen stehen gepaarte Daten für das Training der neuronalen Netze zur Verfügung. Auf der Streustrahlschätzung von Maier et al. [Maier et al., 2018, Maier et al., 2019b] beruhend, werden verschiedene neuronale Netze zur Korrektur der Längs- und Querstreuerung vorgestellt. In Bezug darauf enthält die Tabelle 3.2 eine Übersicht über die verschiedenen Algorithmen. In ersten Experimenten konnte gezeigt werden, dass die Architektur des ursprünglichen DSE-Netzes zur Korrektur der Längsstreuung ohne vorhandene Querstreuerung wie auch letztendlich zur Schätzung der Querstreuerung verwendet werden kann [Vöth, 2019, Vöth

Tabelle 3.2: Überblick über die verschiedenen Netzwerkarchitekturen: Auf der linken Seite sind die Bezeichnungen der unterschiedlichen Algorithmen angegeben, wobei jedes Netz für die Schätzung der Längs- (fDSE) oder Querstreuung (xDSE) trainiert werden kann. In der mittleren Spalte werden die Algorithmen kurz beschrieben. Die Größe der Eingabeschicht ist in der rechten Spalte angegeben.

Bezeichnung des Algorithmus	Beschreibung	Größe der Eingangsschicht
DSE, 2D, 1 → 1	DSE mit 2D Faltungen, 1 Projektion rein, 1 raus	$512 \times 16 \cdot 1$
DSE, 2D, xPEP, 1 → 1	DSE mit 2D Faltungen, Querstreuapproximierung pep-Modell, 1 Projektion rein, 1 raus	$512 \times 16 \cdot 2$
DSE, 2D, axSSE, 1 → 1	DSE mit 2D Faltungen, Querstreuapproximierung basierend auf einer Rekonstruktion aus zwei orthogonalen Projektionen, 1 Projektion rein, 1 raus	$512 \times 16 \cdot 2$
DSE, 2D, xSSE, 1 → 1	DSE mit 2D Faltungen, Querstreuapproximierung basierend auf einer Rekonstruktion von vielen Projektionen, 1 Projektion rein, 1 raus	$512 \times 16 \cdot 2$
DSE, 2D, few views, 3 → 1	DSE mit 2D Faltungen, 3 Projektionen rein, 1 raus	$512 \times 16 \cdot 3$
DSE, 3D, 36 → 36	DSE mit 3D Faltungen, 36 Projektionen rein, 36 raus	$512 \times 16 \times 36 \cdot 1$

et al., 2019]. Da es sich bei den folgenden Analysen um ein realitätsnäheres, klinisches Szenario handelt, wurde der Algorithmus zur Streustrahlschätzung optimiert und so die Netzwerkarchitektur angesichts der zu schätzenden Querstreueung angepasst. Bei einem Dual-Source CT-Scan setzt sich das gemessene Signal I_{total} aus der Summe der Primärstrahlung I_{prim} , der Längsstreuung $I_{\text{Längs}}$ und der Querstreueung I_{Quer} wie folgt zusammen:

$$I_{\text{total}} = \frac{I_{\text{prim}}}{I_0} + \frac{I_{\text{Längs}}}{I_0} + \rho \cdot \frac{I_{\text{Quer}}}{I_0}. \quad (3.1)$$

I_0 beschreibt dabei die ungeschwächte Intensität der Längsstreuung am Detektor. Dazu hängt die gemessene Intensität der Querstreueung vom Röhrenstrom der anderen Röntgenröhre ab. Demzufolge ist die Amplitude der Querstreueung umso höher, je höher der Röhrenstrom an der anderen Röhre ist. Da beide Röhren mit unterschiedlichen Röhrenströmen betrieben werden können, steht ρ für deren Verhältnis zueinander. Der Wert von ρ ist bei einer Messung bekannt und wird im Zuge des Trainings für jede Projektion zufällig auf einen Bereich zwischen 0,25 und 4 festgelegt, um die bei der DSCT typischerweise auftretenden Röhrenstromverhältnisse vollständig abzudecken. Wie von Maier et al. [Maier et al., 2018, Maier et al., 2019b] demonstriert, hat sich die Anwendung der logarithmierten Projektionsdaten p oder des pe^{-p} -Modells [Ohnesorge et al., 1999a, Hangartner, 1987] als äußerst effektive Netzeingabe im Trainieren der neuronalen Netze erwiesen. Da das pe^{-p} -Modell besonders für die Berechnung der Längsstreuung geeignet ist, werden daher zum Training der neuronalen Netzen die logarithmierten Projektionsdaten als Eingabe verwendet:

$$p = -\ln(I_{\text{total}}). \quad (3.2)$$

Zur Optimierung der zu schätzenden Querstreueung kann als anfängliche Information eine Annäherung der Querstreueung berechnet werden, welche als zusätzliche Eingabe für das neuronale Netz verwendet werden kann. Die Kalkulationen dieser möglichen Annäherungen (xSSE, xSSEiterativ, xpép) werden in den nächsten Abschnitten im Detail beschrieben. Weil in Anbetracht einer Schätzung der Querstreueung vor allem Informa-

tionen über die Oberfläche des Patienten essenziell sind, wurden spezielle Netzwerke mit zusätzlichen Projektionen zur Eingabe in das Netz entwickelt. Beim Training mit zweidimensionalen Faltungsoperatoren werden dem Netz dabei wenige vorherige und folgende Projektionen als Eingabe mitgegeben, während das Netz jeweils die Streustrahlintensität von einer Projektion (DSE 2D few views) schätzt. Dagegen führt ein mittels dreidimensionalen (3D) Faltungsoperatoren trainiertes Netz zu einer Eingabe des kompletten Projektionsbereichs (z.B. 180°), sodass in der Folge die zugehörige Streustrahlung (DSE 3D) für den ganzen Bereich geschätzt werden kann.

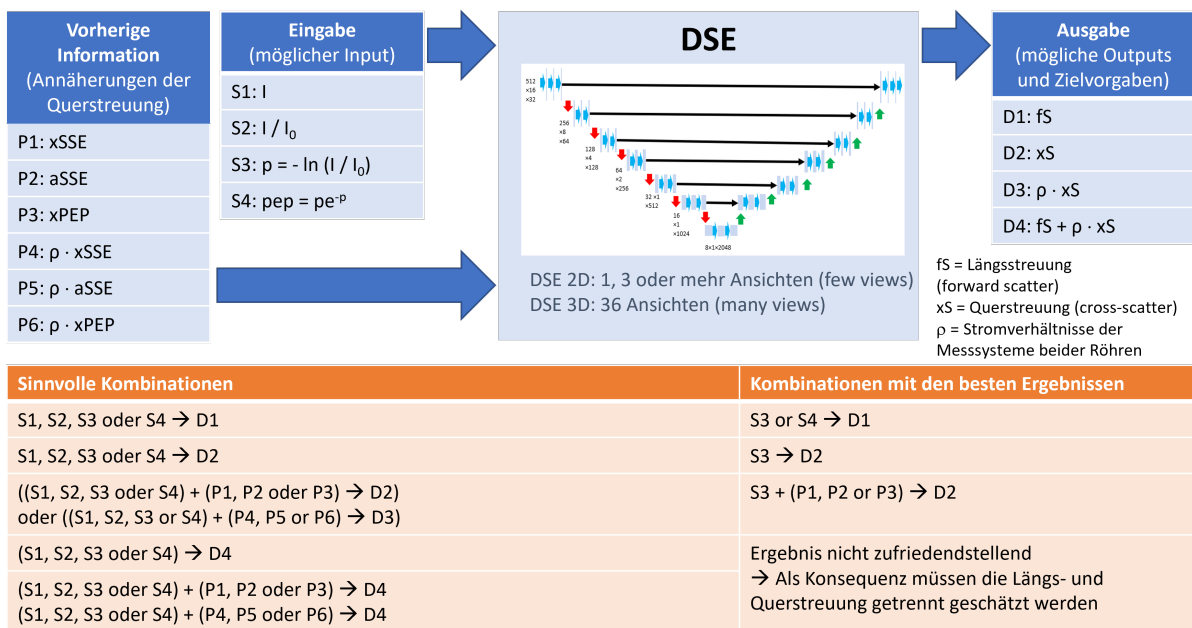


Abbildung 3.2: Übersicht über die DSE-Versionen, die sich durch den Eingangs- und Ausgangstyp in verschiedenen Kombinationen voneinander unterscheiden. Von links nach rechts: 1) Zusätzliche Querstreueannäherung, die dem Netz als Vorabinformation zur Verfügung gestellt wird. 2) Eingangsdaten, 3) DSE-Netz, dessen Architektur davon abhängt, ob es sich um einen DSE-Ansatz mit einer Einzelansicht, mit wenigen oder vielen Ansichten handelt. 4) Verschiedene mögliche Ausgaben des Netzes, die während der Inferenz bereitgestellt oder die in der Verlustfunktion verwendet werden. Unten: Mögliche sowie gut funktionierende Kombinationen. Da eine direkte Abbildung auf D4 keine guten Ergebnisse liefert, werden Längs- und Querstreueung getrennt mit zwei separaten Netzen geschätzt.

In Bezug darauf ist in Abbildung 3.2 eine Übersicht über die möglichen Ein- und Ausgaben für die neuronalen Netze illustriert. Während des Netztrainings zeigte sich, dass die Schätzung der Gesamtsumme aus Längs- und Querstreueung zu weniger zufriedenstellenden Ergebnissen geführt hat als die jeweilige Schätzung durch separate neuronale

Netze. Aus diesem Grunde werden im Folgenden gesonderte Netze zur Schätzung der Längs- und Querstreueung trainiert. In dessen Verlauf wurde außerdem festgestellt, dass die Verwendung des bekannten ρ -Wertes zur nachträglichen Skalierung der Querstreueung bessere Ergebnisse mit sich bringt als die Skalierung der Querstreueannäherung mit ρ und das Training des Netzwerks zum Erlernen der skalierten Querstreueung. Die Schätzung brachte bessere Ergebnisse hervor, wenn die geschätzte Querstreueung mit dem bekannten ρ -Wert multipliziert wird.

Das gewählte Netzwerk (Abbildung 3.3) ist durch eine U-förmige Architektur gekennzeichnet. Zudem hat es einen „Encoder-Decoder“-Pfad mit zusätzlichen „Skip-Connections“, um hochfrequente Anteile von der Eingabe in die Ausgabe zu übertragen und auf diesem Wege die Trainingskonvergenz zu vereinfachen. Der „Encoding“-Pfad, welcher verschiedene Merkmale aus dem Eingangsbild generiert, besteht dabei aus sieben verschiedenen Ebenen. Andererseits setzt sich jede Ebene wiederum aus drei Faltungsoperatoren mit einem 3×3 Faltungskern und einer Aktivierungsfunktion (ReLU) zusammen. In Abhängigkeit vom entsprechenden Netzwerk werden zwei- oder dreidimensionale Faltungsoperatoren verwendet. Die örtliche Auflösung wird nach jeder Ebene durch eine schrittweise Faltung mit einer Größe von zwei halbiert. Demgegenüber wird die Anzahl der Merkmale nach jeder Ebene verdoppelt, beginnend mit einem Zahlenwert von 16. Der „Decoding“-Pfad erzeugt der niedrig-dimensionalen Kodierung entsprechend die Ausgabe mit der gewünschten örtlichen Auflösung.

DSE 2D

Das DSE 2D Netz wird dahingehend trainiert, anhand einer einzelnen Röntgenprojektion die zugehörige Längs- oder Querstreueung zu schätzen. Wie in der Abbildung 3.3 veranschaulicht, erhält es dazu die aktuelle Projektion als Eingabe und wird so darauf trainiert, die Längs- oder Querstreueung zu der Projektion zu schätzen. Zur Optimierung kann eine zusätzliche Annäherung der Querstreueung berechnet und als weitere Eingabe in das Netz aufgenommen werden.

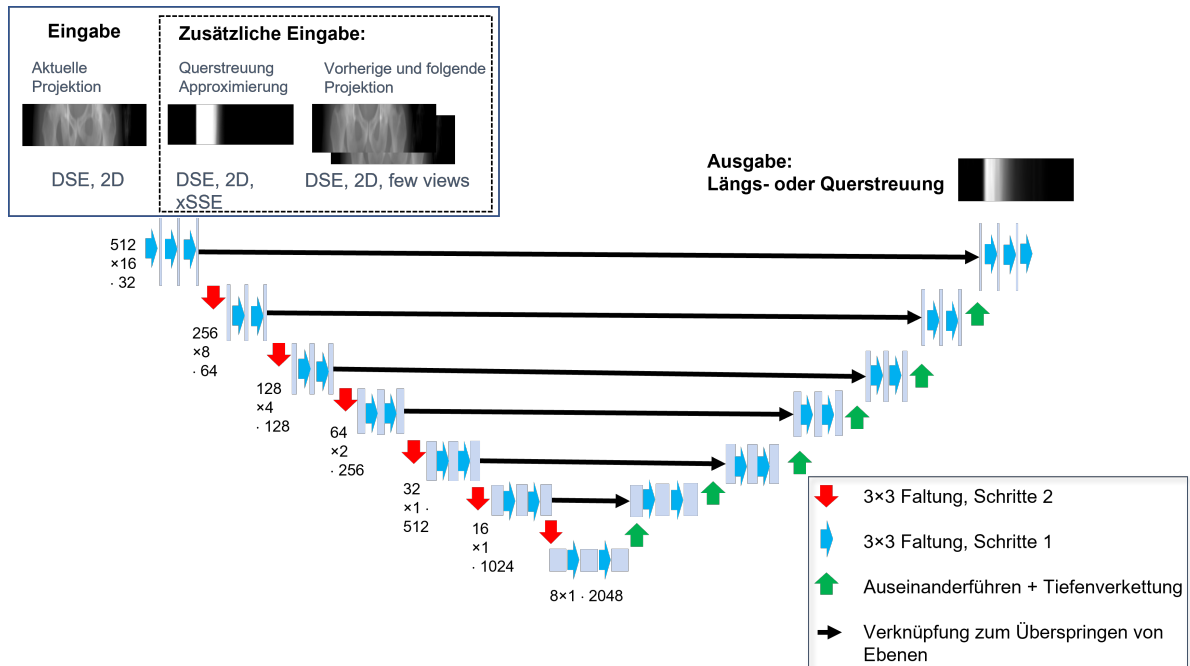


Abbildung 3.3: Darstellung der Netzwerkarchitektur: Je nach Algorithmus kann das neuronale Netz zur aktuellen Eingabe eine zusätzliche Querstreueapproximierung oder weitere Projektionen als Eingabe bekommen. Überdies kann es dazu trainiert werden, die Längs- oder Querstreue zu schätzen, weist eine U-förmige Architektur auf und besteht aus einem „Encoder-Decoder“-Pfad mit zusätzlichen „Skip-Connections“.

Vorabinformationen als zusätzliche Eingabe für xDSE

Um die Robustheit und die Genauigkeit des Netzes zu verbessern, kann eine zusätzliche Eingabe als Lösungsansatz äußerst nützlich sein. Diese Vorabinformationen erwiesen sich für die Netze als effektive Unterstützung zur Schätzung der Querstreuung. Im Allgemeinen soll mit der Integration der Vorabinformationen eine grobe Streustrahlschätzung erreicht werden, wie exemplarisch im Vorfeld eine Berechnung der Streuschätzung erster Ordnung. In diesem Zusammenhang ist von Relevanz, dass die Berechnung der Vorabinformationen eine nicht zu große Laufzeit benötigt, sodass dies sonst in einer Verlangsamung der Streustrahlkorrektur resultieren würde.

DSE xSSE




Abbildung 3.4: Schematische Darstellung der Berechnung der Querstreuapproximation (xSSE) [Erath et al., 2021b]. Hierfür wird zunächst eine Bildrekonstruktion ohne Streustrahlartefaktkorrektur berechnet, woraufhin dann das rekonstruierte Volumen zur Berechnung der Abschwächung des gestreuten Photons Verwendung findet. Daher wird $I_2(x)$ als Produkt aus der Schwächung von der Röntgenquelle I_0 zur Voxelposition (x, y) : $p_{in}(x, y)$ multipliziert mit dem linearen Absorptionskoeffizienten $\mu(x, y)$ und der Schwächung vom Voxel zum Detektor $p_{out}(x, y)$. Diese Querstreuapproximation kann als zusätzliche Eingabe für das neuronale Netz eingesetzt werden.

Eine weitere Option für die Schätzung der Querstreuung durch neuronale Netze umfasst den DSE-Algorithmus xSSE (engl.: „Single Cross Scatter Approximation“) [Erath et al., 2020, Vöth, 2019]. Dazu erfolgt eine Berechnung der Querstreuannäherung erster Ordnung. Im Folgenden wird der entsprechende Algorithmus beschrieben: Im ersten Schritt wird eine Rekonstruktion ohne Streustrahlkorrektur durchgeführt. Das daraus gewonnene, rekonstruierte Volumen wird im Weiteren Verlauf zur Simulation der Wechselbeziehungen von Röntgenstrahlen und Materie unter der Annahme verwendet, dass die Querstreuung lediglich in die Richtung der Primärquelle abgelenkt wird. Der Grundgedanke dahinter besteht darin, dass das auf dem Detektor angebrachte Streustrahlraster die Querstreuung aus anderen Winkeln absorbieren würde. Diesbezüglich wird in Abbildung 3.4 ein vereinfachtes Schema zur Berechnung der Querstreuapproximation präsentiert. Hierbei sei darauf hingewiesen, dass die xSSE-Näherung für eine Kegelstrahlgeometrie mit einem zylindrischen Detektor berechnet wird. Um das Grundprinzip näher zu beleuchten, wird der Algorithmus für eine Parallelstrahlgeometrie erläutert. Außerdem wird angenommen, dass die Röntgenquellen A und B Photonen parallel zur y - und x -Achse emittieren. Das grundlegende Konzept von xSSE lautet: $p_{\text{in}}(x, y)$ ist die Abschwächung von der Querröhre zu dem Voxel an der Position (x, y) :

$$p_{\text{in}}(x, y) = \int_{-\infty}^x d\hat{x} \mu(\hat{x}, y). \quad (3.3)$$

Der lineare Abschwächungskoeffizient $\mu(x, y)$ kann interpretiert werden als die Wahrscheinlichkeit pro Weglänge, mit welcher ein Photon am Punkt (x, y) wechselwirkt und die proportional zur Wahrscheinlichkeit des Auftretens von Querstreuung in (x, y) ist. Entsprechend dazu, stellt $p_{\text{out}}(x, y)$ die Abschwächung vom Voxel (x, y) zum Detektor dar:

$$p_{\text{out}}(x, y) = \int_y^{\infty} d\hat{y} \mu(x, \hat{y}). \quad (3.4)$$

Daraus ergibt sich eine Bestimmung der xSSE-Annäherung $I_2(x)$ aus:

$$I_2(x) \propto \int_{-\infty}^{\infty} dy e^{-p_{\text{in}}(x, y)} \mu(x, y) e^{-p_{\text{out}}(x, y)}. \quad (3.5)$$

Das xSSE DSE-Netz erhält zwei Eingaben, wozu die gemessenen Projektionsdaten und die zugehörigen xSSE-Querstreuan näherungen gehören. Mit deren Hilfe wird das auf zweidimensionalen Faltungsoperatoren basierende, neuronale Netz trainiert, die dazugehörige Querstreuung zu schätzen. Zur Berechnung der xSSE-Annäherung sind ausreichende Projektionsdaten für die initiale Bildrekonstruktion notwendig. In den nachfolgenden Abschnitten werden zwei alternative Querstreuan näherungen vorgestellt, bei welchen die jeweilige Annäherung lediglich aus zwei Projektionen berechnet wird und somit simultan zur Aufnahme erfolgen kann.

Vereinfachte xSSE-Berechnung

Da die xSSE-Annäherung eine initiale Rekonstruktion erfordert, kann die Berechnung erst zu dem Zeitpunkt beginnen, an dem einerseits die Datenerfassung und andererseits die anschließende erste Rekonstruktion abgeschlossen ist. Dabei sollte beachtet werden, dass dieser Prozess im Rahmen der Echtzeitanwendung zu langsam sein könnte. Die Idee hinter der vereinfachten xSSE (axSSE)-Berechnung besteht darin, die anfängliche und aus allen Projektionen eines Scans berechnete Rekonstruktion von xSSE durch eine äußerst komprimierte Rekonstruktion zu ersetzen. Dazu wird diese wiederum aus den beiden aktuellen Projektionen der Detektoren A und B berechnet. In Bezug darauf wird die simultane algebraische Rekonstruktionstechnik (engl.: „Simultaneous algebraic reconstruction technique (SART)“) [Kak and Slaney, 1988] mit einer Nicht-Negativitäts-Beschränkung angewandt, damit ein Bild f unter Verwendung der Aktualisierungsgleichung rekonstruiert werden kann:

$$f_{\nu+1} = f_{\nu} + \frac{1}{\mathbf{X}^T \cdot \mathbf{1}} \mathbf{X}^T \cdot \frac{p - \mathbf{X} \cdot f_{\nu}}{\mathbf{X} \cdot \mathbf{1}}. \quad (3.6)$$

Hierbei bezeichnet X die Röntgentransformation, was einer Vorwärtsprojektion entspricht, und X^T ihre Transponierte, also eine Rückprojektion. In diesen Experimenten werden zehn Iterationen SART durchgeführt. Da diese iterative Rekonstruktion auf nur zwei Projektionen beruht, kann die vereinfachte xSSE-Berechnung (axSSE) dem xSSE-Ansatz nicht überlegen sein.

xPEP

Eine weitere, ergänzende Alternative zur Annäherung der Querstreuung ohne vorheriger Berechnung einer Bildrekonstruktion stellt der xPEP-Algorithmus dar. Das dazugehörige xPEP-Modell wurde durch das zur Annäherung an die Längsstreuung entwickelte PEP-Modell angeregt [Hangartner, 1987, Ohnesorge et al., 1999a].




Abbildung 3.5: Das xPEP-Modell [Erath et al., 2021b] geht davon aus, dass die Abschwächung gleichmäßig auf verschiedenen Stäbchen verteilt ist. Durch Integration entlang dieser Stäbchen kann die Querstreuung angenähert und als zweite Eingabe für das neuronale Netz benutzt werden.

Die Grundidee besteht darin, die gemessenen Intensitäten beider Detektoren zu verwenden und dabei anzunehmen, dass die zugehörige Schwächung gleichmäßig entlang der Strahlenrichtung verteilt sind. Daraus ergibt sich ein aus gleichmäßigen Stäbchen

zusammengesetztes CT-Bild (Abbildung 3.5). Anfänglich wird das Integral über diese Stäbchen berechnet, um die Intensität der Photonen $I_1(x)$ am Punkt x zu erhalten:

$$I_1(x) = I_0 \exp\left(-c_1 \int_{-\infty}^x dx p_A(x)\right). \quad (3.7)$$

I_0 kennzeichnet die Primärstrahlungsintensität ohne Abschwächung, die Konstante c_1 dagegen einen experimentell bestimmbaren Faktor und $p_A(x)$ die gemessene logarithmische Abschwächung von Detektor A an der Position x . Mit $I_1(x)$ wird das Verfahren mit der gemessenen Intensität von Detektor B wiederholt:

$$I_2(x) = I_1(x) \exp\left(-c_2 \int_y^{\infty} dy p_B(y)\right). \quad (3.8)$$

$I_2(x)$ markiert die Annäherung der Querstreuung für Detektor A. Der Gleichung (3.7) entsprechend, bezeichnet $p_B(y)$ die an der Position y des Detektors B gemessene logarithmische Abschwächung und weiterhin c_2 eine Konstante. In den folgenden Experimenten wurden die Konstanten c_1 und c_2 auf 0,005 festgelegt, was schlussendlich mit den vorhandenen Trainings- und Validierungsdaten gute Annäherungen der Querstreuung mit sich brachte. Da die xPEP-Annäherung mit nur zwei Projektionen berechnet wird und damit einhergehend ein geringeres Maß an Informationen über die für die Querstreuung relevante Patientenoberfläche zur Verfügung stehen, kann das xPEP- und axSSE Modell insgesamt nicht vorteilhafter als die xSSE-Annäherung sein.

DSE 2D mit wenigen Ansichten

Im Rahmen der Entstehung von Querstreuung wird ein Großteil der Photonen an der Oberfläche des Patienten gestreut [Petersilka et al., 2010]. Wie in Abschnitt 3.1.2 bereits beschrieben, werden für die DSE-Netzarchitektur 2D Faltungskerne eingesetzt, um Informationen aus den Detektorzeilen und Spalten zur Optimierung der vorherzusagenden Streustrahlung zu gewinnen. Die Merkmale können so jedoch nicht über mehrere Projektionen hinweg generiert werden. Da die Querstreuung meist an der Oberfläche des Patienten eintritt, kann die Einbeziehung von Daten aus verschiedenen Blickwinkeln die Leistung und die Robustheit des Algorithmus verbessern. Um dem neuronalen

Netz die Möglichkeit zu geben, Informationen über Projektionen hinweg zu verarbeiten, werden ergänzende Projektionen als Eingabe hinzugefügt. Im einfachsten Fall erhält das neuronale Netz insgesamt drei Projektionen mit einem bestimmten Winkelversatz, darunter eine vorherige, die aktuelle und eine nachfolgende Projektion. Zur Optimierung des Winkelversatzes wird die Auswirkung verschiedener Winkelabstände auf die Ergebnisse der Streustrahlschätzung eruiert. Davon abgesehen, dass das neuronale über drei Eingabekanäle statt einem verfügt, hat diese DSE-Modifikation die selbe, wie auch in den vorherigen Abschnitten beschriebene Architektur.

DSE 3D mit vielen Ansichten

Damit dem Netz die Option offen steht, noch weitere Informationen über verschiedene Projektionen mit einzubeziehen, wird eine dreidimensionale Netzarchitektur getestet. Das neuronale Netz bekommt hierbei somit mehrere Projektionen als Eingabe, während darüber hinaus dreidimensionale Faltungskerne eingesetzt werden. Im Gegensatz zu den vorherigen DSE-Algorithmen, schätzt die 3D-Version die Streustrahlung für den gesamten Bereich dieser Projektionen. Im Zuge dessen erstreckt sich das Training des Netzes mit Projektionen auf einen Bereich von 360° eines Kreisscans, welcher so gewählt wurde, dass das Netz Projektionen aus allen Blickwinkeln erhält und auf diesem Wege relevante Informationen über die entsprechenden Winkel gewinnen kann. Erwähnenswert ist hierbei, dass dieser Ansatz ausschließlich für Kreisscans untersucht wird, sodass eine Verallgemeinerung für eine Spiralmessung nicht erfolgt ist. Dies ist auf die bei den verschiedenen Untersuchungen anzuwendenden, unterschiedlichen Pitchfaktoren zurückzuführen.

3.1.3 Verlustfunktion

Der von der Streustrahlung ausgehende Einfluss auf die Bildqualität ist nicht von der absoluten Streustrahlintensität abhängig, sondern vom Verhältnis der gestreuten Photonen zu den absorbierten Primärstrahlen. Dieses Streu-Primär-Verhältnis (engl.: „Scatter-to-primary ratio (SPR)“) ist definiert als der Anteil der gestreuten Röntgenquanten zu der

Primärstrahlung. Unter der Prämisse, dass I_{prim} das Primärsignal und I_{scatter} das Signal der gestreuten Photonen darstellt, werden die Projektionsdaten p gebildet aus:

$$p = -\ln\left(\frac{I_{\text{prim}} + I_{\text{scatter}}}{I_0}\right). \quad (3.9)$$

Um zu demonstrieren, dass die Einfluss der Streustrahlung auf die Bildqualität durch das SPR bedingt wird, kann die Gleichung umgestellt werden zu [Bruder et al., 2008]:

$$p = -\ln(I_{\text{prim}}) - \ln\left(1 + \frac{I_{\text{scatter}}}{I_{\text{prim}}}\right) + \ln(I_0). \quad (3.10)$$

Daraus ist ableitbar, dass die gestreuten Photonen insbesondere bei Fällen mit einer hohen Abschwächung zu einem gesteigerten SPR und dadurch zu erheblichen Streustrahlartefakten im rekonstruierten Bild führen können. Darauf Bezug nehmend, wird die Erforderlichkeit einer hochpräzisen Schätzung sowie Korrektur der Streustrahlartefakte deutlich. Zur Berücksichtigung des SPR in der vorgelegten Optimierung, wird der Streuung-zu-Primär-gewichteter mittlerer absoluter Prozentfehler (engl.: „Scatter-to-primary-weighted mean absolute percentage error (SPMAPE)“) als Verlustfunktion für das Training der neuronalen Netze vorgestellt. $I_{\text{scatter, DSE}}$ drückt die Streustrahl-schätzung des neuronalen Netzes aus und $I_{\text{scatter, MC}}$ dagegen die Streustrahlintensität, bestimmt durch die Monte-Carlo-Simulation, als das Label. Abhängig von der Ausgabe des neuronalen Netzes, entspricht die Streustrahlung der Längs- oder Querstreuung. Während N die Anzahl der Detektorpixel angibt, kann die SPMAPE-Verlustfunktion folgendermaßen definiert werden:

$$\text{SPMAPE} = \frac{1}{N} \sum \left| \frac{I_{\text{scatter, MC}} - I_{\text{scatter, DSE}}}{I_{\text{scatter, MC}}} \times \frac{I_{\text{scatter, MC}}}{I_{\text{prim}}} \right| = \frac{1}{N} \sum \left| \frac{I_{\text{scatter, MC}} - I_{\text{scatter, DSE}}}{I_{\text{prim}}} \right|. \quad (3.11)$$

Um den Einfluss der Verlustfunktion auf die Streustrahlkorrektur zu bewerten, wird die SPMAPE mit einer weiteren allgemein bekannten Verlustfunktion zur mittleren quadratischen Abweichung (engl.: „Mean squared error (MSE)“) verglichen:

$$\text{MSE} = \frac{1}{N} \sum |I_{\text{scatter, MC}} - I_{\text{scatter, DSE}}|^2. \quad (3.12)$$

3.1.4 Streustrahlsubtraktion

Infolge der vom Netz prognostizierten Streustrahlung $I_{\text{scatter, DSE}}$ für jeden Projektionswinkel, muss die Streustrahlschätzung von dem gemessenen Signal abgezogen werden. Vor dieser Subtraktion erfolgt eine Glättung der vom neuronalen Netz geschätzten Streustrahlsignale mithilfe eines Gauß-Filters ($\sigma = 5$), um eine Herausfilterung noch vorhandener, hochfrequenter Anteile herbeizuführen. Bei einem DSCT-Scan setzt sich das gemessene Signal I_{total} aus der Primärstrahlung I_{prim} und den gestreuten Photonen zusammen ($I_{\text{scatter}} = I_{\text{forward}} + \rho I_{\text{cross}}$). Zur Korrektur der Streustrahlsignale wird die Streustrahlintensität also von dem gemessenen Signal subtrahiert. Um zu verhindern, dass die Strahlung überschätzt wird und das gemessene Signale nach der Korrektur einen Wert von null oder gar einen negativen Wert einnimmt, wird ein relatives Clipping eingeführt. Dabei entspricht das korrigierte Signal I_{corr} nach der Streustrahlkorrektur zumindest 1% des gemessenen Signals I_{total} :

$$I_{\text{corr}} = \begin{cases} I_{\text{total}} - I_{\text{scatter, DSE}}, & \text{if } I_{\text{scatter, DSE}} < 0.99I_{\text{total}} \\ I_{\text{total}} - 0.99I_{\text{total}}, & \text{otherwise} \end{cases}. \quad (3.13)$$

3.1.5 Bildrekonstruktion

Zur Eruierung des Einflusses der Streustrahlkorrektur auf das CT-Bild werden die korrigierten Projektionsdaten für die Bildrekonstruktion verwendet. Im Zuge dessen wird die von Kachelrieß et al. [Kachelrieß et al., 2004] eingeführte, erweiterte parallele Rückprojektion eingesetzt.

3.1.6 Vergleichsmethode: messbasierte Streustrahlkorrektur

Zur Bewertung der Streustrahlkorrektur werden die streustrahlkorrigierten Bilder mit einer messbasierten Korrektur, wie in 2.2.3 eingeführt, verglichen. Bei der messbasier-

ten Korrektur wird die Streustrahlung mit Sensoren außerhalb des Fächerstrahls in z-Richtung gemessen und direkt korrigiert. Um diese Methode zu simulieren wird eine lineare Interpolation zwischen der ersten und der letzten Detektorzeilen der simulierten Streustrahlungsintensitäten durchgeführt. Bei der Auswertung sollte berücksichtigt werden, dass die Interpolation zwischen der ersten und der letzten Detektorzeile, wie hier angewandt, zu etwas besseren Ergebnissen führt, als wenn die Streusensoren außerhalb des Detektors liegen, d.h. ein paar Millimeter vom Detektor entfernt, wie es bei einem echten Scanner der Fall wäre.

3.1.7 Trainingsprozess der neuronalen Netze

Die neuronalen Netze werden in Tensorflow Version 2.0 als Open-Source-Framework implementiert und daraufhin trainiert. Hierfür werden die Gewichte der Netze mit einer gleichmäßigen Verteilung nach dem Verfahren von Glorot und Bengio initialisiert [Glorot and Bengio, 2010]. Das Training wird auf einer Grafikkarte NVIDIA GTX 1080 Ti GPU durchgeführt, während zur Optimierung der Lernrate der adaptive Adam Algorithmus [Kingma and Ba, 2014] Anwendung findet. Wie in Abbildung 3.3 zu erkennen ist, wird die Anzahl der Faltungsoperatoren für die erste Ebene auf 32 festgelegt. Zu Beginn des Trainings wird die Lernrate auf 10^{-5} gesetzt. Sie wird nach 100 Epochen ohne Verbesserung der Validierungsrate durch zwei dividiert. Nachdem die Lernrate viermal ohne Fortschritt reduziert wurde, führt dies zu einer vorzeitigen Beendigung des Trainingsprozesses. Die Batchgröße für DSE 2D wird auf 100 festgelegt und für DSE 3D hingegen auf 6. Die Trainings- und Validierungsgraphen für das Training der Längs- und der Querstreuung sind in den Abbildungen 3.6 und 3.7 abgebildet.

3.1.8 Methoden zur Auswertung der Streustrahlkorrektur

Die Analysierung der gemessenen Streustrahlkorrekturen erfolgt sowohl im Intensitätsbereich und als auch im eigentlichen Bildraum. Um die Robustheit der Methoden zu bewerten, werden die Algorithmen an sechs unterschiedlichen Patienten mit jeweils 14 verschiedenen z-Positionen angewandt und evaluiert. Die Schätzungen der neuronalen




Abbildung 3.6: Training für die Schätzung der Längsstreuung bei einem DSCT Scan: Links: Trainingsgraph. Rechts: Validierungsgraph.

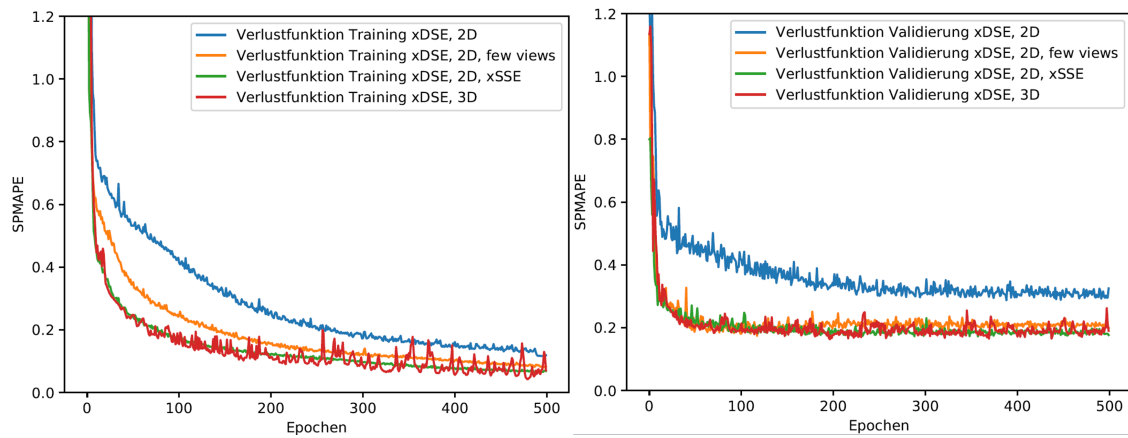


Abbildung 3.7: Training für die Schätzung der Querstreuung bei einem DSCT Scan: Links: Trainingsgraph. Rechts: Validierungsgraph.

Netze im Intensitätsraum werden mit dem SPMAPE, wie in Gleichung (3.11) definiert, verglichen. Zur Bewertung der Streustrahlkorrektur in den rekonstruierten CT-Bildern wird der mittlere absolute Fehler (MAE) herangezogen. Dabei wird der MAE jedoch nur innerhalb des Patientenbereichs ermittelt, da der Luftbereich durch einen Schwellenwert in der Bestimmung des MAE ausgeschlossen wird. Damit die Stabilität der verschiedenen Netze beurteilt werden kann, wird der minimale, der maximale und weiterhin der durchschnittliche mittlere Bildfehler bestimmt.

Im ersten Schritt wird ein Vergleich der Leistungen der unterschiedlichen Verlustfunktionen aus Abschnitt 3.1.3 vorgenommen. Damit einhergehend, wird der Zusammenhang zwischen den Verlustfunktionen und den mittleren Fehlern in den rekonstruierten Bildern analysiert. Um den optimalen Winkelversatz für den 2D DSE few views Algorithmus zu erhalten, werden Winkel zwischen 10° und 90° gegenübergestellt. Anfänglich werden die Korrekturen der Längs- und Querstreuung separat voneinander bewertet, woraufhin beide Algorithmen kombiniert werden und die Streustrahlkorrektur für einen DSCT-Scan evaluiert wird. Weil der Einsatz von Kontrastmittel in einem höheren Streu-Primär-Verhältnis resultiert, wird eine kontrastverstärkte Untersuchung im Detail analysiert. Währenddessen wird eine „Region of Interest (ROI)“ innerhalb eines jodverstärkten Areals definiert und der dazugehörige mittlere Fehler bestimmt. Ergänzend hierzu, wird die Streustrahlkorrektur für einen DECT-Scan analysiert, bei dem eine hochpräzise Streustrahlkorrektur aufgrund des entstehenden, hohen SPR essentiell ist.

3.2 Ergebnisse

3.2.1 Vergleich der Verlustfunktionen

Zunächst werden die beiden unterschiedlichen, im Abschnitt 3.1.3 vorgestellten Verlustfunktionen MSE und SPMAPE miteinander verglichen. Zu diesem Zweck erfolgt ein Training jeweils eines neuronalen Netzes DSE 2D zur Schätzung der Längs- und Querstreuung mit der Verwendung von MSE oder SPMAPE als Verlustfunktionen. Bis auf die Auswahl einer entsprechenden Verlustfunktion, werden sämtliche relevante Parame-

Tabelle 3.3: Analyse unterschiedlicher Verlustfunktionen im Trainingsprozess.

Röhrenspannung A = 80 kV, Röhrenspannung B = 80 kV						
Korrektur Methode	Opt. funktion	Streu- strahlung	MAE [HU]	Min./ Max. Fehler [HU]	SPMAPE	MSE
Unkorrigiert	-	Längs-	4.91 ± 0.93	3.69 / 8.05	-	-
fDSE, 2D	SPMAPE	Längs-	0.68 ± 0.39	0.28 / 1.93	0.06 ± 0.02	$2.32\text{e-}9 \pm 1.16\text{e-}9$
fDSE, 2D	MSE	Längs-	1.00 ± 0.68	0.36 / 4.23	0.08 ± 0.04	$2.15\text{e-}9 \pm 1.39\text{e-}9$
Unkorrigiert	-	Quer-	7.96 ± 6.15	2.26 / 35.81	-	-
xDSE, 2D	SPMAPE	Quer-	2.22 ± 1.99	0.58 / 11.95	0.18 ± 0.16	$3.22\text{e-}9 \pm 1.27\text{e-}9$
xDSE, 2D	MSE	Quer-	2.46 ± 2.17	0.45 / 12.13	0.19 ± 0.19	$2.24\text{e-}9 \pm 9.07\text{e-}10$

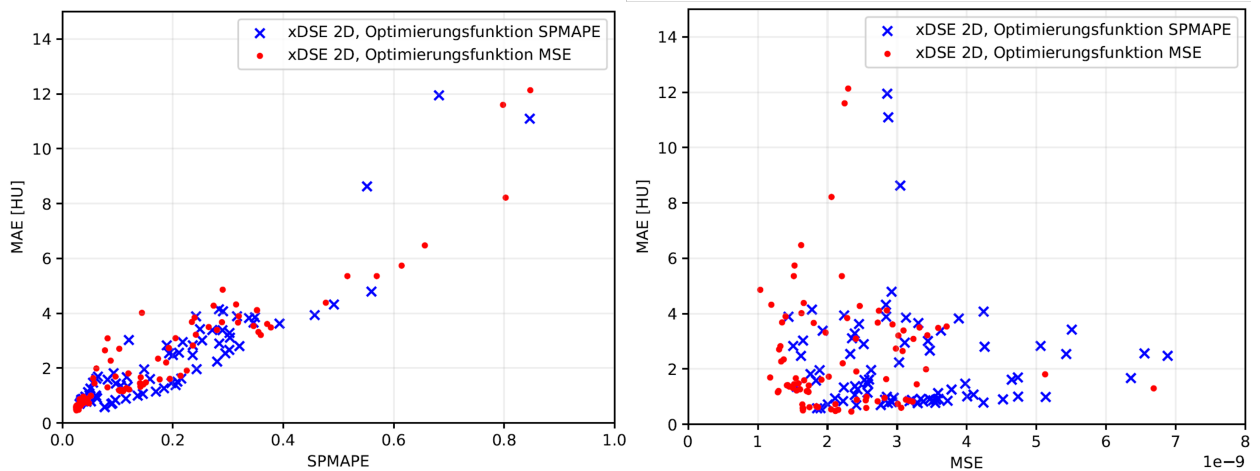


Abbildung 3.8: Vergleich der unterschiedlichen Verlustfunktionen SPMAPE und MSE. Links: Verhältnis von SPMAPE zum MAE mit den Schätzungen des mittels SPMAPE als Verlustfunktion trainierten Netzes (blau) sowie die Ausgaben des mithilfe von MSE trainierten Netzes (rot). Rechts: Abhängigkeit des MAE von MSE. Insgesamt ist eine bessere Korrelation von SPMAPE mit dem MAE im rekonstruierten Bild erkennbar.

ter identisch angewandt. Anhand der Tabelle 3.3 ist zu erkennen, dass das Verwenden von SPMape als Verlustfunktion zu besseren Ergebnissen gegenüber einem Training mittels der MSE-Funktion führt. Überdies bewirkt die Schätzung der Längsstreuung mit der Optimierung durch SPMape im Trainingsprozess einen mittleren MAE von 0,68 HU, während jenes mit der MSE in einem mittleren MAE von 1,00 HU resultiert. Der SPMape ruft einen geringeren maximalen Fehler im rekonstruierten Bild hervor und scheint robuster zu sein als die MSE. Hinsichtlich der Schätzung der Querstreuung mithilfe des SPMape beträgt der durchschnittliche MAE 2,22 HU, wohingegen mit der MSE ein mittlerer MAE von 2,46 HU entsteht. Zudem ist auch die Standardabweichung bei dem Einsatz des SPMape ($\text{stddev} = 1,99$ HU) etwas geringer als beim Trainingsvorgang mit der MSE ($\text{stddev} = 2,17$ HU).

Die Abhängigkeit der beiden verschiedenen Metriken und des resultierenden Fehlers im rekonstruierten Bild zueinander wird in Abbildung 3.8 präsentiert. Diesbezüglich wird für jeden der sechs Validierungspatienten der MAE an 14 verschiedenen z-Positionen berechnet und der entsprechende MSE- und SPMape-Wert bestimmt. Der linke Graph zeigt eine Korrelation zwischen dem SPMape-Wert im Intensitätsbereich und dem daraus hervorgegangenen Fehler im Bildraum. Demgegenüber veranschaulicht der rechte Graph, dass der MSE-Wert ungünstiger mit dem Fehler im rekonstruierten Bild korreliert. Ein Vergleich der jeweiligen Fehler in den rekonstruierten Bildern sowie insbesondere der Korrelationen der verschiedenen Verlustfunktionen mit dem MAE im Bildraum lässt die Annahme zu, dass das Training mittels SPMape zu besseren Ergebnissen als die Verwendung von MSE führt. Aus diesem Grund werden die neuronalen Netze im weiteren Verlauf mit dem SPMape trainiert.

3.2.2 Optimierung des Winkelversatzes

Das Netz xDSE 2D few views betreffend, können zusätzliche Projektionen als Eingabe zur Verfügung gestellt werden. Mit deren Hilfe sollen Informationen über die Projektionswinkel und somit räumliche Angaben gewonnen und auf diese Weise eine Verbesserung der Streustrahlschätzung herbeigeführt werden. Aus diesem Grund werden dem xDSE

Tabelle 3.4: Optimierung des Winkelversatzes für xDSE few views.

Korrekturmethode	Eingabe	Winkelversatz	MAE [HU]	SPMAPE
xDSE, 2D	1 Projektion	-	2.22 ± 1.99	0.18 ± 0.16
xDSE, 2D, few views, 3→1	3 Projektionen	10°	1.40 ± 1.39	0.11 ± 0.08
xDSE, 2D, few views, 3→1	3 Projektionen	20°	1.26 ± 1.10	0.09 ± 0.07
xDSE, 2D, few views, 3→1	3 Projektionen	30°	1.24 ± 0.98	0.09 ± 0.07
xDSE, 2D, few views, 3→1	3 Projektionen	40°	1.33 ± 1.17	0.10 ± 0.08
xDSE, 2D, few views, 3→1	3 Projektionen	50°	1.40 ± 1.10	0.11 ± 0.07
xDSE, 2D, few views, 3→1	3 Projektionen	60°	1.44 ± 1.22	0.11 ± 0.08
xDSE, 2D, few views, 3→1	3 Projektionen	70°	1.53 ± 1.27	0.11 ± 0.09
xDSE, 2D, few views, 3→1	3 Projektionen	80°	1.48 ± 1.26	0.11 ± 0.08
xDSE, 2D, few views, 3→1	3 Projektionen	90°	1.51 ± 1.25	0.11 ± 0.08

2D few views-Netz als ergänzende Eingaben zu der bereits aktuell bestehenden nicht nur eine vorherige, sondern auch eine kommende Projektion mitgegeben. Vor dem Hintergrund einer Algorithmus-Optimierung werden demnach verschiedene Netze mit diversen Winkelversätzen trainiert, was letztendlich eine höhere Genauigkeit und Robustheit der Streustrahlschätzung bewirkt (Tabelle 3.4). Überdies deuten die Ergebnisse darauf hin, dass die zusätzlichen Projektionen und damit einhergehend die gesteigerten räumlichen Informationen über den Patienten vom Netzwerk für eine präzisere Korrektur genutzt werden können. Die vergleichende Analyse zeigt, dass ein Winkelversatz von 30° zwischen den Projektionen die besten Ergebnisse zulässt. Dabei sollte jedoch berücksichtigt werden, dass es sich innerhalb der Untersuchung um simulierte Kreisscans handelt und dagegen Projektionen einer Spiralmessung eine Translation in z-Richtung auslösen würden. Weiterhin kann festgehalten werden, dass je kleiner der Winkelversatz ist, umso geringer diese Verschiebung der Projektionen in z-Richtung wäre. Weil weitere Projektionen in der Eingabe des neuronalen Netzes auch bei einem kleinen Winkelversatz bessere Ergebnisse mit sich brachten, wird im Folgenden der DSE 2D few views-Algorithmus mit einem Winkelversatz von 10° verwendet.

3.2.3 Korrektur der Längsstreuung in der DSCT

Im Hinblick auf die Korrektur der Längsstreuung innerhalb der DSCT enthält die Tabelle 3.5 die bestimmten Ergebnisse. Daraus wird ersichtlich, dass sich der mittlere MAE ohne eine durchgeführte Streustrahlkorrektur durch die Längsstreuung auf 4.91 HU und weiterhin der maximale Fehler bei den Validierungspatienten auf 8.05 HU belaufen. Allerdings ermöglicht die Anwendung des fdSE 2D-Netztes eine Verminderung des mittleren MAE auf 0.68 HU und des maximalen Fehlers auf 1.93 HU. Wenn außerdem mehrere Projektionen als zusätzliche Eingaben genutzt werden, beträgt der mittlere MAE bei fdSE 2D few views 0.62 HU und bei fdSE 3D 0.63 HU. Überdies kann der maximale Fehler jeweils auf 1.41 HU beschränkt werden. Ergänzend hierzu, führen fdSE 2D few view und fdSE 3D zu den robustesten Schätzungen angesichts der damit einhergehenden Standardabweichungen sowie des maximalen Fehlers in den rekonstruierten Bildern. Weil im Rahmen eines klinischen DSCT Streustrahlraster eingesetzt werden, reduziert sich der durch die Längsstreuung hervorgerufene Fehler in den rekonstruierten Bildern gegenüber der vorhandenen Querstreuung. Darüber hinaus erlauben sämtliche Netze eine hinreichende Streustrahlkorrektur zur Steigerung der Bildqualität. Ein Vergleich mit der messbasierten Methode (MAE = 1.06 HU) zeigt, dass alle neuronalen Netze eine präzisere Korrektur zulassen. Zur Veranschaulichung ist in Abbildung 3.9 eine beispielhafte Korrektur der Längsstreuung dargestellt.

Tabelle 3.5: Längsstreukorrektur in der DSCT.

Korrekturmethode	MAE [HU]	Min./Max. Fehler [HU]	SPMAPE
unkorrigiert	4.91 ± 0.93	3.70 / 8.05	-
fdSE, 2D	0.68 ± 0.39	0.29 / 1.93	0.06 ± 0.02
fdSE, 2D, few views	0.62 ± 0.28	0.30 / 1.41	0.06 ± 0.02
fdSE, 3D	0.63 ± 0.27	0.29 / 1.41	0.06 ± 0.02
messbasiert	1.06 ± 0.23	0.81 / 1.91	0.08 ± 0.03




Abbildung 3.9: Exemplarische Korrektur der Längsstreuung für die DSCT [Erath et al., 2021b]. Ohne Streustrahlkorrektur liegt der MAE bei 6.1 HU, während die dabei entstehenden Artefakte insbesondere im Differenzbild gegenüber der Referenz gut erkennbar sind. Mithilfe des neuronalen Netzes fdSE 2D kann der MAE auf 1.1 HU korrigiert werden. Außerdem führt die Verwendung von mehreren Projektionen als Eingabe zu einer weiteren Reduktion des MAE auf 0.9 HU mit fdSE 2D few views oder fdSE 3D. Die trainierten Netze generieren letztendlich eine bessere Korrektur als die messbasierte Referenzmethode die nur einen MAE von 1.8 HU erreicht. Die Rekonstruktionen beinhalten hier sowohl die Primärstrahlung als auch die Längsstreuung. Relevante Parameter der rekonstruierten Bilder: $C = 40$ HU, $W = 300$ HU, Differenzen zum Referenzbild: $C = 0$ HU, $W = 50$ HU. Röhrenspannung A = 80 kV, Röhrenspannung B = 80 kV.

3.2.4 Korrektur der Querstreuung in der DSCT

Angesichts der Querstreukorrektur sind in tabellarischer Form die Ergebnisse aufgelistet (Tabelle 3.6), wobei die entsprechenden Algorithmen für zwei Stromverhältnisse ρ der beiden Röhren ausgewertet wurden. Dabei ergibt sich ohne angewandte Korrektur bei $\rho = 1$ ein MAE von 7.96 HU und dagegen mit $\rho = 2$ ein MAE von 14.33 HU. Weiterhin beläuft sich der maximale Fehler mit $\rho = 1$ auf 35.81 HU und demgegenüber bei $\rho = 2$ auf 54.75 HU, wodurch die Notwendigkeit einer Korrektur der Querstreuung im Rahmen der diagnostischen Bildqualität deutlich wird. Diesbezüglich effiziert die einfachste Netzwerkarchitektur xDSE 2D einen reduzierten MAE von 2.22 HU mit $\rho = 1$ und außerdem mit $\rho = 2$ von 4.72 HU. Eine Gegenüberstellung der verschiedenen neuronalen Netze mit einer zusätzlichen Querstreuapproximation zeigt, dass die besten Ergebnisse in absteigender Reihenfolge unter Verwendung von xSSE (MAE: 1.24 HU mit $\rho = 1$ und 2.46 HU mit $\rho = 2$), gefolgt von xSSE iterativ (MAE: 2.20 HU mit $\rho = 1$ und 4.83 HU mit $\rho = 2$) und xPEP (MAE: 2.31 HU mit $\rho = 1$ und 4.64 HU mit $\rho = 2$) erzielt werden. Durch die Nutzung mehrerer Projektionen als Eingabe kann die Schätzung des neuronalen Netzes sowohl unter Anwendung von wenigen Projektionen (xDSE, 2D, few views mit einem MAE von 1.40 HU bei $\rho = 1$ und von 2.80 HU bei $\rho = 2$) als auch mit mehreren Projektionen (xDSE, 3D mit einem MAE von 1.31 HU bei $\rho = 1$ und von 2.72 HU bei $\rho = 2$) verbessert werden. Eine Betrachtung des mittleren Fehlers sowie des SPMAPE-Werts zeigt, dass xDSE 2D xSSE, xDSE 2D few views und xDSE 3D die beste Korrektur der Querstreuung erzeugen. Darüber hinaus zeigt auch eine vergleichende Analyse des maximalen Fehlers die Robustheit dieser drei Algorithmen. Schlussendlich belegt daneben auch der Abgleich der gesammelten Daten mit der messbasierten Querstreukorrektur, dass die trainierten neuronalen Netze in Lage sind die Streustrahlartefakte zu korrigieren. Darauf Bezug nehmend, veranschaulicht die Abbildung 3.10 beispielhafte Ergebnisse der Längsstreuung mit einer deutlichen Reduktion der Streustrahlartefakte durch die neuronalen Netze, wobei die beste Korrektur mittels der Algorithmen xDSE few views, xDSE xSSE und xDSE 3D erzielt wird. Prinzipiell geht aus den Ergebnissen hervor, dass je mehr Informationen über die Patientenober-

fläche dem Netz als Eingabe zur Verfügung gestellt werden, umso präziser die jeweilige Querstreukorrektur ist. Die vorgeschlagenen Algorithmen lassen sich in drei verschiedene Kategorien klassifizieren, worunter einerseits das Netz xDSE mit lediglich einer Projektion als Eingabe fällt und somit nur beschränkte Informationen über die Patienteneroberfläche bereitstehen. Andererseits gehört dazu ein neuronales Netz mit wenigen zusätzlichen Projektionen (xDSE few views), wodurch ein Teil der Patienteneroberfläche mit den relevantesten Informationen zur Schätzung der Querstreuung bekannt ist und daraus resultierend eine Verbesserung der Korrektur gegenüber der ersten Kategorie erreicht wird. In der dritten Klasse werden dem neuronalen Netz vollständige Informationen über die Konturen des Patienten überlassen, sodass dadurch die besten Ergebnisse der Streustrahlschätzung erzielt werden (xDSE 2D xSSE und xDSE 3D).

Tabelle 3.6: Korrektur der Querstreuung bei DSCT.

Korrekturmethode	MAE [HU]	Min./Max. Fehler [HU]	SPMAPE
Stromverhältnis $\rho=1$, Röhrenspannung = 80 kV			
unkorrigert	7.96 \pm 6.15	2.26 / 35.81	-
xDSE, 2D	2.22 \pm 1.99	0.58 / 11.95	0.18 \pm 0.16
xDSE, 2D, xSSE	1.24 \pm 1.07	0.29 / 7.17	0.11 \pm 0.08
xDSE, 2D, xSSE iterativ	2.20 \pm 1.91	0.51 / 12.82	0.18 \pm 0.14
xDSE, 2D, xPEP	2.31 \pm 2.02	0.65 / 13.21	0.19 \pm 0.15
xDSE, 2D, few views	1.40 \pm 1.39	0.34 / 8.64	0.10 \pm 0.08
xDSE, 3D	1.31 \pm 1.27	0.37 / 7.34	0.09 \pm 0.08
messbasiert	3.19 \pm 2.88	0.78 / 18.06	0.24 \pm 0.21
Stromverhältnis $\rho=2$, Röhrenspannung = 80 kV			
unkorrigert	14.33 \pm 9.85	4.44 / 54.75	-
xDSE, 2D	4.72 \pm 5.71	1.10 / 38.97	0.37 \pm 0.33
xDSE, 2D, xSSE	2.46 \pm 2.01	0.57 / 18.31	0.20 \pm 0.16
xDSE, 2D, xSSE iterativ	4.83 \pm 5.32	0.91 / 35.11	0.40 \pm 0.26
xDSE, 2D, xPEP	4.64 \pm 5.50	1.03 / 39.67	0.41 \pm 0.32
xDSE, 2D, few views	2.80 \pm 2.99	0.68 / 19.30	0.21 \pm 0.16
xDSE, 3D	2.72 \pm 3.10	0.75 / 18.96	0.18 \pm 0.14
messbasiert	5.93 \pm 4.87	1.55 / 29.31	0.32 \pm 0.28




Abbildung 3.10: Beispielhafte Korrektur der Querstreuung für die DSCT. Die angewandten neuronalen Netze bewirken eine bessere Korrektur gegenüber der messbasierten Referenzmethode. Relevante Parameter der rekonstruierte Bilder: $C = 40$ HU, $W = 300$ HU, Differenzen zum Referenzbild: $C = 0$ HU, $W = 50$ HU. Röhrenspannung A = 80 kV, Röhrenspannung B = 80 kV. Stromverhältnis $\rho=1$.

3.2.5 Korrektur der Längs- und Querstreueung in der DSCT

Im Hinblick auf die Korrektur der bei einem DSCT-Scan auftretenden Längs- und Querstreueung werden jeweils zwei separate neuronale Netze eingesetzt, woraufhin die Summe der generierten Schätzungen als Korrekturterm verwendet wird. Weil bereits die einfachste Netzwerkarchitektur zur Längsstreueungsschätzung sehr gute Ergebnisse hervor gebracht hat (vgl. Kapitel 3.2.3) und außerdem die Längsstreueung aufgrund des Streustrahlrasters einen geringeren Einfluss auf das rekonstruierte Bild ausübt, wird fDSE 2D zur Schätzung der Längsstreueung benutzt und zeitgleich mit verschiedenen Netzen zur Korrektur der Querstreueung kombiniert. Da die Anwendung der Querstreueapproximation xSSE iterativ und xPEP keine Verbesserungen gegenüber xDSE 2D bewirkt haben (vgl. Kapitel 3.2.4), findet in dieser Analyse lediglich die Querstreueapproximation xSSE Berücksichtigung. In der Tabelle 3.7 sind die gewonnenen Ergebnisse der verschiedenen Kombinationen der jeweiligen Netze miteinander aufgezeigt. Der durch die Streustrahlung hervorgerufene mittlere Gesamtfehler bei den untersuchten Patienten beziffert sich im unkorrigierten Zustand bei $\rho = 1$ auf 11.77 HU und daneben bei $\rho = 2$ auf 17.79 HU. Anhand der Bewertung des mittleren Fehlers kann geschlussfolgert werden, dass die verschiedenen Kombinationen aus fDSE 2D mit xDSE 2D xSSE (MAE = 1.60 HU bei $\rho = 1$, MAE = 2.87 HU bei $\rho = 2$), mit xDSE 2D 3D (MAE = 1.58 HU bei $\rho = 1$, MAE = 2.94 HU bei $\rho = 2$), mit xDSE few views (MAE = 1.69 HU bei $\rho = 1$, MAE = 3.10 HU bei $\rho = 2$) und mit xDSE 2D (MAE = 2.39 HU bei $\rho = 1$, MAE = 4.86 HU bei $\rho = 2$) die Streustrahlartefakte deutlich reduzieren können. Überdies zeigt die Bewertung des maximalen Fehlers, dass entweder der Einsatz mehrerer Projektionen oder der Gebrauch einer zusätzlichen Querstreueapproximation in einer gesteigerten Robustheit innerhalb der Ergebnisse resultiert. Die unterschiedlichen Kombinationen aus den neuronalen Netzen bedingen jeweils einen niedrigeren mittleren Fehler gegenüber der messbasierten Korrekturmethode. Anhand der Abbildung 3.12 ist sichtbar, dass Streustrahlartefakte zu dunklen Bereichen im Randareal der Patientenaufnahmen führen können, welche durch die eingeführten neuronalen Netze deutlich verbessert werden. Daneben lässt sich die Effizienz der neuronalen Netze weiterhin beträchtlich in den Differenzbildern wie auch

anhand des MAE erkennen. Im Allgemeinen verursacht der Einsatz von Kontrastmittel ein höheres SPR, weshalb hierbei eine genaue Streustrahlkorrektur besonders essentiell ist. Um für diesen Fall die Robustheit der vorgestellten Algorithmen zu eruieren, wird eine Region of Interest (ROI) innerhalb der *Cortex renalis* definiert (Abbildung 3.13). Die unkorrigierte Situation dieser ROI bringt einen mittleren Fehler von 30.1 HU mit sich, welcher durch den Einsatz der neuronalen Netze erheblich gesenkt werden kann. Demgegenüber verringert sich dieser Fehler mit der messbasierten Korrektur auf 6.7 HU und mit der Kombination aus fdSE 2D und xDSE 2D auf 4.5 HU. Die beste Korrektur wird durch die Verknüpfung von fdSE mit xDSE 2D few views (0.8 HU), xDSE 2D xSSE (0.6 HU) und xDSE 3D (0.5 HU) erreicht.

Tabelle 3.7: Korrektur der Längs- und Querstreuung für DSCT.

Korrekturmethode	MAE [HU]	Min./Max. Fehler [HU]	SPMAPE
Röhrenspannung A, B = 80 kV , $\rho = 1$			
unkorrigiert	11.77 \pm 5.99	5.79 / 38.90	-
fdSE, 2D + xDSE, 2D	2.39 \pm 2.06	0.80 / 12.65	0.15 \pm 0.17
fdSE, 2D + xDSE, 2D, xSSE	1.60 \pm 1.29	0.55 / 7.51	0.13 \pm 0.12
fdSE, 2D + xDSE, 2D, few views	1.69 \pm 1.30	0.51 / 8.22	0.13 \pm 0.11
fdSE, 2D + xDSE, 3D	1.58 \pm 1.23	0.52 / 7.09	0.10 \pm 0.12
messbasiert	3.91 \pm 2.79	1.53 / 18.45	0.30 \pm 0.27
Röhrenspannung A, B = 80 kV , $\rho = 2$			
unkorrigiert	17.79 \pm 9.51	7.84 / 57.02	-
fdSE, 2D + xDSE, 2D	4.86 \pm 5.83	1.19 / 39.58	0.39 \pm 0.33
fdSE, 2D + xDSE, 2D, xSSE	2.87 \pm 2.86	0.78 / 18.15	0.20 \pm 0.15
fdSE, 2D + xDSE, 2D, few views	3.10 \pm 3.10	0.89 / 18.96	0.21 \pm 0.16
fdSE, 2D + xDSE, 3D	2.94 \pm 2.91	0.75 / 18.52	0.18 \pm 0.14
messbasiert	4.90 \pm 4.87	1.56 / 29.32	0.37 \pm 0.34

3.2.6 Korrektur der Längs- und Querstreuung im Dual-Energy CT

Wie bereits im vorherigen Kapitel 2.1.4 beschrieben, können im Zuge eines DSCT-Scans beide Röhren mit unterschiedlichen Spannungen betrieben werden. Diesbezüglich wird dazu im Folgenden die Streustrahlkorrektur für die Dual-Energy CT demonstriert, in-

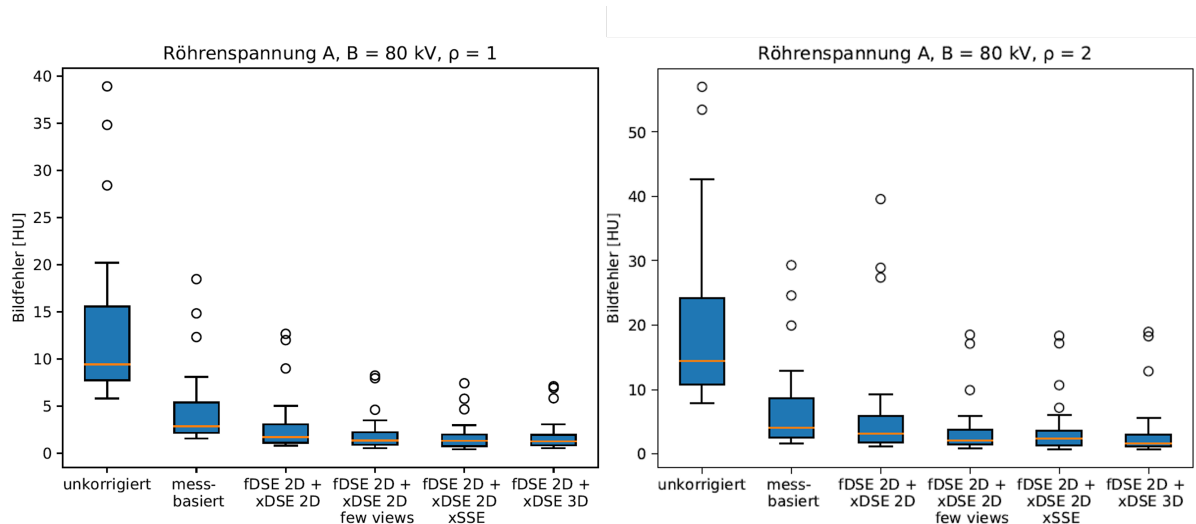


Abbildung 3.11: Statistische Auswertung zum Vergleich der verschiedenen Methoden zur Korrektur der Streustrahlung in der DSCT mittels Boxplot-Diagrammen.

nerhalb welcher die Röhre A mit 80 kV und dagegen die Röntgenröhre B mit 140 kV simuliert wird. Die Netze werden dahingehend trainiert, die Streustrahlung an Detektor A zu korrigieren, während dabei die Primärstrahlung von Messsystem A, die Längstreuung von Röhre A und die von Röhre B kommende Querstreuung erfasst wird. Dies hat zur Folge, dass auch hierbei ungünstige Situationen mit einem hohen Streu-Primär-Verhältnis auftreten können und dadurch vermehrt Fehler in den rekonstruierten Bildern entstehen. Im Hinblick auf die zu korrigierende Streustrahlung in der DECT wird das Netzwerk fdSE zur Schätzung der Längsstreuung mit verschiedenen Netzen der Querstreuung kombiniert. Bei einer Gegenüberstellung der mittleren und maximalen Fehler der Tabelle 3.8 kann festgestellt werden, dass sämtliche vorgeschlagene Netze auch bei unterschiedlichen Spannungen eine deutliche Reduzierung der Artefakte und überlegene Ergebnisse im Vergleich zur messbasierten Referenzmethode bewirken.

Im Allgemeinen kann Streustrahlung nicht nur sichtbare Artefakte erzeugen, sondern auch eine Verschiebung der gemessenen CT-Werte auslösen [Glover, 1982]. Angesichts quantitativer CT-Scans, welche exemplarisch bei der Bewertung von verschiedenen Lungenerkrankungen zum Einsatz kommen, sind die absoluten CT-Werte von äußerst großer Bedeutung [Feldhaus et al., 2019, Rorat et al., 2021, Krings et al., 2021]. Ein konkretes Beispiel stellt diesbezüglich die röntgenologische Diagnostik des Ausmaßes des emphyse-




Abbildung 3.12: Beispielhafte Korrektur der Längs- und Querstreuung für die DSCT, innerhalb welcher zwei separate Netze zur Schätzung der Längs- und Querstreuung verwendet werden [Erath et al., 2021b]. Diesbezüglich wird die Längsstreuung mittels fdSE 2D geschätzt und außerdem mit verschiedenen Netzen zur Schätzung der Querstreuung kombiniert. Der MAE im unkorrigierten Zustand beläuft sich auf 15.3 HU und kann mithilfe von xDSE 2D auf 4.3 HU reduziert werden. Durch eine zusätzliche Annäherung mit xDSE 2D xSSE entsteht ein MAE von 1.6 HU. Darüber hinaus bewirken zusätzliche Projektionen in der Eingabe einen verringerten MAE mit xDSE 2D few views von 2.2 HU und mit xDSE 3D von 1.5 HU. Insgesamt rufen die Netze eine deutliche visuelle Verbesserung des rekonstruierten CT-Bildes hervor, was sich auch in der überlegeneren Korrektur gegenüber der messbasierten Referenzmethode (MAE 4.8 HU) widerspiegelt. Relevante Parameter der rekonstruierten Bilder: $C = 40$ HU, $W = 300$ HU, Differenzen zum Referenzbild: $C = 0$ HU, $W = 50$ HU. Röhrenspannung A = 80 kV, Röhrenspannung B = 80 kV. Stromverhältnis $\rho=1$.




Abbildung 3.13: Veranschaulichung der Längs- und Querstreukorrektur für eine CT-Untersuchung mit im Voraus injiziertem Kontrastmittel [Erath et al., 2021b]. Zur Quantifizierung der Ergebnisse wurde eine ROI innerhalb der *Cortex renalis* analysiert, wobei die neuronalen Netze dabei eine deutliche Reduzierung des mittleren Fehlers erzielen. Relevante Parameter der rekonstruierten Bilder: $C = 40$ HU, $W = 300$ HU. Differenzen zum Referenzbild: $C = 0$ HU, $W = 50$ HU, Röhrenspannung A = 80 kV, Röhrenspannung B = 80 kV. Stromverhältnis $\rho=1$.

martigen Lungenparenchyms dar, um mittels entsprechender therapeutischer Maßnahmen einem weitere Fortschreiten des Lungenemphysems und damit einer irreversiblen Zerstörung des Lungengewebes entgegenzuwirken [Reske and Seiwerts, 2009]. Zur Ausführung der Streustrahlkorrektur im Zuge eines DECT-Scans wurde bei einem Patienten der durchschnittliche CT-Wert der Lunge analysiert (Abbildung 3.14), wobei im Referenzbild ein absoluter CT-Wert von -809.4 HU gemessen wird. Damit einhergehend, führt der Einfluss der Streustrahlung zu einer Veränderung dieses Messwerts auf -795.2 HU, welche mithilfe der Kombination von fDSE 2D und xDSE xSSE auf -808.9 HU korrigiert werden kann. Insgesamt impliziert dies, dass die neuronalen Netze sowohl eine Korrektur der sichtbaren Artefakte als auch des quantitativen CT-Werts ermöglichen.

Tabelle 3.8: Ergebnisse der Korrektur der Längs- und Querstreuung für Dual-Energy-CT.

Röhrenspannung A = 80 kV, Röhrenspannung B = 140 kV, $\rho = 1$			
Korrekturmethode	MAE [HU]	Min./Max. Fehler [HU]	SPMAPE
unkorrigiert	13.23 ± 7.08	6.07 / 43.91	-
fDSE, 2D + xDSE, 2D	2.48 ± 2.09	0.64 / 11.89	0.23 ± 0.18
fDSE, 2D + xDSE, 2D, xSSE	1.72 ± 1.04	0.61 / 6.10	0.13 ± 0.07
fDSE, 2D + xDSE, 2D, few views	1.67 ± 1.09	0.59 / 6.47	0.14 ± 0.08
fDSE, 2D + xDSE, 3D	1.63 ± 1.15	0.55 / 6.21	0.13 ± 0.08
messbasiert	4.27 ± 3.13	1.58 / 20.10	0.32 ± 0.23

3.3 Diskussion

Innerhalb der DSCT kann zusätzlich zur Längsstreuung die Querstreuung zu Artefakten in den rekonstruierten Bildern führen [Petersilka et al., 2010, Engel et al., 2008]. Damit diese Streustrahlung korrigiert und so die Bildqualität gesteigert werden kann, wurden verschiedene neuronale Netze vorgeschlagen und die damit einhergehenden Ergebnisse zur Evaluierung der Effizienz der neuartigen Methodik mit der messbasierten Streustrahlkorrektur verglichen. Insgesamt zeigt die gegenüberstellende Analyse, dass




Abbildung 3.14: Veranschaulichung der Längs- und Querstreukorrektur für DECT. Da bei quantitativen CT-Scans der absolute Wert wesentlich ist, erfolgte zur Quantifizierung eine Bestimmung des mittleren Werts in der segmentierten Lunge. Eine Kombination aus fDSE und xDSE xSSE kann die Verschiebung des absoluten CT-Werts durch Streustrahlung auf 0.5 HU korrigieren. Relevante Parameter der rekonstruierte Bilder: $C = -500$ HU, $W = 1500$ HU, Differenzen zum Referenzbild: $C = 0$ HU, $W = 300$ HU. Röhrensprungung A = 80 kV, Röhrensprungung B = 140 kV. Stromverhältnis $\rho=1$.

die neuronalen Netze die Streustrahlartefakte äußerst gut korrigieren können und somit der messbasierten Methodik überlegen sind.

Zu Beginn wurde ein zweidimensionales neuronales Netz vorgestellt, das anhand einer Projektion die entsprechende Streustrahlung bestimmt. Insbesondere im Rahmen der zu korrigierenden Längsstreuung konnten mit diesem Algorithmus sehr gute Ergebnisse erzielt werden, wohingegen beim Einsatz zur Korrektur der Querstreuung jedoch Situationen mit einem hohen SPR auftraten und aus diesem Grund die Artefakte nicht vollständig reduziert werden konnten. Im Zuge einer Optimierung der Querstreuung wurde die Berechnung der Querstreuapproximation xSSE eingeführt. Dabei wird mithilfe einer anfänglichen, unkorrigierten Bildrekonstruktion eine Annäherung der Querstreuung erster Ordnung anhand der Primärstrahlung berechnet und diese als zusätzliche Eingabe im nächsten Schritt dem Netz mitgegeben. Dies erlaubt eine deutlich verbesserte Genauigkeit der Streustrahlkorrektur, wobei vor allem der maximale Fehler reduziert werden konnte. Diese ergänzende Annäherung schafft dem Netz letztendlich eine gesteigerte Robustheit bei der Schätzung der Querstreuung. Eine einschränkende Limitierung des xSSE-Algorithmus stellt die vor der Schätzung der Querstreuung erforderliche Berechnung einer niedrig aufgelösten Bildrekonstruktion dar, wobei zu deren Generierung mehrere Projektionen vonnöten sind und außerdem die Berechnung der Querstreuannäherung somit erst im Anschluss daran erfolgen kann. Die dargebotenen Alternativen xSSE iterativ und xPEP, die anhand von lediglich zwei Projektionen die Annäherung bestimmen, sind wie zu erwarten der ursprünglichen xSSE Berechnung unterlegen. Kürzlich wurden auf verschiedenen neuronalen Netzen basierende Methoden eingeführt, um aus wenigen Projektionen ein Bild rekonstruieren zu können [Eulig et al., 2021, Ye et al., 2018, Zhao et al., 2016]. Ergänzend hierzu, umfasst eine mögliche Alternative zur iterativen Rekonstruktion aus zwei Projektionen den Einsatz von auf Deep-Learning beruhenden Methoden, die möglicherweise ein realistischeres Bildvolumen generieren und für die Echtzeitberechnung der xSSE-Annäherung Anwendung finden könnten.

Um dem neuronalen Netz die Option zu bieten, relevante Merkmale über mehrere Projektionen hinweg zu extrahieren, wurde xDSE 2D few views als neuronales Netz welches drei Projektionen als Eingabe verwendet, eingeführt. Die vergleichende Untersu-

chung des Winkelversatzes zwischen diesen drei Projektionen zeigte ähnliche Ergebnisse, während hierbei der niedrigste MAE mit einem Winkelversatz von 30° erreicht werden konnte. Die zusätzlichen Projektionen dienen dem Netz als Werkzeuge zum Zugewinn weiterer räumlicher Informationen über die Oberfläche des Patienten, welche wiederum hauptsächlich für die Querstreuung verantwortlich ist. Allerdings fanden bei der durchgeführten Analyse lediglich Kreisscans Berücksichtigung, wohingegen bei einem Spiral-CT die pitchabhängige z-Translation der Projektionen berücksichtigt werden müsste.

Als Alternativmöglichkeit zur Nutzung zweidimensionaler Faltungsoperatoren wurde xDSE 3D mit der Verwendung von dreidimensionalen Faltungskernen präsentiert, in welcher das Netz dabei Projektionen von einem vollständigen Kreisscan als Eingabe erhält und auf diese Weise die Streustrahlverteilungen für diesen gesamten Bereich schätzt. In Anbetracht dessen, brachte xDSE 3D sehr gute Ergebnisse mit sich, wobei der nötige Vorlauf von Projektionen und damit einhergehend keine umsetzbare Berechnung in Echtzeit die Grenzen dieses Algorithmus aufzeigen. Darüber hinaus wurden bisher nur Kreisscans einbezogen, während spiralförmige Aufnahmen hingegen eine Berücksichtigung der unterschiedlichen Pitchfaktoren beim Trainingsprozess erfordern würden.

Überdies wurde die hohe Relevanz des Verhältnisses von der Streu- zur Primärstrahlung für die Minimierung des resultierenden Bildfehlers demonstriert. Im Zuge dessen wurde der SPMAPE als Verlustfunktion für das Training vorgelegt, welche zu einer günstigeren Korrelation mit dem Fehler im rekonstruierten CT-Bild als die MSE geführt hat.

Infolge des Trainingsprozesses erlangen die neuronalen Netze eine Inferenzzeit von etwa 3 ms je Projektion. Die rapide Berechnungszeit wie auch die hohe Genauigkeit sprechen dafür, diese Korrekturmethode auch für den klinischen Praxisalltag einzusetzen.

In den beschriebenen Versuchsaufbauten haben sich zwei separate Algorithmen zur Schätzung der Längs- und Querstreuung als effizient herausgestellt. Diesbezüglich ist jedoch auch potenziell denkbar, eine wirkungsvolle Schätzung der gesamten Streustrahlung mit einer angepassten Netzarchitektur zu erreichen. Im Hinblick auf zukünftige Forschungsarbeiten könnte dies beispielsweise mit mehreren Eingangs- und Ausgangskanälen untersucht werden. Weiterhin umfasst die begrenzte Anzahl an Patienten, die für das

Training und das Validieren der Netze zur Verfügung standen, einen bedeutenden, limitierenden Faktor der vorgestellten Methoden. Überdies beruhen sämtliche Ergebnisse auf Simulationen, da die genaue Anpassung und Kalibrierung der Monte-Carlo-Simulation an das verwendete CT-System über den Rahmen dieser Arbeit hinausgehen würden. Sowohl die Anwendung als auch die Validierung der fDSE und xDSE-Algorithmen mit gemessenen Datensätzen könnten jedoch der nächste Schritt für die Implementierung in den klinischen Einsatz sein.

4 Streustrahlschätzung für grobe Streustrahlraster

Photonenzählende Detektoren erfordern aufgrund der kleineren Detektorpixel grobe Streustrahlraster, bei denen sich dementsprechend mehrere Pixel zwischen den Lamellen befinden. Dies kann hohe Frequenzen in der Streustrahlung zur Konsequenz haben, wodurch wiederum Moiré-artige Artefakte in den rekonstruierten Bildern entstehen können. In diesem Abschnitt wird eine angepasste Version der Deep Scatter Estimation (DSE) behandelt, um diese hochfrequenten Artefakte effizient zu korrigieren.

4.1 Material und Methoden

4.1.1 Monte-Carlo-Simulation

Damit Streustrahlverteilungen für die Verwendung eines groben Streustrahlrasters generiert werden können, wurde die Monte-Carlo-Simulation an die Geometrie (Tabelle 4.1) des photonenzählenden CT Scanners NAEOTOM Alpha[®] (Siemens Healthineers, Forchheim, Deutschland) adaptiert. Im Gegensatz zu einem energieintegrierenden Detektor, bei dem jedes Pixel von den Lamellen des Streustrahlrasters umgeben ist, wird ein grobes ASG mit 2×3 befindlichen Pixel zwischen den Lamellen des Streustrahlrasters eingesetzt. Diesbezüglich beläuft sich die Gesamtgröße des Detektors auf insgesamt 1376×144 Pixel. Wie in Abbildung 4.1 zu erkennen ist, sind zwischen den Lamellen jeweils sechs verschiedene Pixelpositionen zu finden, welche sowohl winkel- als auch ortsabhängig unterschiedliche Streustrahlintensitäten der eingehenden, gestreuten Photonen detektieren.



Abbildung 4.1: Simulierte Detektorgeometrie mit mehreren, zwischen den Lamellen des Streustrahlrasters befindlichen Pixeln.

Die Monte-Carlo-Simulation findet mit 18 verschiedenen Patienten statt, wobei zwölf davon für das Training, zwei für die Validierung während des Trainingsprozesses und vier Probanden für das anschließende Testen eingesetzt werden. Die Simulation erfolgt jeweils an 14 unterschiedlichen z-Positionen wie auch in 10° Schritten, woraus sich insgesamt 9072 gepaarte Projektionen ergeben.

Tabelle 4.1: Technische Spezifikationen des photonenzählenden CTs.

Simulierte Geometrie	
Durchmesser des Messfeldes	500 mm
Detektorform	Zylindersegment
Anzahl der Detektorzeilen	144
Anzahl der Detektorspalten	1376
Abstand der Röntgenröhre zum Drehzentrum	610 mm
Abstand des Drehzentrums zum Detektor	503 mm
Art des Streustrahlrasters	2D
Pixel zwischen den Lamellen	2×3
Simulierte Streustrahlung	Längsstreuung
Pixelgröße im Isozentrum	$0.30 \text{ mm} \times 0.35 \text{ mm}$

In Anbetracht der selben Pixelpositionen zwischen dem Streustrahlraster ist die Streustrahlung weiterhin niederfrequent verteilt. Um dies zu berücksichtigen, werden die Streustrahlverteilungen nach der Monte-Carlo-Simulation nicht zwischen den benachbarten Pixeln, sondern nur über dieselben Pixelpositionen hinweg mit einem Gauß-Filter geglättet.




Abbildung 4.2: Zur Berücksichtigung der unterschiedlichen Pixelpositionen zwischen den Lamellen des Streustrahlrasters erhält das neuronale Netze sechs verschiedene Netzeingaben und wird weiterhin dahingehend trainiert, für jeden Kanal die Streustrahlung separat zu schätzen. Die unterschiedlichen Netzausgaben können anschließend zur Streustrahlkorrektur kombiniert werden.

4.1.2 Deep Scatter Estimation für grobe Streustrahlraster

Um die verschiedenen Pixelpositionen zwischen den Lamellen des Streustrahlrasters einzubeziehen, wurde die Netzwerkarchitektur des neuronalen Netzes demgemäß angepasst. Im Zuge dessen wird die Summe der Primär- und Streustrahlung der unterschiedlichen Pixelpositionen in verschiedenen Kanälen als Eingabe mitgegeben (Abbildung 4.2). Auf diese Weise bekommt das Netz sechs unterschiedliche Bilder mit einer Auflösung von

je 688×48 Detektorpixel, während es dazu trainiert wird, für jeden dieser Kanäle die entsprechende Streustrahlverteilung anzugeben. Anhand dieser sechs Ausgaben kann damit die Streustrahlschätzung für den gesamten Detektor zusammengeführt werden, wobei das neuronale Netz mit der Verlustfunktion SPMAPE trainiert wird und die Auswahl der Hyperparameter zum Training des Netzes denen im Kapitel 3.1.7 genannten Parametern entsprechen.

4.2 Ergebnisse

Durch die Anpassung der Netzwerkarchitektur ist die DSE in der Lage, die hochfrequenten Anteile der Streustrahlverteilung wegen des erforderlichen groben Streustrahlrasters zu schätzen. Darauf Bezug nehmend, illustriert die Abbildung 4.3 die Streustrahlverteilung der MC-Simulation sowie die Schätzung der Deep Scatter Estimation. Darüber hinaus ist die ortsabhängige Intensitätsveränderung der Streustrahlverteilung in der Abbildung 4.4 ersichtlich, während die Streustrahlverteilung über die Detektorzeilen gemittelt wurde. Dies bedingt wiederum einen ortsgebundenen Intensitätsunterschied in Abhängigkeit davon, ob sich der Detektorpixel auf der linken oder rechten Seite einer Lamellenwand des Streustrahlrasters befindet. Bei einer separaten Analyse der geraden und ungeraden Detektorspalten (Abbildung 4.5) wird deutlich, dass die Streustrahlung angesichts der selben Pixelpositionen im Streustrahlraster weiterhin niederfrequent verteilt ist. Daneben kann abgeleitet werden, dass die Schätzung der DSE mit einer hohen Genauigkeit verbunden ist und außerdem mit der MC Streustrahlverteilung nahezu übereinstimmt. Der Einsatz der DSE erlaubt eine Reduktion des unkorrigierten MAE von 8.55 HU auf 1.05 HU (Tabelle 4.2), während die Abbildungen 4.6 und 4.7 außerdem einen deutlich verringerten Moiré-artige Effekt veranschaulichen. Sowohl in den vergrößerten Bereichen als auch in den Differenzbildern lässt sich die Verminderung dieses Effekts explizit feststellen, wobei allerdings lediglich innerhalb der Bildmitte noch ein geringer Moiré-artiger Effekt auftritt.




Abbildung 4.3: Das Netz bekommt die jeweilige Röntgenprojektion als Eingabe und schätzt die dazugehörige Längsstreuung. Das durch den Einsatz grober Streustrahlraster entstehende hochfrequente Muster der Streustrahlverteilung ist sowohl in der MC-Simulation als auch in der DSE-Schätzung sichtbar. Relevante Parameter der Projektion: $C= 2.5$, $W= 5.5$ / Streustrahlung: $C=0.0004$, $W=0.0010$.

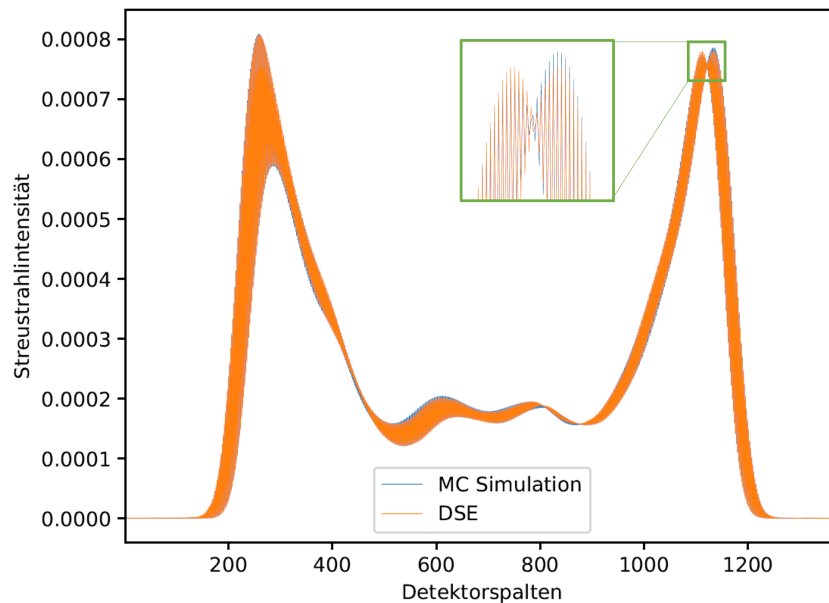


Abbildung 4.4: Abbildung der Streustrahlverteilung der MC sowie die Schätzung der Deep Scatter Estimation. Die Verteilung der Streustrahlung ist in dieser Funktion über alle Detektorzeilen gemittelt, wobei der vergrößerte Bereich die hochfrequente Veränderung über die Detektorspalten aufzeigt. Daraus geht hervor, dass die DSE zu einer präzisen Schätzung der Streustrahlverteilung führt.

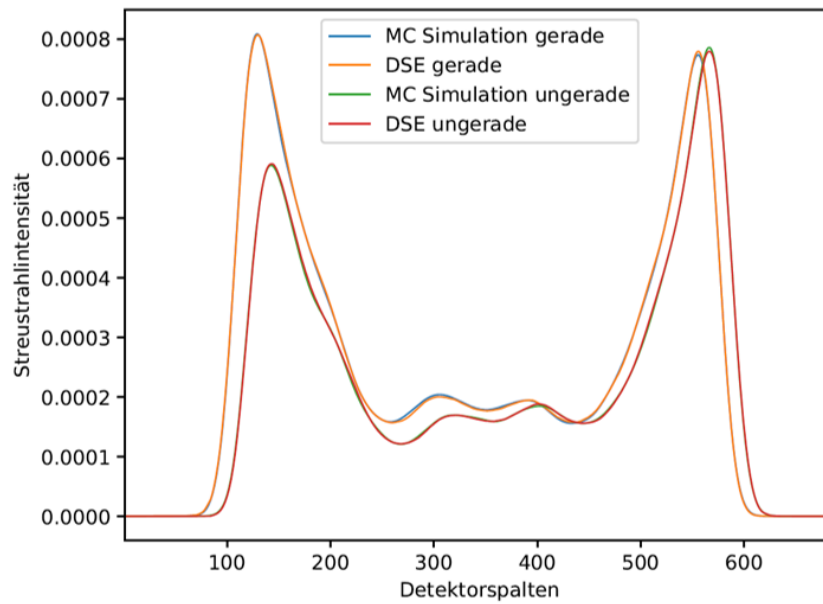


Abbildung 4.5: Zur optimalen Wiedergabe der Genauigkeit der Streustrahlschätzung sind die geraden und ungeraden Detektorspalten separat dargestellt. Überdies wurde der Mittelwert der Streustrahlung über alle Detektorzeilen hinweg berechnet. Bei gesonderter Untersuchung der geraden und ungeraden Spalten lässt sich eine niederfrequent verhaltende Streustrahlung erkennen.

Tabelle 4.2: Längsstreukorrektur für grobe Streustrahlraster.

Korrekturmethode	MAE [HU]	Min./Max. Fehler [HU]	SPMAPE
unkorrigert	8.55 ± 1.21	3.68 / 9.01	-
fdSE, 2D für grobe Streustrahlraster	1.05 ± 0.63	0.18 / 2.65	0.05 ± 0.01




Abbildung 4.6: Beispiel der DSE für grobe Streustrahlraster: Durch die Streustrahlkorrektur kann der MAE von 8.4 HU auf 0.9 HU reduziert werden, während darüber hinaus eine deutliche Verminderung des Moiré-artigen Effekts durch die DSE erkennbar ist. $C = 0$ HU, $W = 400$ HU, Differenzen zum Referenzbild: $C = 0$ HU, $W = 50$ HU.




Abbildung 4.7: Durch die DSE lassen sich sowohl der mittlere Fehler als auch die Moiré-artigen Artefakte deutlich reduzieren. $C = 0$ HU, $W = 400$ HU, Differenzen zum Referenzbild: $C = 0$ HU, $W = 50$ HU.

4.3 Diskussion

Der Einsatz sehr kleiner Detektorpixel, wie bei photonenzählenden Detektoren, kann aufgrund der Strahlendosis sowie der Fertigungspräzision mit der Verwendung von daher notwendigen, groben Streustrahlrastern verbunden sein, bei denen mehrere Pixel zwischen den Lamellen zu finden sind. Dies kann sich in einem hochfrequentem Muster in der Streustrahlverteilung äußern, wodurch wiederum Moiré-artigen Artefakte in den rekonstruierten Bildern auftreten können. In diesem Kapitel wurde die Verwendung der Deep Scatter Estimation für die Korrektur dieses Moiré-artigen Effekts dargelegt, während deutliche hochfrequente Anteile in Anbetracht der Streustrahlverteilung über den gesamten Detektor erkennbar sind. Bei separater Betrachtung derselben Pixelpositionen zwischen den Lamellen ist weiterhin eine niederfrequente Verhaltensweise der Streustrahlung ersichtlich. Diese Eigenschaft fand in der Anpassung der Netzwerkarbeitung Berücksichtigung, indem eine gesonderte Verarbeitung derselben Pixelposition zwischen den Lamellen innerhalb der Kanalein- und Ausgabe durch das Netz erfolgt. Im Anschluss kann die Ausgabe der verschiedenen Kanäle zusammengeführt werden, um die Streustrahlverteilung mit hochfrequenten Anteilen zu generieren. Die festgestellten Ergebnisse dieses Forschungsansatzes haben gezeigt, dass die DSE mit dem Einsatz von groben Streustrahlrastern eine sehr gute Schätzung der Streustrahlverteilung erlaubt. Das neuronale Netz ist demzufolge in der Lage, Informationen über diese verschiedenen Pixelpositionen hinweg in einer daraus resultierenden hohen Genauigkeit anzuwenden. Ergänzend hierzu, wiesen die rekonstruierten Bilder eine deutliche Reduzierung der Moiré-artigen Artefakte und daneben auch eine signifikante Minderung des mittleren Fehlers auf. Diesbezüglich sollte allerdings beachtet werden, dass die vorgestellten Ergebnisse lediglich auf simulierten Daten basieren. In diesem Zusammenhang wäre ein mögliches, zukünftiges Forschungsthema eine Untersuchung auf die Exaktheit der zu korrigierenden Messungen. Das Ausmaß der Genauigkeit des Algorithmus zur Korrektur gemessener Daten wäre mit der vorgestellten Methode abhängig von der Genauigkeit der MC-Simulation. Um bei der Korrektur von Messungen nicht auf die MC-Simulationen angewiesen zu sein, wäre ein Training der DSE mit gemessenen Daten und damit unab-

hängig von einer Simulation potenziell annehmbar [Erath et al., 2019]. Überdies wurden in dem vorgestellten Experiment nicht die spektralen Informationen der photonenzählenden Detektoren berücksichtigt und ausschließlich eine Anpassung des neuronalen Netzes für die Verwendung von groben Streustrahlrastern demonstriert. Demgemäß erfordern weitergehende Forschungen eine Beachtung verschiedener Energieschwellen und somit eine weiter angepasste Streustrahlkorrektur für photonenzählende Detektoren.

5 Schlussfolgerung und Ausblick

Die Zielsetzung der vorliegenden Dissertationsschrift beinhaltete die Analyse des Einsatzes neuronaler Netze für die Korrektur von Streustrahlartefakten in der klinischen Computertomographie. Im Zusammenhang damit bewirkt die Verwendung eines zweiten Messsystems bei der DSCT zusätzlich zur Querstreuung eine Längsstreuung, indem beispielsweise von Röntgenröhre A ausgesandte und am Patienten gestreute Photonen anschließend im Detektor B registriert werden. In Anbetracht der Querstreuung kann diese mit ausbleibender Korrektur ausgeprägte Artefakte in den rekonstruierten Bildern herbeiführen [Petersilka et al., 2010, Engel et al., 2008]. Die bisher dafür angewandten Methoden zur Optimierung sind entweder nicht ausreichend akkurat, erfordern komplexe zeitintensive Berechnungen oder benötigen ergänzende Hardware, welche mit zusätzlichen Kosten verbunden sind. Basierend auf der DSE von Maier et al. [Maier et al., 2018, Maier et al., 2019b], welche anhand einer Projektion die zugehörige Schätzung der Längsstreuung vornimmt, wurden verschiedene neuronale Netze für die Anwendung in der DSCT entwickelt. Im Hinblick auf die Korrektur der Längsstreuung in der DSCT zeigte sich, dass die DSE mithilfe einer Projektion als Eingabe eine präzise Streustrahlkorrektur zulässt. Weil hingegen die Querstreuung ein hohes Streu-Primär-Verhältnis zur Folge haben kann, blieben in einigen Situationen noch Artefakte in den rekonstruierten Bildern bestehen. Aus diesem Grund empfiehlt es sich, dem neuronalen Netz für eine optimale Verbesserung weitere räumliche Informationen über die für die Querstreuung hauptverantwortliche Patientenoberfläche zur Verfügung zu stellen. Eine Möglichkeit hierfür stellt die Berechnung der Querstreuannäherung $xSSE$ dar, bei der mit dem, aus einer raschen Bildrekonstruktion resultierenden, grob aufgelösten Bildvolumen die Querstreuung erster Ordnung anhand der Primärstrahlung berechnet wird. Diese Annä-

herung kann dem neuronalen Netz als hinzukommende Eingabe mitgegeben werden, was letztendlich eine robustere Streustrahlschätzung bewirkt. Für die Berechnung der xSSE-Annäherung ist jedoch ein Vorlauf von ausreichenden Projektionen notwendig, um eine Bildrekonstruktion durchzuführen. Für eine Berechnung der Querstreuannäherung in Echtzeit wurden die Algorithmen xSSE iterativ und xPEP vorgeschlagen, bei denen die Approximation lediglich anhand zweier Projektionen erfassbar ist. In der vorgestellten Untersuchung erwiesen sich die Ergebnisse mit DSE xSSE gegenüber den Annäherungen mit zwei Projektionen als überlegen, woraus sich ein mögliches, zukünftiges Forschungsthema in Form einer weiteren Optimierung dieser auf zwei Projektionen beruhenden Annäherungen ergibt. Eine weitere Alternative die Korrektur der Querstreuung zu verbessern, umfasst die Ausstattung des neuronalen Netzes mit mehreren Projektionen zur Eingabe, wobei dabei zwischen der Nutzung von zwei- oder dreidimensionalen Faltungsoperatoren unterschieden wird. Bei Ersterem wird das Netz xDSE few views jeweils mit einer vorherigen, der aktuellen wie auch einer folgenden Projektion mit einem Winkelversatz von 10° versehen. Demgegenüber steht die dreidimensionale Architektur, innerhalb welcher das Netz Projektionen eines gesamten Bereichs (360°) als Eingabe bekommt und so die zugehörige Verteilung der Streustrahlung für dieses Areal vollständig schätzt. Die zusätzlichen Projektionen in der Eingabe bewirkten sowohl eine präzise Streustrahlschätzung als auch eine erhöhte Robustheit in der Korrektur. Allerdings muss an dieser Stelle hervorgehoben werden, dass die Anwendung der Algorithmen ausschließlich für Kreisscans erforscht wurde und eine Korrektur der Streustrahlung von Spiralscans eine Berücksichtigung unterschiedlicher Tischvorschubgeschwindigkeiten im Trainingsprozess benötigen würde. Nichtsdestotrotz zeigten sich die neuronalen Netze mit ihrer enormen Stabilität in den durchgeführten Versuchsaufbauten gegenüber der messbasierten Referenzmethode als dominierend. Des Weiteren erfolgte im Laufe dieser Forschungsarbeit eine Anpassung der Streustrahlkorrektur für die Verwendung von groben Streustrahlrastern, wie es die photonenzählenden Detektoren erfordern, um auf diesem Wege die vielfältigen Einsatzmöglichkeiten der DSE darzulegen. Durch die Beachtung der verschiedenen Pixelpositionen zwischen den Lamellen des Streustrahlrasters in der Netzwerkarchitektur konnten die entstehenden Moiré-artigen Artefakte deutlich reduziert werden. Jedoch

fanden in diesen ersten Versuchen der Streustrahlkorrektur die spektralen Informationen bei einem PCD keine Berücksichtigung. Somit stellt ein möglicher Einsatz der DSE für die photonenzählenden Detektoren ein weiteres Forschungsthema für die Zukunft dar.

Ein bedeutender Vorteil der hier präsentierten Algorithmen besteht in der äußerst geringen Inferenzzeit, die einen möglichen klinischen Einsatz besonders praktikabel und attraktiv macht. Zusammenfassend stellen die Ergebnisse der vorliegenden Forschungsarbeit das große Potential der neuronalen Netze für die Korrektur von Streustrahlartefakten in der CT unter Beweis. Vor einer möglichen Eingliederung in die Klinik sollte jedoch die Robustheit der Algorithmen mithilfe eines größeren Patientendatensatzes eruiert werden, um eine Übertragung in den Praxisalltag rechtfertigen zu können. Sämtliche vorgestellte Ergebnisse beruhen auf Simulationen als Analysemethode, sodass die Korrektur von Messungen der nächste stringente Schritt für die Integration der Streustrahlkorrektur mittels neuronaler Netze in einen klinischen CT-Scanner darstellt.

6 Zusammenfassung

Korrektur der Quer- und Längsstreuung

Im Rahmen der gegenwärtigen Dual-Source-Computertomographie werden zur Optimierung der zeitlichen Auflösung und der spektralen Bildinformationen zwei Messsysteme in einem Winkel von etwa 90° zueinander eingesetzt, wodurch zusätzlich zur üblichen Längsstreuung, die Querstreuung entsteht. Bei dieser emittieren beispielsweise Photonen von der Röntgenröhre A, welche dann am Patienten streuen und wiederum im Detektor B gemessen werden (Gleiches gilt umgekehrt). Die Querstreuung kann starke Bildartefakte in den rekonstruierten CT-Bildern hervorrufen, wobei die bestehenden Korrekturmethoden entweder sehr rechenintensiv sind, zusätzliche Messsensoren erfordern oder mit einer zu geringen Präzision einhergehen. Ziel dieser Dissertation bestand darin, eine Technik zur Korrektur der Längs- und Querstreuung in der Dual-Source CT durch den Einsatz tiefer neuronaler Netze zu entwickeln. Zu Beginn wurden zum Trainieren und Validieren der Netze die Verteilungen der Streustrahlung durch eine Monte-Carlo-Simulation generiert, wobei vorab eine Anpassung an einen klinischen CT-Scanner vorgenommen wurde. Die verschiedenen Netzarchitekturen unterschieden sich in den Eingabe- und Ausgabeinformationen voneinander, welche allerdings sowohl für den Trainingsvorgang und die Vorhersagbarkeit als auch für die jeweilige Anwendung von zwei- oder dreidimensionalen Faltungsoperatoren erforderlich sind. Bei vorhandener Querstreuung konnte die Längsstreuung äußerst präzise anhand der aktuellen Projektion bestimmt werden. Damit zudem eine robuste Schätzung der Querstreuung durch eine Projektion mithilfe eines neuronalen Netzes ermöglicht wird, kann im Vorfeld dieser Schätzung die Berechnung einer Querstreuannäherung erfolgen. Im Zuge dessen wird

mittels einer schnellen, grob aufgelösten Bildrekonstruktion die Querstreuung durch die Berechnung der Abschwächung entlang der Primärstrahlung approximiert. Diese Annäherung als zusätzliche Eingabe erlaubt eine exakte Korrektur von Querstreuartefakten durch das neuronale Netz. Eine weitere Möglichkeit für eine präzise Optimierung umfasst die Bereitstellung mehrerer Projektionen innerhalb der Eingabe für das entsprechende Netz. Im Rahmen der Nutzung von zweidimensionalen Faltungsoperatoren erreicht die Korrektur mit den zusätzlichen Eingaben einer vorherigen und folgenden Projektion eine gesteigerte Zuverlässigkeit. Des Weiteren geht die Verwendung einer dreidimensionalen Architektur mit der Verwendung von einem vollständigen Projektionsbereich als Eingabe und von Streustrahlverteilungen als Ausgabe einher, sodass auch hierbei die Genauigkeit der Verbesserung deutlich erhöht wird. Der mit den Streustrahlartefakten zusammenhängende mittlere Fehler in den Bildrekonstruktionen kann durch den hier analysierten Testdatensatz von 18 HU auf etwa 3 HU verringert werden. Insgesamt resultiert die Streustrahlkorrektur mittels neuronaler Netze gegenüber der messbasierten Referenzmethode in einer präziseren Korrektur. Zusammenfassend können tiefe neuronale Netze die in der Dual-Source-CT entstehenden Streustrahlartefakte deutlich korrigieren. Überdies verbessert eine zusätzliche Querstreuanneherung oder die Eingabe zusätzlicher Projektionswinkel die Präzision des Algorithmus.

Korrektur des Moiré-artigen Effekts

Der Einsatz sehr kleiner Pixelgrößen, wie es bei photonenzählenden Detektoren der Fall ist, kann den Gebrauch grober Streustrahlraster erfordern, bei denen mehrere Pixel zwischen den Lamellen des Rasters vorgefunden werden können. Dadurch ergeben sich in der sonst niederfrequenten Streustrahlverteilung hochfrequente Anteile, welche zu Moiré-artigen Artefakten in den Rekonstruktionen führen können. Durch eine an den photonenzählenden CT-Scanner angepasste Geometrie mit einem groben Streustrahlraster wird die Streustrahlverteilung anhand von Monte-Carlo simuliert. Im Hinblick auf dieselbe Pixelposition inmitten der Lamellen des Streustrahlrasters, verändert sich die Streustrahlintensität langsam wie auch kontinuierlich über die Detektorpositionen

unter Bewahrung der typischen, niederfrequenten Eigenschaften. In Anbetracht dessen, werden dem neuronalen Netz für jede Pixelposition zwischen den Lamellen die zugehörige Eingabe, bestehend aus Primärstrahlung und Längsstreuung, zur Verfügung gestellt. Folglich wird das neuronale Netz dazu trainiert, für jede Eingabe die zugehörige Streustrahlverteilung als separate Ausgabe zu schätzen. Infolgedessen können die verschiedenen Ausgaben zusammengeführt werden, um so die Streustrahlverteilungen für den gesamten Detektor samt der hochfrequenten Veränderungen zu erzeugen. Schlussendlich ist das neuronale Netz in der Lage den mittleren Fehler der Längsstreuung von 8 HU auf etwa 1 HU und dazu die Moiré-artigen Artefakte erheblich zu senken.

Abbildungsverzeichnis

1.1	Streustrahlartefakte bei einem Dual-Source-CT	3
1.2	Entwicklung von „Deep Learning“ -Publikationen in den letzten 10 Jahren	5
2.1	Zusammensetzung des Abschwächungskoeffizienten für Wasser	10
2.2	Interaktionen von Röntgenstrahlen mit Materie	11
2.3	Grundprinzipien von energieintegrierenden und photonenzählenden Detektoren	14
2.4	Vergleich der Streustrahlraster bei einem energieintegrierenden und photonenzählenden Detektor	15
2.5	Streustrahlartefakte bei einem energieintegrierenden und photonenzählenden Detektor	16
2.6	Illustration eines Dual-Source-CT-Scanners	19
2.7	Dual-Energy-CT	21
2.8	Visualisierung der Streuung bei einem DSCT-Scanner	22
2.9	Vorwärtsgerichtetes neuronales Netz	29
2.10	Faltungs- und Poolingschicht	30
3.1	Beispiel von simulierten Sinogrammen	36
3.2	Übersicht der möglichen Ein- und Ausgänge der neuronalen Netze	39
3.3	Darstellung der Netzwerkarchitektur	41
3.4	Schematische Darstellung der xSSE-Berechnung	42
3.5	Schematische Darstellung des xPEP-Modells	45

3.6	Trainings- und Validierungsgraphen der Schätzung der Längsstreuung für die DSCT	51
3.7	Trainings- und Validierungsgraphen der Schätzung der Querstreuung für die DSCT	51
3.8	Vergleich unterschiedlicher Verlustfunktionen	53
3.9	Korrektur der Längsstreuung	57
3.10	Korrektur der Querstreuung	60
3.11	Auswertung der verschiedenen Methoden zur Korrektur der Längs- und Querstreuung mittels Boxplot-Diagrammen	63
3.12	Korrektur der Längs- und Querstreuung	64
3.13	Korrektur der Längs- und Querstreuung beim Einsatz von Kontrastmittel	65
3.14	Korrektur der Längs- und Querstreuung bei DECT	67
4.1	Simulierte Detektorgeometrie	72
4.2	Angepasste Netzwerkarchitektur für grobe Streustrahlraster	73
4.3	Intensitäten der Streustrahlschätzung mit groben Streustrahlrastern . . .	75
4.4	Vergleich der Streustrahlschätzung mit der Referenzstreustrahlverteilung	75
4.5	Streustrahlschätzung bei separater Betrachtung der geraden und ungeraden Detektorspalten	76
4.6	Beispiel der DSE für grobe Streustrahlraster	77
4.7	Weiteres Beispiel für die DSE für grobe Streustrahlraster	78

Tabellenverzeichnis

2.1	Übersicht spezifischer CT-Werte von Geweben und Organen	17
3.1	Technische Spezifikationen der simulierten DSCT (Messsystem A).	35
3.2	Überblick über die Netzwerkarchitekturen	37
3.3	Analyse unterschiedlicher Verlustfunktionen im Trainingsprozess.	53
3.4	Optimierung des Winkelversatzes für xDSE few views.	55
3.5	Längsstreukorrektur in der DSCT.	56
3.6	Korrektur der Querstreuung bei DSCT.	59
3.7	Korrektur der Längs- und Querstreuung für DSCT.	62
3.8	Ergebnisse der Korrektur der Längs- und Querstreuung für Dual-Energy- CT.	66
4.1	Technische Spezifikationen des photonenzählenden CTs.	72
4.2	Längsstreukorrektur für grobe Streustrahlraster.	76

Literaturverzeichnis

- [Achenbach et al., 2010] Achenbach, S., Marwan, M., Ropers, D., Schepis, T., Pflederer, T., Anders, K., Kuettner, A., Daniel, W., Uder, M., and Pell, M. (2010). Coronary computed tomography angiography with a consistent dose below 1 mSv using prospectively electrocardiogram-triggered high-pitch spiral acquisition. *European Heart Journal*, 31:340–346.
- [Achenbach et al., 2006] Achenbach, S., Ropers, D., Kuettner, A., Flohr, T., Ohnesorge, B., Bruder, H., Theessen, H., Karakaya, M., Daniel, W., Bautz, W., Kalender, W., and Anders, K. (2006). Contrast-enhanced coronary artery visualization by dual-source computed tomography—initial experience. *European Journal of Radiology*, 57:331–335.
- [Alkadhi et al., 2013] Alkadhi, H., Leschka, S., Stolzmann, P., and Flohr, T. (2013). *Praxisbuch Herz-CT*, volume 2. Springer.
- [Amato et al., 2020] Amato, C., Klein, L., Wehrse, E., Rotkopf, L. T., Sawall, S., Maier, J., Ziener, C. H., Schlemmer, H.-P., and Kachelrieß, M. (2020). Potential of contrast agents based on high-Z elements for contrast-enhanced photon-counting computed tomography. *Medical Physics*, 47(12):6179–6190.
- [Andreo, 1991] Andreo, P. (1991). Monte Carlo techniques in medical radiation physics. *Physics in Medicine and Biology*, 36(7):861.
- [Baer and Kachelrieß, 2012] Baer, M. and Kachelrieß, M. (2012). Hybrid scatter correction for CT imaging. *Physics in Medicine and Biology*, 57:6849–6867.
- [Biotechnology, 2021] Biotechnology, C. (2021). <https://pubmed.ncbi.nlm.nih.gov/>.

- [Brooks and DiChiro, 1976] Brooks, R. A. and DiChiro, G. (1976). Beam hardening in x-ray reconstructive tomography. *Physics in Medicine and Biology*, 21(3):390–398.
- [Bruder et al., 2008] Bruder, H., Stierstorfer, K., Petersilka, M., Wiegand, C., Suess, C., and Flohr, T. (2008). Correction of cross-scatter in next generation dual source CT (DSCT) scanners. In *Medical Imaging 2008: Physics of Medical Imaging*, volume 6913, page 69131W. International Society for Optics and Photonics, SPIE.
- [Brüning et al., 2008] Brüning, R., Küttner, A., and Flohr, T. (2008). *Mehrschicht-CT: Ein Leitfaden*. Springer.
- [Bundesamt für Strahlenschutz (BfS), 2013] Bundesamt für Strahlenschutz (BfS) (2013). Umweltradioaktivität und Strahlenbelastung im Jahr 2012: Unterrichtung durch die Bundesregierung.
- [Buzug, 2008] Buzug, T. (2008). *Computed Tomography*. Springer.
- [Callahan, 2011] Callahan, M. J. (2011). CT dose reduction in practice. *Pediatric radiology*, 41(2):488–492.
- [Carlsson, 1999] Carlsson, C. A. (1999). Imaging modalities in x-ray computerized tomography and in selected volume tomography. *Physics in Medicine and Biology*, 44(3):R23–R56.
- [Chen et al., 2017] Chen, H., Zhang, Y., Kalra, M. K., Lin, F., Chen, Y., Liao, P., Zhou, J., and Wang, G. (2017). Low-dose CT with a residual encoder-decoder convolutional neural network. *IEEE Transactions on Medical Imaging*, 36(12):2524–2535.
- [Cullen et al., 1997] Cullen, D. E., Hubbell, J. H., and Kissel, L. (1997). EPDL97: the evaluated photo data library97 version. Technical report, Lawrence Livermore National Lab.(LLNL), Livermore, CA (United States).
- [Cybenko, 1989] Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4):303–314.

- [Engel et al., 2008] Engel, K. J., Herrmann, C., and Zeitler, G. (2008). X-ray scattering in single- and dual-source CT. *Medical Physics*, 35(1):318–332.
- [Erath et al., 2019] Erath, J., Maier, J., Fournié, E., Vöth, T., Stierstorfer, K., and Kachelrieß, M. (2019). Monte Carlo-free deep scatter estimation (DSE) for x-ray CT and CBCT. *Program of the 105th Scientific Assembly and Annual Meeting of the RSNA*, pages SSE24–06.
- [Erath et al., 2021a] Erath, J., Vöth, T., Maier, J., Fournié, E., Petersilka, M., Stierstorfer, K., and Kachelrieß, M. (2021a). Deep scatter estimation (DSE) and correction for dual-source dual-energy CT. *ECR Book of Abstracts, Insights into Imaging*, 12(75).
- [Erath et al., 2022] Erath, J., Vöth, T., Maier, J., Fournié, E., Petersilka, M., Stierstorfer, K., and Kachelrieß, M. (2022). Estimating the high scatter frequencies caused by coarse anti scatter grids in x-ray CT. *ECR Book of Abstracts, Insights into Imaging*.
- [Erath et al., 2021b] Erath, J., Vöth, T., Maier, J., Fournié, E., Petersilka, M., Stierstorfer, K., and Kachelrieß, M. (2021b). Deep learning-based forward and cross-scatter correction in dual-source CT. *Medical Physics*, 48(9):4824–4842.
- [Erath et al., 2020] Erath, J., Vöth, T., Maier, J., Fournié, E., Stierstorfer, K., Petersilka, M., and Kachelrieß, M. (2020). Deep learning-based cross-scatter correction for clinical CT. *Conference Record of the 6th International Conference on Image Formation in X-Ray Computed Tomography*, pages 412–415.
- [Erickson et al., 2017] Erickson, B. J., Korfiatis, P., Akkus, Z., and Kline, T. L. (2017). Machine learning for medical imaging. *Radiographics*, 37(2):505–515.
- [Esteva et al., 2021] Esteva, A., Chou, K., Yeung, S., Naik, N., Madani, A., Mottaghi, A., Liu, Y., Topol, E., Dean, J., and Socher, R. (2021). Deep learning-enabled medical computer vision. *NPJ digital medicine*, 4(1):1–9.
- [Eulig et al., 2021] Eulig, E., Maier, J., Knaup, M., Bennett, N. R., Hörndler, K., Wang, A. S., and Kachelrieß, M. (2021). Deep learning-based reconstruction of interventional

- tools and devices from four x-ray projections for tomographic interventional guidance. *Medical Physics*, 48(10):5837–5850.
- [Faby et al., 2015] Faby, S., Kuchenbecker, S., Sawall, S., Simons, D., Schlemmer, H.-P., Lell, M., and Kachelrieß, M. (2015). Performance of today’s dual energy CT and future multienergy CT in virtual noncontrast imaging and in iodine quantification: A simulation study. *Medical Physics*, 42(7):4349–4366.
- [Feinendegen, 2005] Feinendegen, L. E. (2005). Evidence for beneficial low level radiation effects and radiation hormesis. *The British Journal of Radiology*, 78:3–7.
- [Feldhaus et al., 2019] Feldhaus, F. W., Theilig, D. C., Hubner, R.-H., Kuhnigk, J.-M., Neumann, K., and Doellinger, F. (2019). Quantitative CT analysis in patients with pulmonary emphysema: is lung function influenced by concomitant unspecific pulmonary fibrosis? *International journal of chronic obstructive pulmonary disease*, 14:1583.
- [Flaton et al., 1995] Flaton, K. A., Gehlen, S., Hormel, M., Konen, W., and Kopecz, J. (1995). Neuronale Netze: Grundlagen und Anwendungen. In *Neuro+ Fuzzy*, pages 26–58. Springer.
- [Flohr et al., 2015] Flohr, T., De Cecco, C. N., Schmidt, B., Wang, R., Schoepf, U., and Meinel, F. (2015). Computed tomographic assessment of coronary artery disease state-of-the-art imaging techniques. *Radiologic Clinics of North America*, 53.
- [Flohr et al., 2008] Flohr, T. G., Bruder, H., Stierstorfer, K., Petersilka, M., Schmidt, B., and McCollough, C. H. (2008). Image reconstruction and image quality evaluation for a dual source CT scanner. *Medical Physics*, 35(12):5882–5897.
- [Flohr et al., 2006] Flohr, T. G., McCollough, C. H., Bruder, H., Petersilka, M., Gruber, K., Süß, C., Grasruck, M., Stierstorfer, K., Krauss, B., Raupach, R., Primak, A. N., Küttner, A., Achenbach, S., Becker, C., Kopp, A., and Ohnesorge, B. M. (2006). First performance evaluation of a dual-source CT (DSCT) system. *European Radiology*, 16(2):256–268.

- [Glaser-Gallion and Stolzmann, 2011] Glaser-Gallion, N. and Stolzmann, P. (2011). *Erkennung und Vermeidung von Artefakten*, pages 31–39. Springer Berlin Heidelberg.
- [Glorot and Bengio, 2010] Glorot, X. and Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS)*, 9:249–256.
- [Glover, 1982] Glover, G. (1982). Compton scatter effects in CT reconstructions. *Medical Physics*, 9(6):860–867.
- [Hangartner, 1987] Hangartner, T. N. (1987). Correction of scatter in computed tomography images of bone. *Medical Physics*, 14(3):335–340.
- [Hausleiter et al., 2009] Hausleiter, J., Bischoff, B., Hein, F., Meyer, T., Hadamitzky, M., Thierfelder, C., Allmendinger, T., Flohr, T., Schömig, A., and Martinoff, S. (2009). Feasibility of dual-source cardiac CT angiography with high-pitch scan protocols. *J. Cardiovasc. Comput. Tomogr.*, 3:236–242.
- [Hornik, 1991] Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2):251–257.
- [Hunold et al., 2003] Hunold, P., Vogt, F. M., Schmermund, A., Debatin, J. F., Kerkhoff, G., Budde, T., Erbel, R., Ewen, K., and Barkhausen, J. (2003). Radiation exposure during cardiac CT: Effective doses at multi-detector row CT and electron-beam CT. *Radiology*, 226(1):145–152.
- [James, 1980] James, F. (1980). Monte Carlo theory and practice. *Reports on Progress in Physics*, 43(9):1145–1189.
- [Johnson et al., 2006] Johnson, T. R. C., Nikolaou, K., Wintersperger, B. J., Leber, A. W., von Ziegler, F., Ristand, C., Buhmann, S., Knez, A., Reiser, M., and Christoph R., Becker, C. (2006). Dual-source CT cardiac imaging: Initial experience. *European Journal of Radiology*, 16:1409–1415.

- [Kachelrieß et al., 2004] Kachelrieß, M., Knaup, M., and Kalender, W. A. (2004). Extended parallel backprojection for standard 3D and phase-correlated 4D axial and spiral cone-beam CT with arbitrary pitch and 100% dose usage. *Medical Physics*, 31(6):1623–1641.
- [Kachelrieß et al., 2006] Kachelrieß, M., Knaup, M., and Kalender, W. A. (2006). Multithreaded cardiac CT. *Medical Physics*, 33(7):2435–2447.
- [Kahn et al., 2014] Kahn, J., Grupp, U., and M., M. (2014). How does arm positioning of polytraumatized patients in the initial computed tomography (CT) affect image quality and diagnostic accuracy? *European Journal of Radiology*, 83.
- [Kak and Slaney, 1988] Kak, A. C. and Slaney, M. (1988). Principles of computerized tomographic imaging. *SIAM, Philadelphia*.
- [Kalender, 2005] Kalender, W. A. (2005). *Computed Tomography*. Wiley & Sons. ISBN 3-89578-216-5, 2nd Edition.
- [Kang et al., 2017] Kang, E., Min, J., and Ye, J. C. (2017). A deep convolutional neural network using directional wavelets for low-dose x-ray CT reconstruction. *Medical Physics*, 44(10):e360–e375.
- [Kearney et al., 2018] Kearney, V., Haaf, S., Sudhyadhom, A., Valdes, G., and Solberg, T. D. (2018). An unsupervised convolutional neural network-based algorithm for deformable image registration. *Physics in Medicine and Biology*, 63(18):185017.
- [Kingma and Ba, 2014] Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [Klein et al., 2020] Klein, L., Dorn, S., Amato, C., Heinze, S., Uhrig, M., Schlemmer, H.-P., Kachelrieß, M., and Sawall, S. (2020). Effects of detector sampling on noise reduction in clinical photon-counting whole-body computed tomography. *Investigative Radiology*, 55(2):111–119.

- [Krauss et al., 2011] Krauss, B., Schmidt, B., and Flohr, T. (2011). Dual source CT, in dual energy CT in clinical practice. *Springer*, pages 11–20.
- [Krieger, 2004] Krieger, H. (2004). Grundlagen der Strahlungsphysik und des Strahlenschutzes. 1.
- [Krings et al., 2021] Krings, J. G., Goss, C. W., Lew, D., Samant, M., McGregor, M. C., Boomer, J., Bacharier, L. B., Sheshadri, A., Hall, C., Brownell, J., et al. (2021). Quantitative CT metrics are associated with longitudinal lung function decline and future asthma exacerbations: Results from SARP-3. *Journal of Allergy and Clinical Immunology*.
- [Krizhevsky et al., 2012] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [Lei et al., 2016] Lei, R., Yingxuan, C., You, Z., William, G., Jianyue, J., and Fang-Fang, Y. (2016). Scatter reduction and correction for dual-source cone-beam CT using prepatient grids. *Technology in Cancer Research & Treatment*, 15(3):416–427.
- [Lell and Kachelrieß, 2020] Lell, M. M. and Kachelrieß, M. (2020). Recent and upcoming technological developments in computed tomography: high speed, low dose, deep learning, multienergy. *Investigative Radiology*, 55(1):8–19.
- [Lell et al., 2015] Lell, M. M., Wildberger, J. E., Alkadhi, H., Damilakis, J., and Kachelrieß, M. (2015). Evolution in computed tomography: The battle for speed and dose. *Investigative Radiology*, 50(9):629–644.
- [Leng et al., 2018] Leng, S., Rajendran, K., Gong, H., Zhou, W., Halaweish, A. F., Henning, A., Kappler, S., Baer, M., Fletcher, J. G., and McCollough, C. H. (2018). 150- μm spatial resolution using photon-counting detector computed tomography technology: technical performance and first patient images. *Investigative Radiology*, 53(11):655–662.

- [Li et al., 2008] Li, H., Mohan, R., and Zhu, X. R. (2008). Scatter kernel estimation with an edge-spread function method for cone-beam computed tomography imaging. *Physics in Medicine and Biology*, 53(23):6729–6748.
- [Love and Kurger, 1987] Love, L. A. and Kurger, R. A. (1987). Scatter estimation for a digital radiographic system using convolution filtering. *Medical Physics*, 14(2):178–185.
- [Lu et al., 2017] Lu, L., Zheng, Y., Carneiro, G., and Yang, L. (2017). Deep learning and convolutional neural networks for medical image computing. *Advances in computer vision and pattern recognition*, 10:978–3.
- [Maaß et al., 2011] Maaß, C., Meyer, E., and Kachelrieß, M. (2011). Exact dual energy material decomposition from inconsistent rays (MDIR). *Medical Physics*, 38(2):691–700.
- [Mahesh, 2013] Mahesh, M. (2013). The essential physics of medical imaging, third edition. *Medical Physics*, 40(7):077301.
- [Maier et al., 2019a] Maier, A., Syben, C., Lasser, T., and Riess, C. (2019a). A gentle introduction to deep learning in medical image processing. *Zeitschrift für Medizinische Physik*, 29(2):86–101.
- [Maier et al., 2019b] Maier, J., Eulig, E., Vöth, T., Knaup, M., Kuntz, J., Sawall, S., and Kachelrieß, M. (2019b). Real-time scatter estimation for medical CT using the deep scatter estimation: Method and robustness analysis with respect to different anatomies, dose levels, tube voltages, and data truncation. *Medical Physics*, 46(1):238–249.
- [Maier et al., 2021] Maier, J., Lebedev, S., Erath, J., Eulig, E., Sawall, S., Fournié, E., Stierstorfer, K., Lell, M., and Kachelrieß, M. (2021). Deep learning-based coronary artery motion estimation and compensation for short-scan cardiac CT. *Medical Physics*, 48(7):3559–3571.

- [Maier et al., 2018] Maier, J., Sawall, S., Knaup, M., and Kachelrieß, M. (2018). Deep scatter estimation (DSE): Accurate real-time scatter estimation for x-ray CT using a deep convolutional neural network. *Journal of Nondestructive Evaluation*, 37(3):57.
- [Mainegra-Hing and Kawrakow, 2010] Mainegra-Hing, E. and Kawrakow, I. (2010). Variance reduction techniques for fast Monte Carlo CBCT scatter correction calculations. *Physics in Medicine and Biology*, 55 16:4495–507.
- [Matt et al., 2007] Matt, D., Scheffel, H., Leschka, S., Flohr, T. G., Marincek, B., Kaufmann, P., and Alkadi, H. (2007). Dual-source CT coronary angiography: image quality, mean heart rate, and heart rate variability. *AJR Am J Roentgenol.*, 189,3:567 – 73.
- [Meschede, 2002] Meschede, D. (2002). Gerthsen physik. 21. auflage.
- [Nikl, 2006] Nikl, M. (2006). Scintillation detectors for x-rays. *Measurement Science and Technology*, 17(4):R37.
- [Ohnesorge et al., 1999a] Ohnesorge, B., Flohr, T., Becker, C., Kopp, A., and Knez, A. (1999a). Comparison of EBCT and ECG-gated multislice spiral CT: A study of 3D Ca-scoring with phantom and patient data. *Radiology*, 213(P):402.
- [Ohnesorge et al., 1999b] Ohnesorge, B., Flohr, T., and Klingenbeck-Regn, K. (1999b). Efficient object scatter correction algorithm for third and fourth generation CT scanners. *European Radiology*, 9:563–569.
- [Oppelt, 2006] Oppelt, A. (2006). Imaging systems for medical diagnostics: fundamentals, technical solutions and applications for systems applying ionizing radiation, nuclear magnetic resonance and ultrasound. *John Wiley & Sons*.
- [Pantos et al., 2011] Pantos, I., Thalassinou, S., Argentos, S., Kelekis, N., Panayiotakis, G., and Efstathopoulos, E. (2011). Adult patient radiation doses from non-cardiac CT examinations: A review of published results. *The British Journal of Radiology*, 84(100):293–303.

- [Petersilka et al., 2008] Petersilka, M., Bruder, H., Stierstorfer, K., and Flohr, T. (2008). Technical principles of dual source CT. *European Journal of Radiology*, 68:362–368.
- [Petersilka et al., 2010] Petersilka, M., Stierstorfer, K., Bruder, H., and Flohr, T. (2010). Strategies for scatter correction in dual source CT. *Medical Physics*, 37(11):5971–5992.
- [Pourmorteza et al., 2018] Pourmorteza, A., Symons, R., Henning, A., Ulzheimer, S., and Bluemke, D. A. (2018). Dose efficiency of quarter-millimeter photon-counting computed tomography: first-in-human results. *Investigative Radiology*, 53(6):365–372.
- [Pratt et al., 1973] Pratt, R., Ron, A., and Tseng, H. (1973). Atomic photoelectric effect above 10 keV. *Reviews of Modern physics*, 45(2):273.
- [Reske and Seiwerts, 2009] Reske, A. and Seiwerts, M. (2009). Qualitative und quantitative CT-Analysen beim akuten Lungenversagen. *Der Radiologe*, 49(8):687–697.
- [Rinkel et al., 2007] Rinkel, J., Gerfault, L., Estève, F., and Dinten, J.-M. (2007). A new method for x-ray scatter correction: First assessment on a cone-beam CT experimental setup. *Physics in Medicine and Biology*, 52(15):4633–4652.
- [Ronneberger et al., 2015] Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. pages 234–241. Springer, International Conference on Medical image computing and computer-assisted intervention.
- [Rorat et al., 2021] Rorat, M., Jurek, T., Simon, K., and Guziński, M. (2021). Value of quantitative analysis in lung computed tomography in patients severely ill with covid-19. *PLoS One*, 16(5):e0251946.
- [Rührnschopf and Klingenbeck, 2011a] Rührnschopf, E.-P. and Klingenbeck, K. (2011a). A general framework and review of scatter correction methods in cone beam CT. part 2: Scatter estimation approaches. *Medical Physics*, 38(9):5186–5199.
- [Rührnschopf and Klingenbeck, 2011b] Rührnschopf, E.-P. and Klingenbeck, K. (2011b). A general framework and review of scatter correction methods in x-ray

- cone-beam computerized tomography. part 1: Scatter compensation approaches. *Medical Physics*, 38(7):4296–4311.
- [Salvat et al., 2001] Salvat, F., Fernández-Varea, J. M., Acosta, E., and Sempau, J. P. (2001). A code system for Monte Carlo simulation of electron and photon transport. In *Proceedings of a Workshop/Training Course, OECD/NEA*, pages 5–7.
- [Samei and J., 2019] Samei, E. and J., P. D. (2019). Hendeer’s physics of medical imaging. *Wiley-Blackwell*, 5th Edition.
- [Schirmacher et al., 2017] Schirmacher, F., Köhler, T., Husvogt, L., Fujimoto, J. G., Hornegger, J., and Maier, A. K. (2017). Quasi: Quantile sparse image prior for spatio-temporal denoising of retinal oct data. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 83–91. Springer.
- [Schlegel and Bille, 2008] Schlegel, W. and Bille, J. (2008). Medizinische Physik.
- [Schlegel et al., 2018] Schlegel, W., Karger, C. P., and Jäkel, O. (2018). Medizinische Physik: Grundlagen–Bildgebung–Therapie–Technik. *Springer-Verlag*, pages 153–204.
- [Seibert and Boone, 2005] Seibert, J. and Boone, J. M. (2005). X-ray imaging physics for nuclear medicine technologists. part 2: X-ray interactions and image formation. *Journal of Nuclear Medicine Technology*, 33.
- [Seibert, 2004] Seibert, J. A. (2004). X-ray imaging physics for nuclear medicine technologists. part 1: Basic principles of x-ray production. *Journal of Nuclear Medicine Technology*, 32(3):139–147.
- [Shefer et al., 2013] Shefer, E., Altman, A., Behling, R., Goshen, R., Gregorian, L., Rorterman, Y., Uman, I., Wainer, N., Yagil, Y., and Zarchin, O. (2013). State of the art of CT detectors and sources: A literature review. *Current Radiology Reports*, 1(1):76–91.
- [Siewerdsen et al., 2006] Siewerdsen, J. H., Daly, M. J., Bakhtiar, B., Moseley, D. J., Richard, S., Keller, H., and Jaffray, D. A. (2006). A simple, direct method for x-ray

- scatter estimation and correction in digital radiography and cone-beam CT. *Medical Physics*, 33(1):187–197.
- [Sun and Star-Lack, 2010] Sun, M. and Star-Lack, J. M. (2010). Improved scatter correction using adaptive scatter kernel superposition. *Physics in Medicine and Biology*, 55(22):6695–6720.
- [Swindell and Evans, 1996] Swindell, W. and Evans, P. M. (1996). Scattered radiation in portal images: A monte Carlo simulation and a simple physical model. *Medical Physics*, 23(1):63–73.
- [Taguchi et al., 2010] Taguchi, K., Frey, E. C., Wang, X., Iwanczyk, J. S., and Barber, W. C. (2010). An analytical model of the effects of pulse pileup on the energy spectrum recorded by energy resolved photon counting x-ray detectors. *Medical Physics*, 37(8):3957–3969.
- [Taguchi and Iwanczyk, 2013] Taguchi, K. and Iwanczyk, J. S. (2013). Vision 20/20: Single photon counting x-ray detectors in medical imaging. *Medical Physics*, 40(10):100901.
- [Taguchi et al., 2009] Taguchi, K., Srivastava, S., Kudo, H., and Barber, W. C. (2009). Enabling photon counting clinical x-ray CT. In *2009 IEEE Nuclear Science Symposium Conference Record (NSS/MIC)*, pages 3581–3585.
- [Taguchi et al., 2011] Taguchi, K., Zhang, M., Frey, E. C., and Wang, X. (2011). Modeling the performance of a photon counting x-ray detector for CT: Energy response and pulse pileup effects. *Medical Physics*, 38(2):1089–1102.
- [Tucker et al., 1991] Tucker, D. M., Barnes, G. T., and Chakraborty, D. P. (1991). Semiempirical model for generating tungsten target x-ray spectra. *Medical Physics*, 18(3):211–218.
- [Vöth, 2019] Vöth, T. (2019). Cross-scatter correction in dual source CT using the deep scatter estimation. *Master Thesis at the Heidelberg University*.

- [Vöth et al., 2019] Vöth, T., Maier, J., Erath, J., and Kachelrieß, M. (2019). Forward and cross-scatter estimation in dual source CT using the deep scatter estimation (dse). In *Medical Imaging 2019: Physics of Medical Imaging*, volume 10948, pages 174–179. SPIE.
- [White, 1977] White, D. R. (1977). An analysis of the z-dependence of photon and electron interactions. *Physics in Medicine and Biology*, 22(2):219–228.
- [Wolterink et al., 2017] Wolterink, J. M., Leiner, T., Viergever, M. A., and Išgum, I. (2017). Generative adversarial networks for noise reduction in low-dose CT. *IEEE Transactions on Medical Imaging*, 36(12):2536–2545.
- [Wortman et al., 2018] Wortman, J. R., Uyeda, J. W., Fulwadhva, U. P., and Sodickson, A. D. (2018). Dual-energy CT for abdominal and pelvic trauma. *RadioGraphics*, 38(2):586–602.
- [Ye et al., 2018] Ye, D. H., Buzzard, G. T., Ruby, M., and Bouman, C. A. (2018). Deep back projection for sparse-view ct reconstruction. In *2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, pages 1–5.
- [Zaidi and Ay, 2007] Zaidi, H. and Ay, M. R. (2007). Current status and new horizons in Monte Carlo simulation of x-ray CT scanners. *Med. Bio. Eng. Comput.*, 45:809–817.
- [Zhang and Yu, 2018] Zhang, Y. and Yu, H. (2018). Convolutional neural network based metal artifact reduction in x-ray computed tomography. *IEEE Transactions on Medical Imaging*, 37(6):1370–1381.
- [Zhao et al., 2016] Zhao, J., Chen, Z., Zhang, L., and Jin, X. (2016). Few-view ct reconstruction method based on deep learning. In *2016 IEEE Nuclear Science Symposium, Medical Imaging Conference and Room-Temperature Semiconductor Detector Workshop (NSS/MIC/RTSD)*, pages 1–4.
- [Zheng et al., 2016] Zheng, X., Lu, Z., Ravishankar, S., Long, Y., and Fessler, J. A. (2016). Low dose CT image reconstruction with learned sparsifying transform. In

2016 IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP), pages 1–5.

Publikationsliste

Zeitschriftenartikel

- [1] **J. Erath**, T. Vöth, J. Maier, E. Fournié, M. Petersilka, K. Stierstorfer, and M. Kachelrieß, “Deep learning-based forward and cross-scatter correction in dual-source CT,” *Medical Physics*, vol. 48, no. 9, pp. 4824–4842, 2021, **Editors Choice Sept. 2021**
- [2] J. Maier, S. Lebedev, **J. Erath**, E. Eulig, S. Sawall, E. Fournié, K. Stierstorfer, M. Lell, and M. Kachelrieß, “Deep learning-based coronary artery motion estimation and compensation for short-scan cardiac CT,” *Medical Physics*, vol. 48, no. 7, pp. 3559–3571, 2021.

Konferenzbeiträge

- [1] **J. Erath**, J. Maier, E. Fournié, T. Vöth, K. Stierstorfer, and M. Kachelrieß, „Monte Carlo-free deep scatter estimation (DSE) for x-ray CT and CBCT“, *Program of the 105th Scientific Assembly and Annual Meeting of the RSNA*, pp. SSE 24–06, Dec. 2019.
- [2] **J. Erath**, T. Vöth, J. Maier, E. Fournié, K. Stierstorfer, M. Petersilka, and M. Kachelrieß, „Deep learning-based cross-scatter correction for clinical CT“, *Conference Record of the 6th International Conference on Image Formation in X-Ray Computed Tomography*, pp. 412–415, Aug. 2020.
- [3] **J. Erath**, T. Vöth, J. Maier, E. Fournié, M. Petersilka, K. Stierstorfer, and M. Kachelrieß, „Deep scatter estimation (DSE) and correction for dual-source dual-energy CT“, *ECR Book of Abstracts, Insights into Imaging*, vol. 12, no. 75, 2021.

- [4] **J. Erath**, T. Vöth, J. Maier, E. Fournié, M. Petersilka, K. Stierstorfer, and M. Kachelrieß, „Estimating the high scatter frequencies caused by coarse anti scattergrids in x-ray CT“, *ECR Book of Abstracts, Insights into Imaging*, 2022.
- [5] T. Vöth, J. Maier, **J. Erath**, and M. Kachelrieß, „Forward and cross-scatter estimation in dual source CT using the deep scatter estimation (DSE)“, *SPIE Medical Imaging Proc.*, vol. 10948, Mar. 2019.
- [6] L. Heinz, **J. Erath**, J. Maier, K. Stierstorfer, M. Kachelrieß, „Performance of Different Anti-Scatter Grids (ASGs) combined with the Deep Scatter Estimation (DSE) Algorithm“, *ECR Book of Abstracts, Insights into Imaging*, 2022.

Curriculum Vitae

PERSONALIEN

Name	Julien Frank Josef Erath
Geburtsdatum	07.05.1990
Geburtsort	Nizza / Frankreich
Familienstand	Ledig
Staatsangehörigkeit	Deutsch / Französisch

SCHULISCHER WERDEGANG

1996 - 2000	Grundschule Ketschendorf
2000 - 2004	Gymnasium Ernestinum Coburg
2004 - 2009	Ulrich-von-Hutten Gymnasium Schlüchtern
2009	Allgemeine Hochschulreife (Abitur)

UNIVERSITÄRER WERDEGANG

10/2010 - 04/2015	Bachelor of Science (B. Sc.) Medizintechnik Friedrich-Alexander-Universität Erlangen-Nürnberg Abschlussarbeit: „Particle Tracking zur Bestimmung des mechanischen Verhaltens von Perikard“
08/2013 - 05/2014	École de Technologie Supérieure, Montréal Canada
10/2015 - 04/2018	Master of Science (M. Sc.) Medizintechnik Friedrich-Alexander-Universität Erlangen-Nürnberg Abschlussarbeit: „Kultur bakterieller Cellulose in 3-D Form“
Seit 10/2018	Doktorand, Deutsches Krebsforschungszentrum (DKFZ) Abteilung Röntgenbildgebung und Computertomographie Medizinische Fakultät Ruprecht-Karls-Universität Heidelberg Abschlussarbeit: „Korrektur von Streustrahlartefakten durch tiefe neuronale Netze in der klinischen Computertomographie“

Danksagung

An dieser Stelle möchte mich herzlich bei allen bedanken, die mich während meiner Promotion unterstützt haben:

Prof. Dr. Marc Kachelrieß für die hervorragende wissenschaftliche Betreuung und die Übernahme des Erstgutachtens der vorliegenden Arbeit. Vielen Dank Marc für die Möglichkeit in deiner Arbeitsgruppe promovieren zu können und die vielen Einblicke in dieses interessante Themengebiet. Die zahlreichen Denkanstöße und deine Expertise haben einen großen Teil zu dieser Arbeit beigetragen.

Dr. Karl Stierstorfer für die ausgezeichnete Betreuung und die Gelegenheit mit Siemens Healthineers promovieren zu können. Vielen Dank Karl, deine uneingeschränkte Unterstützung und dauerhafte Motivation haben diese Arbeit erst ermöglicht.

Weiterhin danke ich besonders Dr. Martin Petersilka und Eric Fournié. Vielen Dank für eure kontinuierliche Unterstützung.

Dr. Joscha Maier für die vielen Ideen und fachliche Unterstützung.

Sämtlichen Kollegen der Arbeitsgruppe „Röntgenbildgebung und Computertomographie“ für die angenehme und freundschaftliche Arbeitsatmosphäre. Besonderer Dank gilt dabei Carlo, Elias, Laura, Markus, Philip, Sergej, Stefan und Tim.

Den Siemens CT-Physik Kollegen für die netten Gespräche und ihre stetige Hilfsbereitschaft, insbesondere Sascha Manuel, Viktor und Jan für die schöne Zeit.

Ganz herzlich möchte ich mich auch bei meiner Familie, insbesondere meinen Eltern und meiner Schwester bedanken. Merci pour votre aide.

Ein ganz besonderer Dank gilt meiner Partnerin für ihre dauerhafte Unterstützung und Geduld während der gesamten Promotion.

Eidesstattliche Erklärung

1. Bei der eingereichten Dissertation zu dem Thema „Korrektur von Streustrahlartefakten durch tiefe neuronale Netze in der klinischen Computertomographie“ handelt es sich um meine eigenständig erbrachte Leistung.
2. Ich habe nur die angegebenen Quellen und Hilfsmittel benutzt und mich keiner unzulässigen Hilfe Dritter bedient. Insbesondere habe ich wörtlich oder sinngemäß aus anderen Werken übernommene Inhalte als solche kenntlich gemacht.
3. Die Arbeit oder Teile davon habe ich bislang nicht an einer Hochschule des In- oder Auslands als Bestandteil einer Prüfungs- oder Qualifikationsleistung vorgelegt.
4. Die Richtigkeit der vorstehenden Erklärungen bestätige ich.
5. Die Bedeutung der eidesstattlichen Versicherung und die strafrechtlichen Folgen einer unrichtigen oder unvollständigen eidesstattlichen Versicherung sind mir bekannt. Ich versichere an Eides statt, dass ich nach bestem Wissen die reine Wahrheit erklärt und nichts verschwiegen habe.

Heidelberg, 17. März 2022