Aus der

Radiologischen Universitätsklinik Tübingen

Diagnostische und interventionelle Radiologie

Evaluation künstlicher Intelligenz zur Optimierung angiographischer Interventionsverfahren: Einfluss auf die Bildqualität und diagnostische Aussagekraft in der Cone-Beam-Computertomographie

Inaugural- Dissertation
zur Erlangung des Doktorgrades
der Medizin

der Medizinischen Fakultät
der Eberhard Karls Universität
zu Tübingen

vorgelegt von

Dehdab, Reza

2026

Dekanin:	Professorin Dr. S. Y. Brucker
1. Berichterstatter:	Prof. Dr. S. K. Afat
2. Berichterstatter:	Prof. Dr. C. Gani
Tag der Disputation:	12.10.2026

Lizenzhinweis

Dieses Werk ist lizenziert unter der Creative Commons Namensnennung – Nicht kommerziell – Keine Bearbeitungen 4.0 International Lizenz (CC BY-NC-ND 4.0).

Der vollständige Lizenztext ist unter folgendem Link abrufbar:

https://creativecommons.org/licenses/by-nc-nd/4.0/legalcode.de

Für meine Eltern

Inhaltsverzeichnis

Inhalt

Inhaltsverzeichnis 2

Abkürzungsverzeichnis 5

1. Einleitung 5

1.1 Bildgebung in der interventionellen Radiologie 5

1.2 Grundlagen der Cone-Beam-CT und Bildentstehung 6

1.3 Rauschquellen und Artefakte in der CBCT 8

1.4 Notwendigkeit der Rauschunterdrückung und Bildqualitätsverbesserung 14

1.4.1 Traditionelle Methoden der Rauschunterdrückung in der medizinischen Bildgebung 15

1.5 KI in der medizinischen Bildgebung 17

1.5.1 Deep-Learning und neuronale Netze 18

1.5.2 Vielfalt der Deep-Learning-Architekturen und -Methoden 19

1.6 Anwendungen von KI-Denoising in verschiedenen medizinischen Bildgebungsmodalitäten 28

1.7 Spezifische Anwendungen von KI in der interventionellen Radiologie 30

1.8 Zielsetzung und Fragestellung 32

2 Material und Methoden 33

2.1 Studiendesign und Patientenpopulation 33
2.2 Bildakquisition und Rekonstruktion 35
2.3 KI-Denoising-Algorithmus 36
2.4 Objektive Bildqualitätsanalyse 38
2.5 Subjektive Bildqualitätsanalyse 39
2.6 Statistische Analyse 40
3 Ergebnisse 41
3.1 Patientencharakteristika und Dosis-FlächenProdukt (DAP) 41
3.2 Objektive Bildqualitätsmetriken (SNR, CNR, Rauschen) 42
3.3 Subjektive Beurteilung der Bildqualität 47
4 Diskussion 52
4.1 Interpretation der Hauptergebnisse 52
4.2 Vergleich mit bestehender Literatur 54
4.3 Relevanz für die klinische Anwendung 55
4.4 Integration in den klinischen Workflow und Akzeptanz 56
4.5 Potenzial für neue interventionelle Verfahren und Techniken 57
4.6 Ethische und rechtliche Aspekte der KI-Anwendung 57
4.7 Limitationen 59
4.8 Ausblick 61
5 Zusammenfassung 63

6 Literaturverzeichnis 65

7 Anhang 74

7.1 Abbildungsverzeichnis 74

7.2 Tabellenverzeichnis 76

8. Erklärung zum Eigenanteil 77

9. Veröffentlichungen 79

10. Danksagungen 80

Abkürzungsverzeichnis

CT	Computertomographie
CBCT	Cone-Beam-Computertomographie
FBP	Filtered Back Projection
MDCT	Mehrzeilen-CT
CNR	Kontrast Rausch-Verhältnis
KI	Künstliche Intelligenz
CNN	Convolutional Neural Networks
RNN	Rekurrente Neuronale Netze
GAN	Generative Adversarial Networks
AE	Autoencoder
DRL	Deep Reinforcement Learning
GNN	Graph Neural Network
MRT	Magnetresonanztomographie
PET	Positronen-Emissions-Tomographie
SNR	Signal-Rausch-Verhältnis
HU	Hounsfield-Einheiten
TIPSS	Transjugulärer Intrahepatischer Portosystemischer Shunt
BMI	Body Mass Index
ROI	Regionen von Interesse

1. Einleitung

1.1 Bildgebung in der interventionellen Radiologie

Die interventionelle Radiologie ist ein medizinisches Fachgebiet, das minimal-invasive, bildgesteuerte Verfahren zur Diagnose und Behandlung einer Vielzahl von Erkrankungen einsetzt[1]. Dazu zählen die Gefäßembolisation, Katheterplatzierungen und onkologische Interventionen[2]. Die Qualität der Bildgebung ist dabei von entscheidender Bedeutung, da sie die Grundlage für die präzise Navigation von Instrumenten und die genaue Beurteilung anatomischer Strukturen bildet[3] (Abb. 1). Herausforderungen in der interventionellen Bildgebung umfassen die Notwendigkeit einer hohen räumlichen und zeitlichen Auflösung, die Minimierung der Strahlenexposition für Patient und Personal sowie der Umgang mit Bewegungsartefakten, die insbesondere bei längeren Akquisitionszeiten auftreten können[4]. Eine suboptimale Bildqualität kann zu Unsicherheiten bei der Diagnose, verlängerten Prozedurzeiten und potenziell schlechteren Patientenergebnissen führen[5].

1.2 Grundlagen der Cone-Beam-CT und Bildentstehung

Die Cone-Beam-Computertomographie (CBCT) ist eine spezielle Form der Computertomographie, die sich im Gegensatz zum fächerförmigen Strahl der konventionellen CT[6] (Abb.1) durch die Verwendung eines kegelförmigen Röntgenstrahls auszeichnet. Dieser kegelförmige Strahl ermöglicht die simultane Erfassung eines gesamten Volumens in einer einzigen Rotation des C-Bogens um den Patienten. Die Detektion erfolgt durch einen großflächigen Flachdetektor, der die durch den Patienten transmittierten Röntgenstrahlen in ein D-Projektionsbild umwandelt. Während einer typischen CBCT-Akquisition werden hunderte solcher Projektionsbilder aus verschiedenen Winkeln aufgenommen. Diese D-Projektionen werden anschließend mittels komplexer Rekonstruktionsalgorithmen, wie der gefilterten Rückprojektion (Filtered Back Projection, FBP) oder iterativen Rekonstruktionsmethoden, zu einem dreidimensionalen Datensatz des untersuchten Volumens verarbeitet[6,7]. Die Vorteile der CBCT liegen in ihrer Fähigkeit, hochauflösende D-Bilder mit relativ geringem physischem Platzbedarf und oft auch geringeren Kosten im Vergleich zu herkömmlichen CT-Systemen zu erzeugen[6,8,9]. Dies macht sie besonders attraktiv für den Einsatz in der interventionellen Radiologie, wo präzise D-Informationen für die Navigation von Instrumenten und die Lokalisierung von Zielstrukturen unerlässlich sind (Abb. 2)[10].

Abbildung 1: Selbst erstellte Abbildung der Angiographieeinheit (CBCT) zur interventionellen Bildgebung in der Radiologie/Neuroradiologie Universitätsklinikum Tübingen.

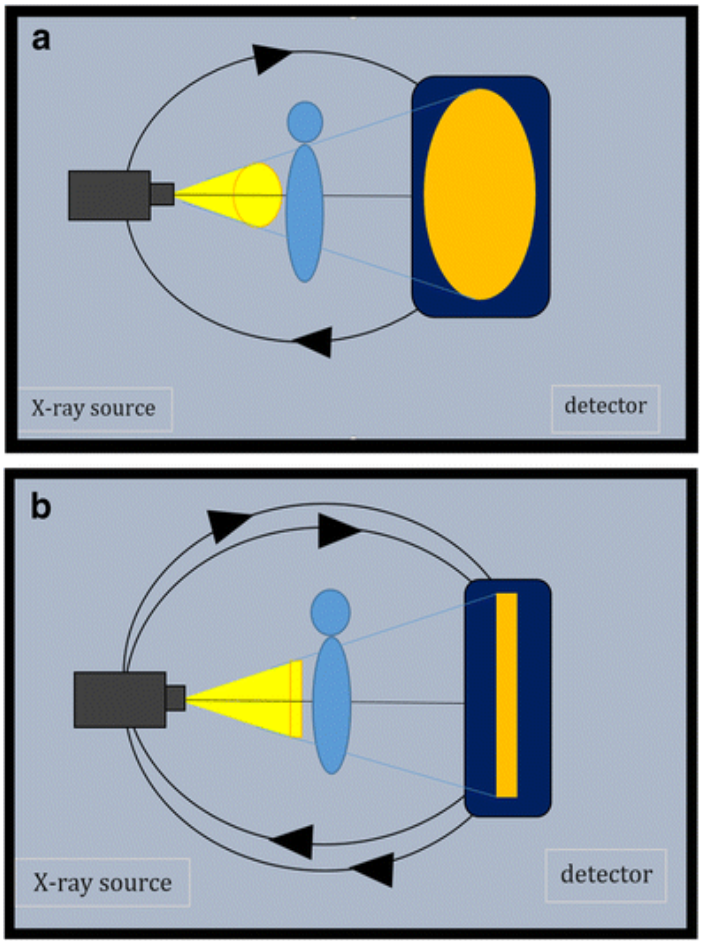

Abbildung 2: Prinzip von CBCT und Mehrzeilen-CT (MDCT). a Bei der CBCT trifft ein kegelförmiger Röntgenstrahl nach einer einzigen Rotation des Gantry um den Patienten auf einen flachen Detektor. b Bei der MDCT rotiert ein eng kollimierter, fächerförmiger Röntgenstrahl zusammen mit mehreren linearen Detektoren um den Patienten, um pro Rotation mehrere Bildschichten zu erfassen. modifiziert nach posadzy et al. (CCBY 4.0)[11]

1.3 Rauschquellen und Artefakte in der CBCT

Obwohl die CBCT zahlreiche Vorteile bietet, ist die Bildqualität häufig durch verschiedene Rauschquellen und Artefakte beeinträchtigt. Rauschen in medizinischen Bildern bezeichnet unerwünschte Schwankungen der Bildintensität, die die Sichtbarkeit feiner Details beeinträchtigen und dadurch die diagnostische Genauigkeit verringern können . In der CBCT sind die primären Rauschquellen:

- Quantenrauschen: Dies ist die dominierende Rauschquelle in der Röntgenbildgebung und entsteht durch die statistische Natur der Röntgenphotonen. Bei niedrigen Strahlendosen, die zur Reduzierung der Patientenexposition angestrebt werden, nimmt das Quantenrauschen zu, was zu körnigen und weniger detaillierten Bildern führt (Abb. 3)[12].

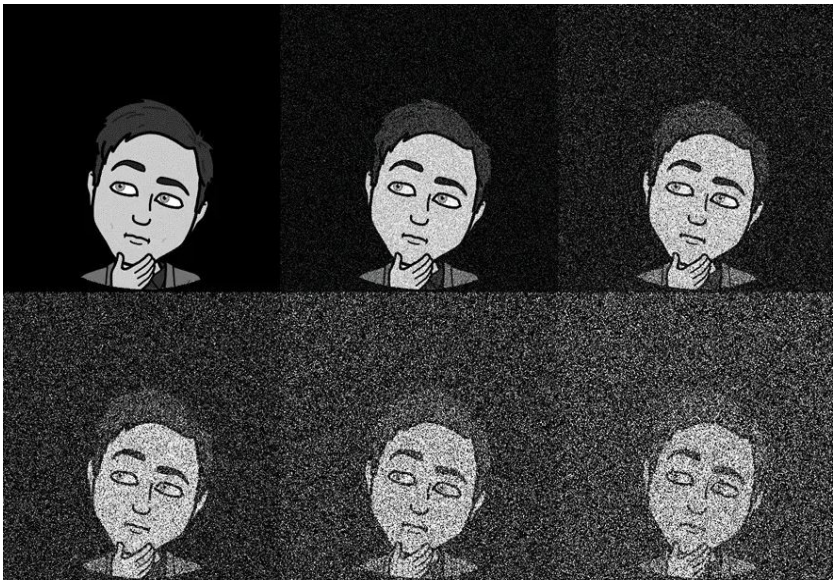

Abbildung 3: Quantenrauschen. Von oben links nach unten rechts nimmt das Quantenrauschen zu, wodurch die Detailerkennbarkeit erschwert wird. Abbildung frei zugänglich unter https://howradiologyworks.com/x-ray-cnr[13][13]

- Elektronisches Rauschen: Entsteht in den Detektoren und der Ausleseelektronik des CBCT-Systems. Obwohl das elektronische Rauschen heutzutage in modernen Systemen nur noch minimal vertreten ist, trägt es dennoch zum Gesamtrauschen bei (Abb. 4)[14].

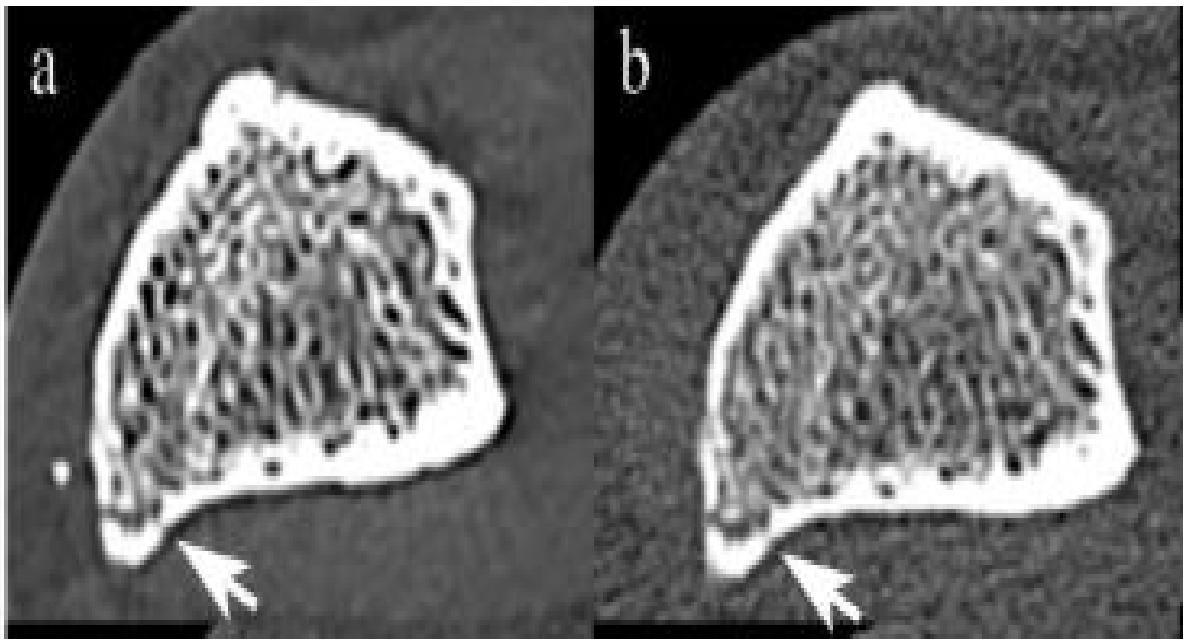

Abbildung 4: CT-Aufnahmen des Unterarms a) Photon-Counting-CT mit reduzierter elektronischer Rauschkomponente; b) Energie-integrierender Detektor mit insgesamt höherem Bildrauschen im Vergleich zu a. modifiziert nach fukuda et al. (CCBY)[15].

- Streustrahlung: Röntgenstrahlen, die im Körper des Patienten gestreut werden, treffen den Detektor aus unerwarteten Richtungen. Dies führt zu einer Verringerung des Bildkontrasts sowie zu Artefakten wie Streifenbildungen[16].

- Bewegungsartefakte: Patientenbewegungen während der Akquisition, insbesondere Atembewegungen, können zu Unschärfen und Doppelkonturen in den rekonstruierten Bildern führen. Dies ist besonders relevant bei längeren Akquisitionszeiten, wie sie bei einigen CBCT-Protokollen vorkommen (Abb. 5).

Zusätzlich zu diesen Rauschquellen können weitere Artefakte die Bildqualität beeinträchtigen, darunter durch Detektorfehler verursachte Ringartefakte (Abb. 6) und durch die unterschiedliche Absorption von Röntgenstrahlen bei verschiedenen Energien verursachte Aufhärtungsartefakte (Abb. 7). Die Reduzierung dieser Rauschquellen und Artefakte ist entscheidend, um die diagnostische Qualität der CBCT-Bilder zu maximieren.

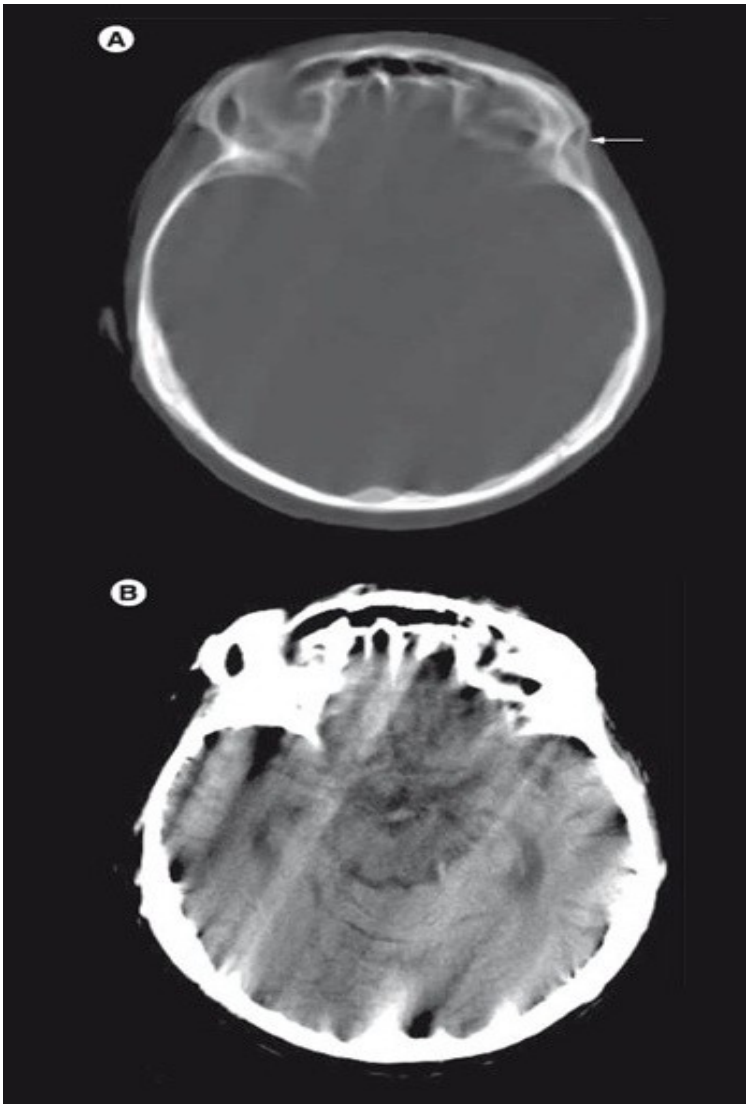

Abbildung 5: Bewegungsartefakte. Bewegungen während der Bildakquisition führen zu Unschärfen, Doppelkonturen (A) und langreichweitigen Streifenartefakten (B). modifiziert nach Boas et al. mit freundlicher Genehmigung zur nicht-kommerziellen Nutzung [17].

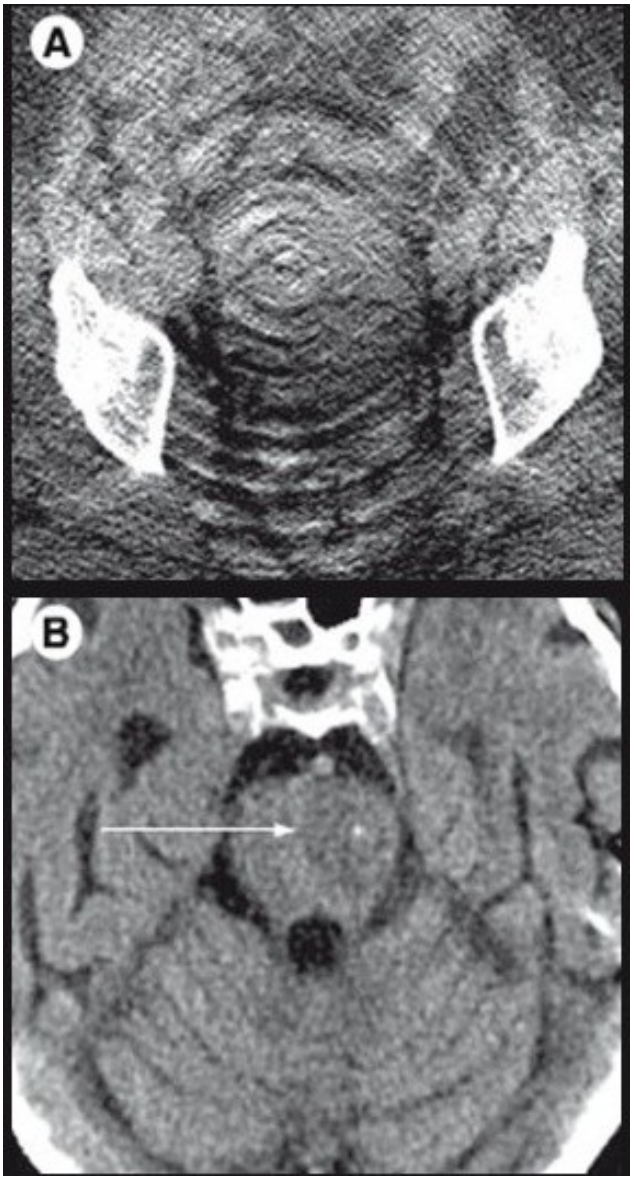

Abbildung 6: Ringartefakte. (A) Becken-CT mit ausgeprägtem Ringartefakt. (B) Schädel-CT mit subtil ausgeprägtem Ringartefakt, der fälschlicherweise eine Läsion im Pons (Pfeil) vortäuscht. modifiziert nach Boas et al. mit freundlicher Genehmigung zur nicht-kommerziellen Nutzung[17]

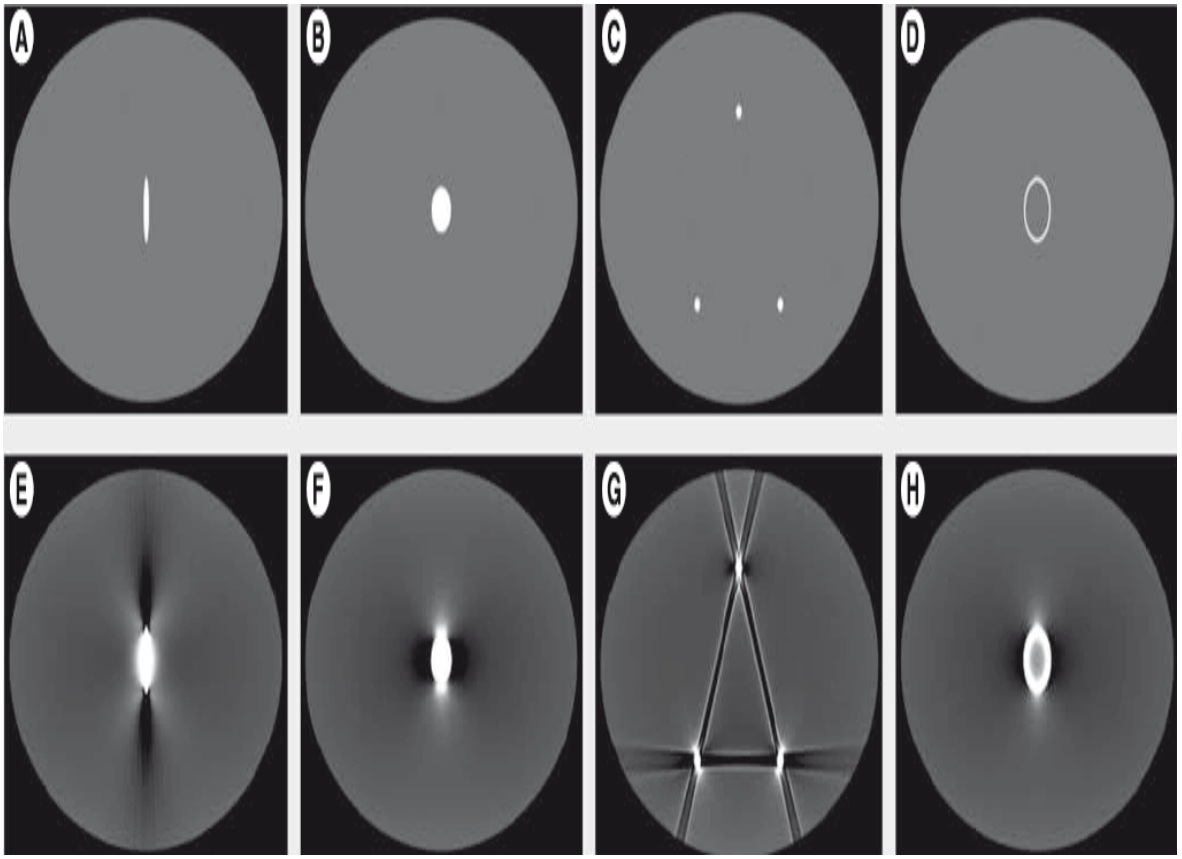

Abbildung 7: Aufhärtungsartefakte. (A–D) Simulierte Scans ohne und (E–H) mit Aufhärtungseffekten. Dunkle Streifen treten entlang der Linien mit der höchsten Abschwächung auf, während helle Streifen in anderen Richtungen erscheinen. Auch Streustrahlung kann zu ähnlichen Artefakten führen. modifiziert nach Boas et al. mit freundlicher Genehmigung zur nicht-kommerziellen Nutzung[17]

1.4 Notwendigkeit der Rauschunterdrückung und Bildqualitätsverbesserung

Eine wesentliche Einschränkung für die breite Anwendung der CBCT ist die vergleichsweise hohe Strahlenexposition, die mit diesem Verfahren einhergeht[18]. Um die Strahlenbelastung zu reduzieren, werden häufig Protokolle mit kürzeren Akquisitionszeiten oder niedrigeren Dosen verwendet. Dies kann jedoch zu einem erhöhten Bildrauschen und einer verminderten Bildqualität führen, was die diagnostische Aussagekraft der Bilder beeinträchtigen kann. Ein geringeres Kontrast-Rausch-Verhältnis (CNR) kann die Erkennung feiner anatomischer Details erschweren und somit die Sicherheit und Effektivität des Eingriffs gefährden[19](Abb. 8). Andererseits können längere Akquisitionszeiten, die zur Verbesserung der Bildqualität beitragen würden, die Wahrscheinlichkeit von Bewegungsartefakten erhöhen und sind mit einer höheren Strahlenexposition verbunden[20]. Daher besteht ein dringender Bedarf an Verfahren zur Rauschunterdrückung und Verbesserung der Bildqualität, die eine Reduktion der Strahlenexposition ermöglichen, ohne die diagnostische Aussagekraft zu beeinträchtigen. .

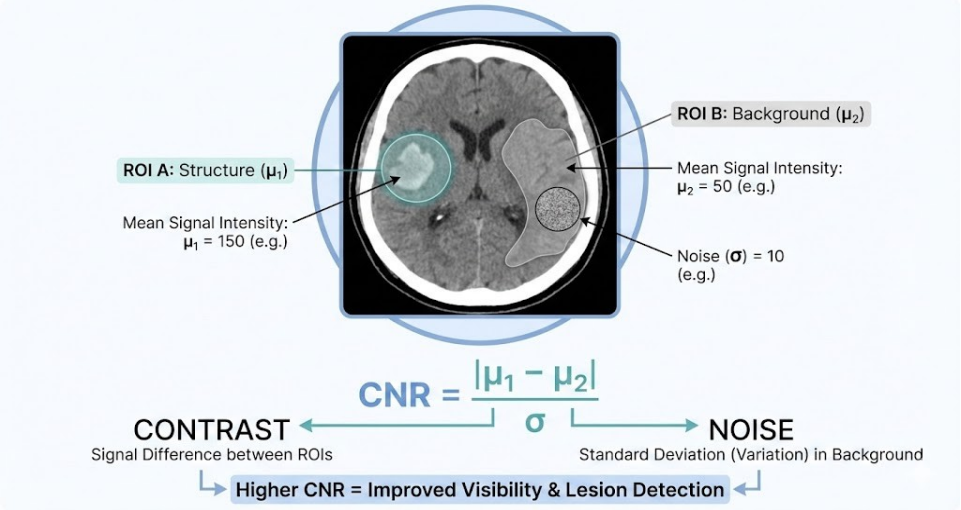

Abbildung 8: *Schematische Darstellung des CNR. Das CNR ergibt sich aus dem Signalunterschied zwischen zwei ROIs dividiert durch die Rauschstärke im Hintergrund (Standardabweichung). Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.*

1.4.1 Traditionelle Methoden der Rauschunterdrückung in der medizinischen Bildgebung

Traditionell kommen in der medizinischen Bildgebung verschiedene Verfahren zur Rauschunterdrückung zum Einsatz, die sich grob in zwei Kategorien einteilen lassen: hardwarebasierte und softwarebasierte Ansätze. .

Hardwarebasierte Ansätze konzentrieren sich auf die Optimierung der Bildakquisitionsparameter. Dazu gehören die Erhöhung der Röntgendosis, die Verwendung effizienterer Detektoren oder die Anpassung der Röhrenspannung und des Röhrenstroms. Eine höhere Dosis führt zwar zu einer Reduzierung des Quantenrauschens, ist jedoch mit einer erhöhten Strahlenexposition für den Patienten verbunden, was aus Gründen der Patientensicherheit oft unerwünscht ist[21].

Softwarebasierte Ansätze umfassen eine Vielzahl von Bildverarbeitungsalgorithmen, die nach der Akquisition auf die Rohdaten oder die rekonstruierten Bilder angewendet werden. Gängige Methoden sind:

- Lineare Filter: Dazu gehören der Mittelwertfilter und der Gauß-Filter, die das Rauschen durch Glättung der Bilddaten reduzieren. Sie sind einfach zu implementieren, können aber zu einer unerwünschten Unschärfe von Bilddetails und Kanten führen[22].

- Nichtlineare Filter: Beispiele hierfür sind der Medianfilter und der bilaterale Filter. Der Medianfilter ist effektiv bei der Reduzierung von Salt-and-Pepper Rauschen (äußert sich als vereinzelte sehr helle „salt“ und sehr dunkle „pepper“ Pixel). und führt im Vergleich zu linearen Filtern zu einer besseren Kantenerhaltung. Der bilaterale Filter glättet das Bild, während er Kanten und wichtige Strukturen durch Berücksichtigung sowohl der räumlichen Nähe als auch der Intensitätsähnlichkeit schützt[23].

- Iterative Rekonstruktionsalgorithmen: Diese Methoden versuchen, das Rauschen bereits während des Rekonstruktionsprozesses zu minimieren, indem sie iterative Optimierungsverfahren verwenden, die physikalische Modelle der Bildentstehung und Rauschverteilung berücksichtigen (Abb. 9). Sie können eine bessere Bildqualität bei niedrigeren Dosen liefern als die FBP, sind jedoch rechenintensiver[24].

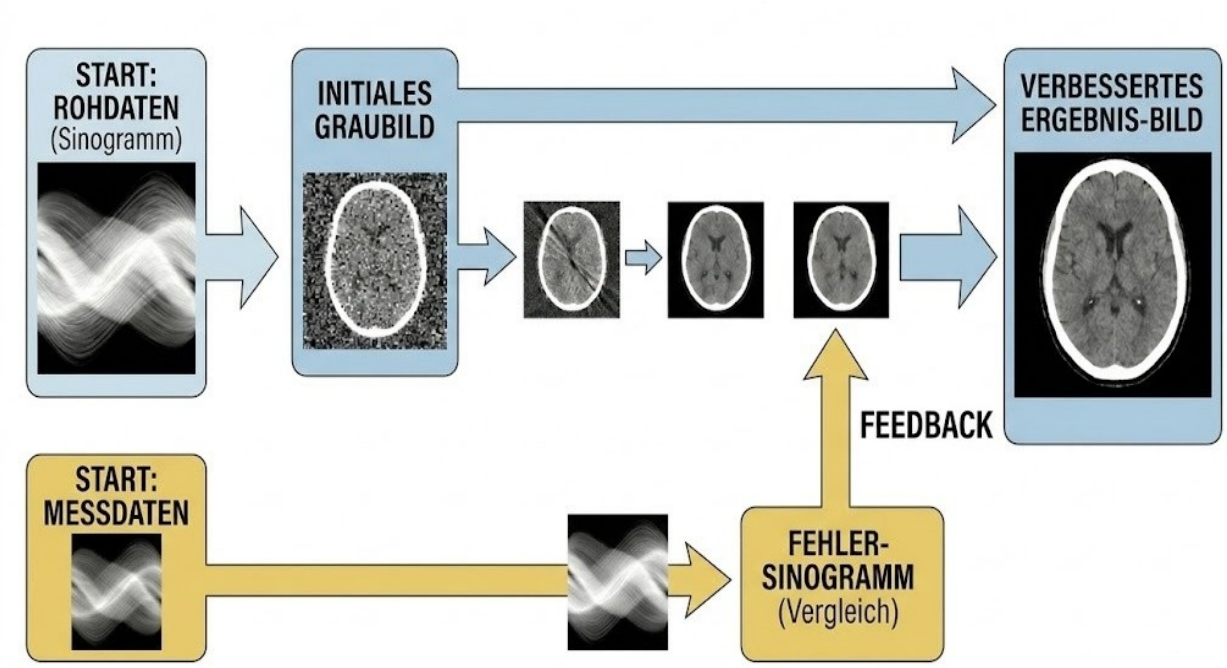

Abbildung 9: *Schematische Darstellung eines iterativen Rekonstruktionsverfahrens in der CT. Ausgehend von Rohdaten wird zunächst ein Bild geschätzt, das in einem iterativen Zyklus mit dem gemessenen Datensatz verglichen und anhand physikalischer Modelle sowie Rauschannahmen korrigiert wird. Durch wiederholte Anpassungen entsteht eine rauschärmere, qualitativ verbesserte Rekonstruktion. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.*

- Wavelet-basierte Methoden: Diese Ansätze zerlegen das Bild in verschiedene Frequenzkomponenten und wenden Schwellenwerte auf Wavelet-Koeffizienten an, um Rauschen zu entfernen. Sie sind effektiv bei der Erhaltung von Details, können aber bei der Auswahl der optimalen Schwellenwerte komplex sein[25,26].

Diese traditionellen Verfahren tragen zwar zur Rauschreduktion bei, stoßen jedoch häufig an ihre Grenzen. Insbesondere gelingt es ihnen nur bedingt, ein optimales Gleichgewicht zwischen Rauschunterdrückung und Detailerhalt zu erreichen, ohne die Strahlenexposition zu erhöhen. . Dies hat den Weg für neuere, datengesteuerte Ansätze wie die künstliche Intelligenz (KI) geebnet[27].

1.5 KI in der medizinischen Bildgebung

Jüngste Fortschritte in der KI haben post-processing-Techniken (nach der Bildaufnahme bzw. nach der Rekonstruktion) hervorgebracht, die in der Lage sind, die Bildqualität in radiologischen Interventionen erheblich zu verbessern. KI-basierte Denoising-Algorithmen können Rauschen und Artefakte effektiv aus medizinischen Bildern entfernen, während wichtige diagnostische Informationen erhalten bleiben[28]. Diese Algorithmen lernen aus großen Datensätzen von verrauschten und sauberen Bildern, um die zugrunde liegenden Muster zu erkennen und qualitativ hochwertige, rauschfreie Bilder zu rekonstruieren[29]. Die Anwendung von KI in der medizinischen Bildgebung ermöglicht eine Optimierung des Kompromisses zwischen Strahlenbelastung, Bildrauschen und Bewegungsartefakten, was zu kürzeren Akquisitionszeiten und einer reduzierten Strahlenexposition bei gleichzeitig erhaltener oder sogar verbesserter diagnostischer Qualität führen kann[30].

1.5.1 Deep-Learning und neuronale Netze

Deep-Learning ist ein Teilbereich des maschinellen Lernens, der auf künstlichen neuronalen Netzen mit mehreren Schichten (daher engl. „deep“, dt. „tief“) basiert (Abb. 10). Diese Netze sind in der Lage, komplexe Muster und Hierarchien in großen Datensätzen zu lernen, ohne explizit programmiert werden zu müssen. Die grundlegende Einheit eines neuronalen Netzes ist das Neuron. Dieses empfängt Eingaben, summiert diese nach Wichtung und erzeugt über eine Aktivierungsfunktion einen Output. Durch die Verbindung vieler Neuronen in Schichten entstehen komplexe Architekturen, die für Aufgaben wie Bilderkennung, Sprachverarbeitung und eben auch Bildverarbeitung eingesetzt werden können[31].

Die Entwicklung des Deep-Learning wurde durch drei Hauptfaktoren vorangetrieben: die Verfügbarkeit großer Datenmengen, leistungsfähigere Hardware, insbesondere Grafikprozessoren, sowie Fortschritte bei den Algorithmen, etwa durch verbesserte Aktivierungsfunktionen, Regularisierungstechniken und Optimierer.

Im Kontext der Bildverarbeitung haben sich insbesondere Convolutional Neural Networks (CNNs) als äußerst erfolgreich erwiesen[32].

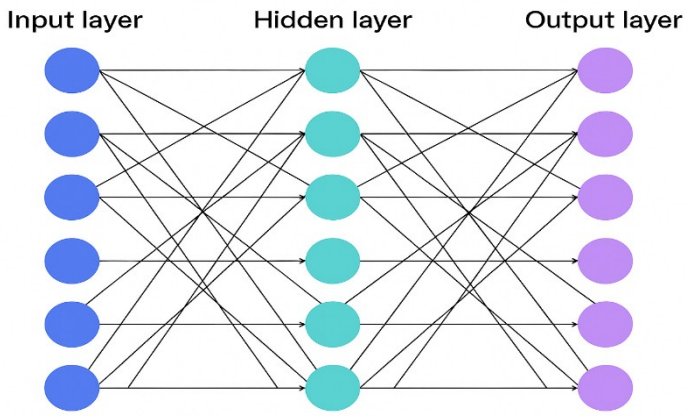

Abbildung 10: Schematische Darstellung eines künstlichen neuronalen Netzwerks (Architektur 8–5–5). Grafische Darstellung erstellt mit ChatGPT-5, eigene Illustration.

1.5.2 Vielfalt der Deep-Learning-Architekturen und -Methoden

Die Landschaft des Deep-Learning ist durch eine Vielfalt an Architekturen und Methoden gekennzeichnet, die jeweils für spezifische Problemstellungen optimiert sind. Neben den bereits erwähnten Modellen existiert eine breite Palette weiterer Ansätze, die in verschiedenen Domänen Anwendung finden:

CNN: CNNs sind speziell für die Verarbeitung von gitterartigen Daten (Daten auf einem regelmäßigen Raster mit lokalen Nachbarschaften) wie Bildern, Videos oder Zeitreihen konzipiert. Die zentrale Komponente ist die Faltungsschicht, die durch den Einsatz von Filtern (Kerneln) lokale räumliche Merkmale extrahiert und dabei die gleiche Filtergewichtung wiederverwendet, um die Anzahl der zu lernenden Parametern deutlich zu reduzieren. . Darauf folgen oft Pooling-Schichten, die die räumliche Dimension reduzieren und die Robustheit gegenüber kleinen Verschiebungen erhöhen. Durch das Stapeln dieser Schichten lernen CNNs eine hierarchische Merkmalsrepräsentation, von einfachen Kanten in den ersten Schichten bis zu komplexen Objekten in tieferen Schichten[33].

Rekurrente Neuronale Netze (RNNs): Diese Architekturen sind für die Verarbeitung sequenzieller Daten (z.B. Text, Sprache, Zeitreihen) unerlässlich, da sie eine interne Schleife besitzen, die es ihnen ermöglicht, Informationen aus vorherigen Schritten der Sequenz in einem verborgenen Zustand (hidden state) zu speichern. Um das Problem des verschwindenden Gradienten (vanishing gradient) bei langen Sequenzen zu überwinden, wurden spezialisierte Varianten entwickelt: Long-Short-Term Memory-Netzwerke nutzen eine komplexe Struktur aus Gates (Input, Forget, Output), um den Informationsfluss in einer Zellstruktur präzise zu steuern und so relevante Informationen über lange Zeiträume zu speichern. Gated Recurrent Units bieten eine vereinfachte, aber ähnlich effektive Alternative mit nur zwei Gates (Update, Reset) (Abb. 11)[34].

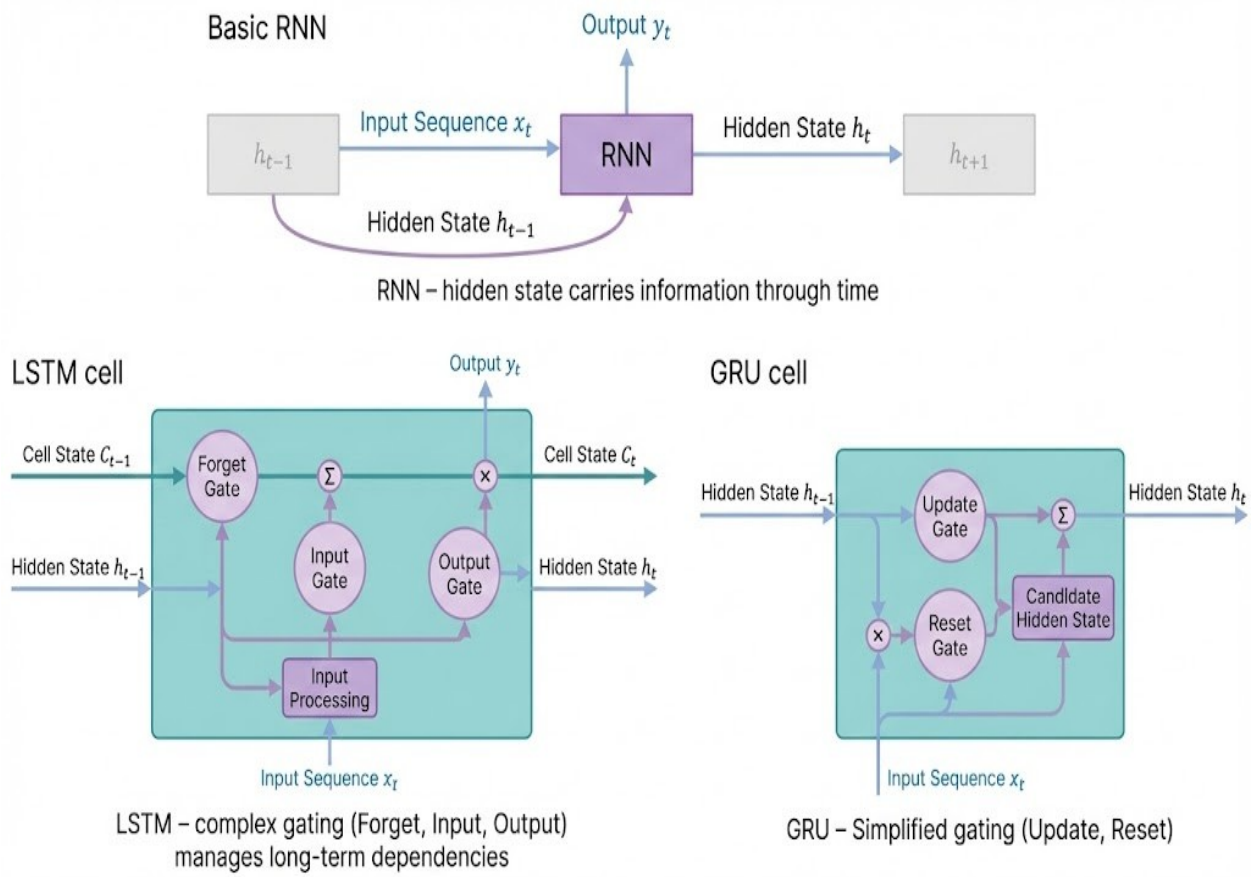

Abbildung 11: *Schematische Darstellung rekurrenter neuronaler Netze (RNNs) und ihrer Varianten. Gezeigt sind ein grundlegendes RNN mit zeitlich fortgeführtem Hidden State sowie die Zellstrukturen von LSTM- und GRU-Modellen mit ihren jeweiligen Gate-Mechanismen zur Stabilisierung des Lernens über lange Sequenzen. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.*

Encoder-Decoder-Architekturen: Diese Modelle sind in zwei Hauptkomponenten unterteilt: Der Encoder komprimiert die Eingabe schrittweise in eine dichte, semantische latente Repräsentation (bottleneck), während der Decoder diese Repräsentation nutzt, um die gewünschte Ausgabe in der ursprünglichen oder einer neuen Domäne zu rekonstruieren. Für Aufgaben der Bildsegmentierung und des Denoising, bei denen eine pixelgenaue Ausgabe erforderlich ist, hat sich das U-Net als Standard etabliert. Es verwendet Skip-Connections, um hochauflösende Merkmale direkt vom Encoder zum entsprechenden Decoder-Level zu übertragen. Dies stellt sicher, dass sowohl der globale Kontext (vom Encoder) als auch die feingranulare Lokalisierung (durch die Skip-Connections) für die Rekonstruktion genutzt werden (Abb. 12)[35].

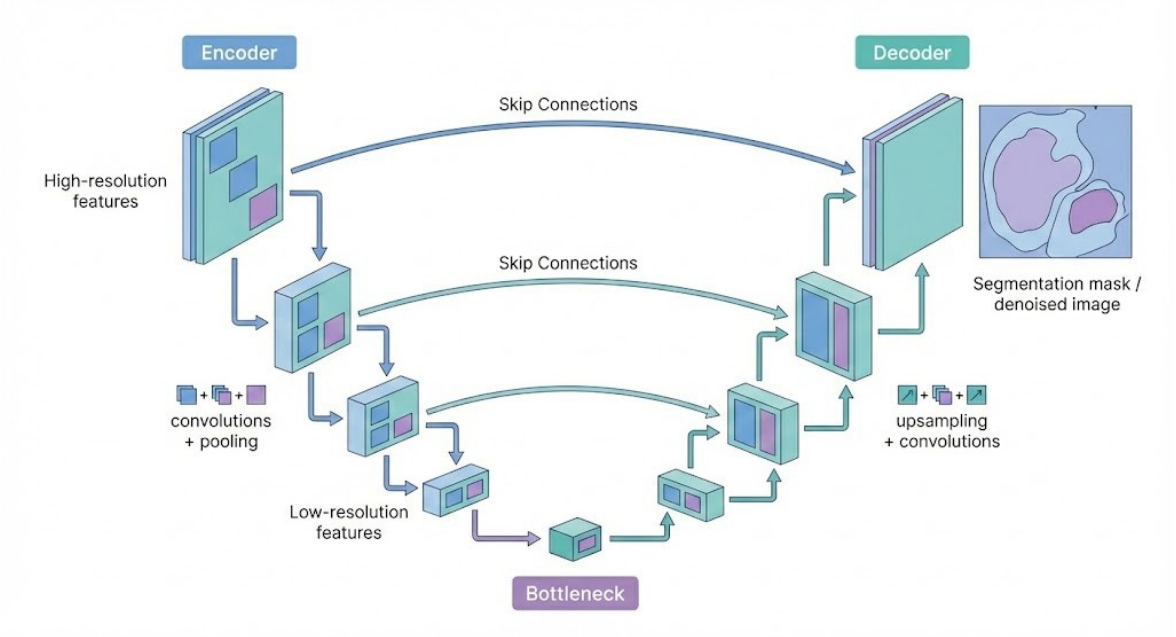

Abbildung 12: *Schematische Darstellung einer Encoder-Decoder-Architektur (U-Net). Der Encoder komprimiert die Eingabebilder schrittweise zu einer latenten Repräsentation, während der Decoder diese zur pixelgenauen Rekonstruktion nutzt. Skip-Connections übertragen hochauflösende Merkmale direkt vom Encoder zu korrespondierenden Decoder-Ebenen und ermöglichen eine präzise Segmentierung bzw. Rauschunterdrückung. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.*

Generative Adversarial Networks (GANs): GANs repräsentieren einen bahnbrechenden Ansatz für generative Modellierung und bestehen aus einem Generator und einem Diskriminator, die in einem adversariellen Spiel gegeneinander trainiert werden. Der Generator versucht, synthetische Daten zu erzeugen, die von echten Daten nicht zu unterscheiden sind (Abb. 13). Der Diskriminator hingegen wird darauf trainiert, zwischen den echten und den vom Generator erzeugten Daten zu unterscheiden. Dieser kompetitive Prozess treibt beide Netzwerke zu immer besseren Leistungen an, was zur Erzeugung hochqualitativer, detailreicher Daten führt 6. Wichtige Varianten wie Conditional GANs ermöglichen die Generierung von Daten basierend auf bestimmten Bedingungen, während Wasserstein GANs eine stabilere Trainingsmetrik verwenden[36,37].

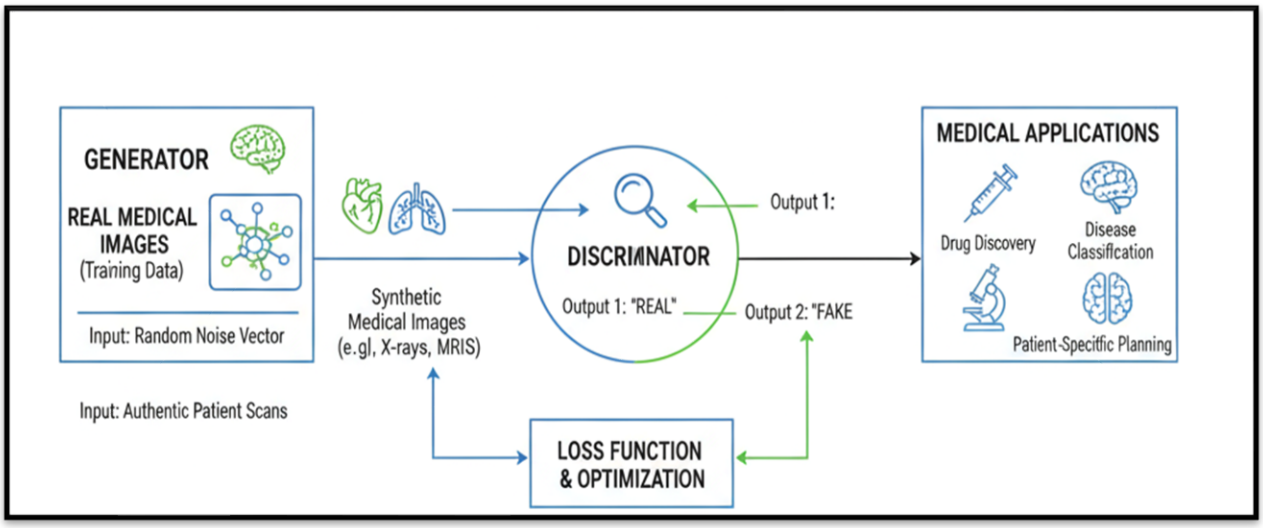

Abbildung 13: Schematische Darstellung eines GAN-Modells für medizinische Bildgebung. Der Generator erzeugt synthetische Bilder, der Diskriminator unterscheidet zwischen „echt“ und „fake“. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.

Transformer-basierte Modelle: Diese Modelle haben die Verarbeitung sequenzieller Daten revolutioniert, indem sie auf rekurrente oder konvolutionale Schichten verzichten und stattdessen vollständig auf den Aufmerksamkeitsmechanismus (Attention) setzen. Insbesondere die Self-Attention-Komponente ermöglicht es dem Modell, die Abhängigkeiten zwischen beliebigen Positionen in der Eingabesequenz direkt zu modellieren, unabhängig von ihrer Entfernung (Abb. 14). Dies ist ein entscheidender Vorteil gegenüber RNNs. Ursprünglich für die Sprachverarbeitung entwickelt, finden sie als Vision Transformers und in multimodalen Architekturen zunehmend Anwendung in der Bildverarbeitung, wo sie globale Abhängigkeiten im Bild effektiv erfassen[38,39].

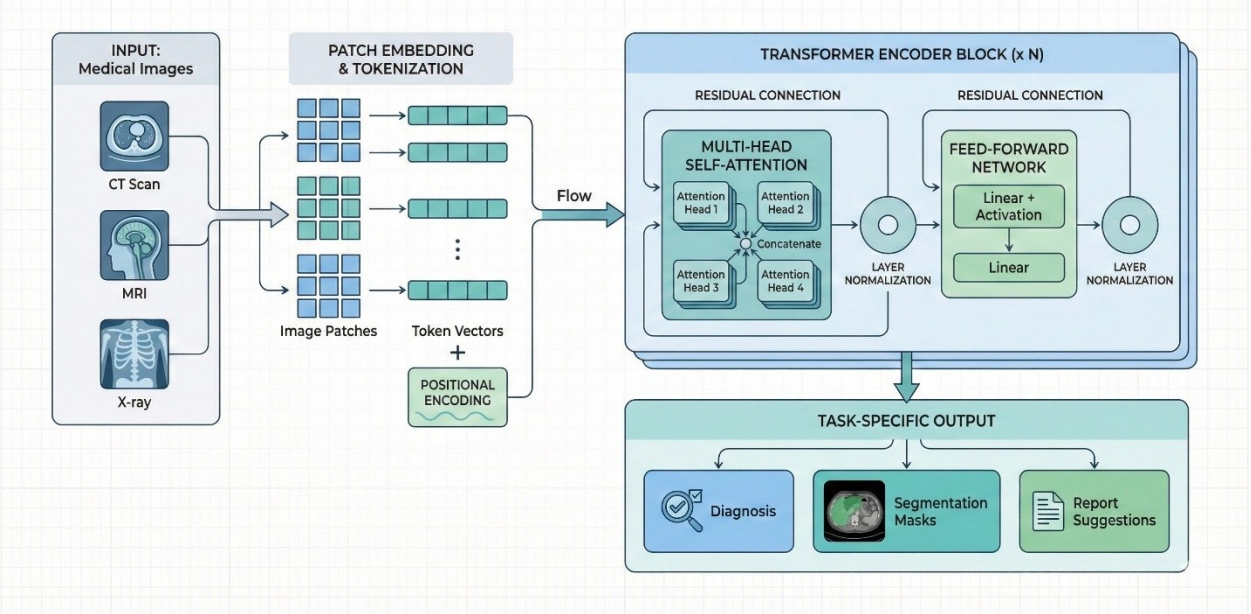

Abbildung 14: *Schematische Darstellung eines Transformermodells für die radiologische Bildanalyse. Medizinische Bilddaten werden in Patches zerlegt und als Token mit Positionskodierung verarbeitet. Über Multi-Head Self-Attention und Encoder-Blöcke entstehen modellierte Bildmerkmale, die in diagnostische Ausgaben wie Klassifikation, Segmentierung oder Befundvorschläge überführt werden. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.*

Autoencoder (AE): AEs sind unüberwachte neuronale Netze, die darauf trainiert werden, ihre Eingabe in der Ausgabe zu rekonstruieren. Sie dienen primär der Dimensionsreduktion und dem Erlernen effizienter Datenkodierungen (latent representations). Der Encoder bildet die Eingabe auf den latenten Raum ab, und der Decoder rekonstruiert sie von dort. Variational Autoencoder führen einen probabilistischen Ansatz ein, indem sie den latenten Raum als eine Verteilung (z.B. Gauß-Verteilung) modellieren, was sie zu leistungsfähigen generativen Modellen macht (Abb. 15). Denoising Autoencoder werden speziell darauf trainiert, verrauschte Eingaben zu rekonstruieren, wodurch sie robuste Merkmale lernen[40,41].

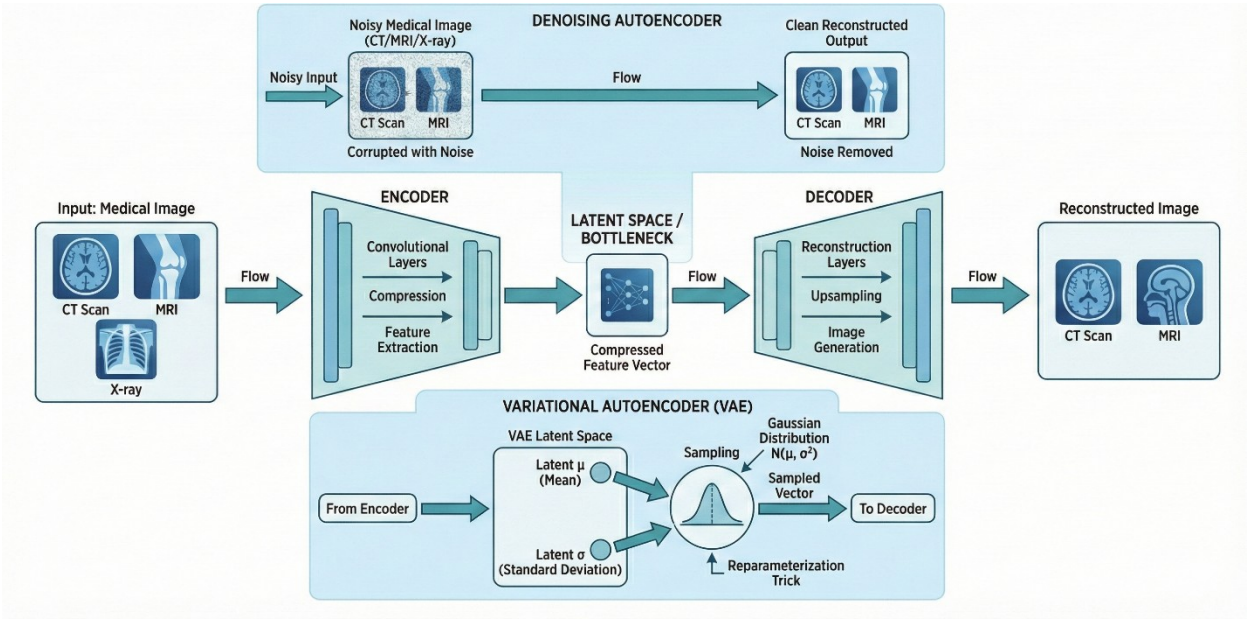

Abbildung 15: Schematische Darstellung verschiedener Autoencoder-Architekturen für die radiologische Bildverarbeitung. Ein klassischer Autoencoder komprimiert Bilddaten über den Encoder in einen latenten Raum und rekonstruiert sie über den Decoder. Der Variational Autoencoder modelliert den latenten Raum probabilistisch über Mittelwert und Standardabweichung. Denoising Autoencoder lernen, verrauschte Eingaben zu säubern und robuste Merkmale zu extrahieren. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.

Deep Reinforcement Learning (DRL): DRL kombiniert Deep-Learning mit Reinforcement Learning, um einen Agenten zu trainieren, optimale Entscheidungen in einer komplexen Umgebung zu treffen, um eine kumulative Belohnung zu maximieren. Das Deep-Learning-Netzwerk dient dabei als Funktionsapproximator für die Wertfunktion oder die Policy des Agenten. Prominente Algorithmen sind Deep Q-Networks, die die Q-Funktion approximieren, Proximal Policy Optimization, ein Policy-Gradient-Verfahren, das für seine Stabilität bekannt ist, und Asynchronous Advantage Actor-Critic, das paralleles Training nutzt (Abb. 16)[42,43].

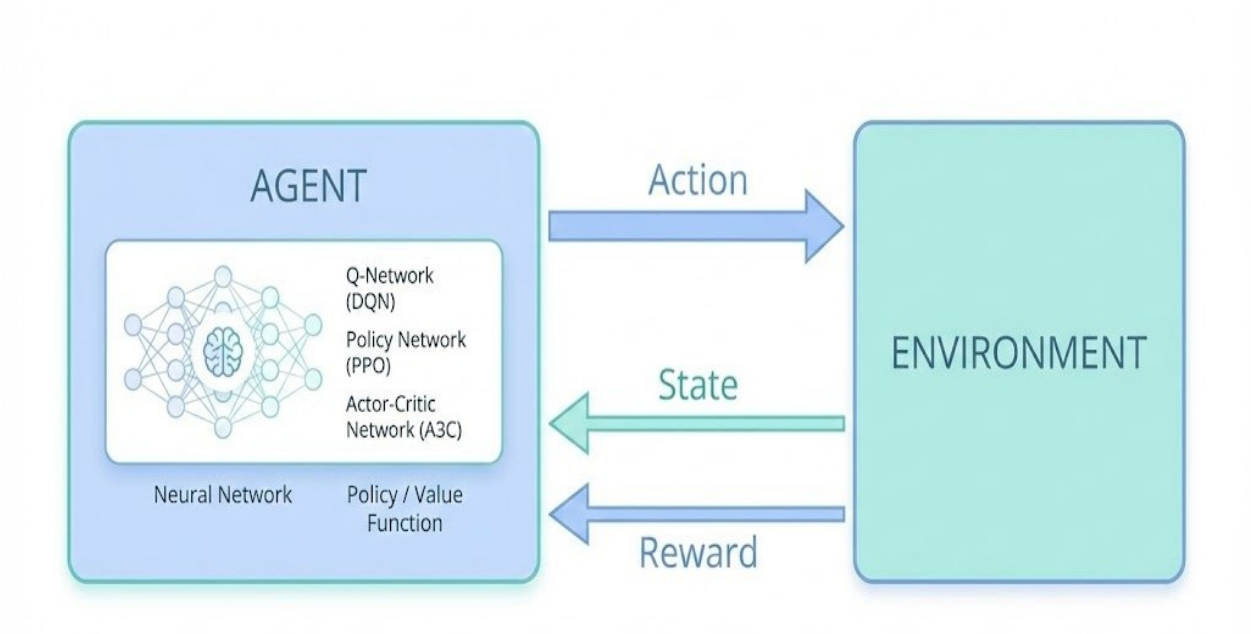

Abbildung 16: *Schematische Darstellung des DRL. Ein Agent interagiert mit seiner Umgebung durch Aktionen und erhält Zustandsinformationen sowie Belohnungen. Neuronale Netze dienen als Approximatoren für Policy- und Wertfunktionen, wie bei DQN, PPO und A3C. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.*

Graph Neural Networks (GNNs): GNNs sind eine Klasse von Architekturen, die speziell für die Verarbeitung von Graphen-strukturierten Daten entwickelt wurden, bei denen die Beziehungen zwischen den Datenpunkten (Knoten) ebenso wichtig sind wie die Merkmale der Knoten selbst (z.B. soziale Netzwerke, Molekülstrukturen). Sie arbeiten, indem sie Informationen von den Nachbarknoten aggregieren und so eine Repräsentation für jeden Knoten lernen. Dazu gehören Graph Convolutional Networks, die eine Form der Faltung auf Graphen anwenden, und Graph Attention Networks, die den Aufmerksamkeitsmechanismus nutzen, um die Wichtigkeit verschiedener Nachbarn zu gewichten (Abb. 17)[44].

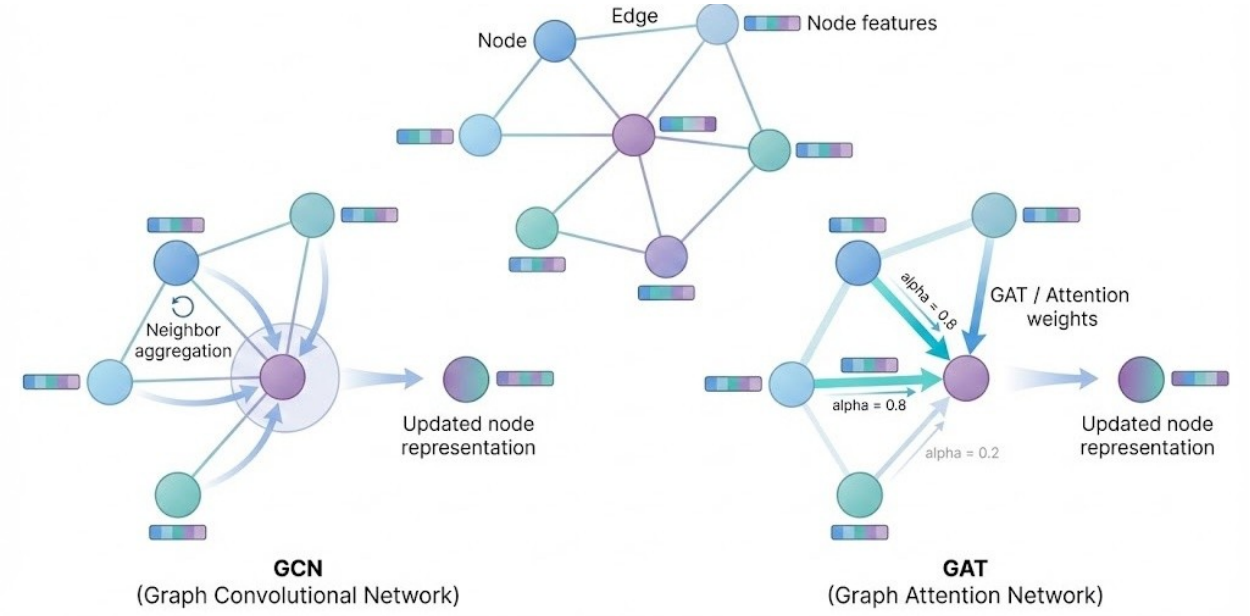

Abbildung 17: *Schematische Darstellung eines GNN. Knoten aggregieren Informationen ihrer Nachbarn zur Aktualisierung ihrer Repräsentationen. Gezeigt sind ein Graph Convolutional Network (GCN) mit Faltungsoperation sowie ein Graph Attention Network (GAT), das Nachbarn über gewichtete Aufmerksamkeiten einbezieht. Grafische Darstellung erstellt mit Gemini-Pro, eigene Illustration.*

Weitere Architekturen: Die historische Entwicklung des Deep-Learning umfasst auch Architekturen wie Deep Belief Networks, die aus gestapelten Restricted Boltzmann Machines bestehen und oft im unüberwachten Pre-Training verwendet wurden, sowie Deep Stacking Networks. Diese frühen Modelle legten den Grundstein für die heutigen komplexeren Architekturen[45].

Diese Vielfalt an Methoden ermöglicht es der Forschung, für nahezu jede Art von Daten und Problemstellung eine spezialisierte und leistungsfähige Deep-Learning-Lösung zu entwickeln. Die Wahl der geeigneten Architektur hängt stark von der Struktur der Eingabedaten (sequenziell, gitterartig, graphisch) und der Art der Aufgabe (Klassifikation, Generierung, Denoising) ab[46].

1.6 Anwendungen von KI-Denoising in verschiedenen medizinischen Bildgebungsmodalitäten

KI-basierte Denoising-Algorithmen haben in den letzten Jahren in verschiedenen medizinischen Bildgebungsmodalitäten vielversprechende Ergebnisse gezeigt. Sie können Rauschen reduzieren und gleichzeitig diagnostisch relevante Details weitgehend erhalten, was zu einer verbesserten Bildqualität und potenziell einer höheren diagnostischen Genauigkeit beitragen kann.

CT: In der konventionellen CT ist die Dosisreduktion ein zentrales Thema. KI-Denoising-Algorithmen ermöglichen die Aufnahme von Niedrigdosis-CT-Bildern und deren anschließende Rauschunterdrückung, sodass ihre Bildqualität der von Standarddosis-CT-Bildern entspricht oder sie in bestimmten Fällen sogar übertrifft. [47]. Dies ist besonders wichtig für Patienten, die wiederholten CT-Untersuchungen unterzogen werden müssen, wie z.B. Krebspatienten. KI-Denoising wird erfolgreich eingesetzt, um Quantenrauschen, Streifenartefakte und andere Bildfehler zu minimieren, was zu klareren und diagnostisch verwertbareren Bildern führt[48].

Magnetresonanztomographie (MRT): MRT-Bilder sind anfällig für thermisches Rauschen (zufällige Signalfluktuationen durch die Wärmebewegung von Elektronen in Leitern) und physiologisches Rauschen (z.B. durch Patientenbewegung oder Blutfluss). KI-Denoising kann das Signal-Rausch-Verhältnis (SNR) von MRT-Bildern verbessern, was eine klarere Visualisierung kleiner Läsionen ermöglicht und die Genauigkeit quantitativer Messungen erhöht. Dies ist besonders nützlich bei der Bildgebung von Gehirn, Rückenmark und muskuloskelettalen Strukturen, wo ein hoher Weichteilkontrast entscheidend ist[49].

Ultraschall: Ultraschallbilder sind typischerweise von Speckle-Rauschen betroffen, das durch die Interferenz von gestreuten Ultraschallwellen entsteht und die Erkennbarkeit feiner Details erschwert. KI-Denoising-Techniken können das Speckle-Rauschen effektiv

reduzieren und die Bildklarheit verbessern, was die Visualisierung von fetalen Anomalien und abdominalen Pathologien erleichtert. Die Echtzeitfähigkeit von Ultraschall in Kombination mit schnellen KI-Denoising-Algorithmen eröffnet neue Möglichkeiten für die intraoperative Bildführung[50].

Positronen-Emissions-Tomographie (PET): PET-Bilder liefern funktionelle Informationen über den Stoffwechsel, sind aber oft durch Quantenrauschen und Streustrahlung beeinträchtigt. KI-Denoising kann die Bildqualität von PET-Scans verbessern, was zu einer genaueren Quantifizierung der Tracer-Aufnahme und einer besseren Erkennung von Tumoren oder entzündlichen Prozessen führt (Abb.18)[51].

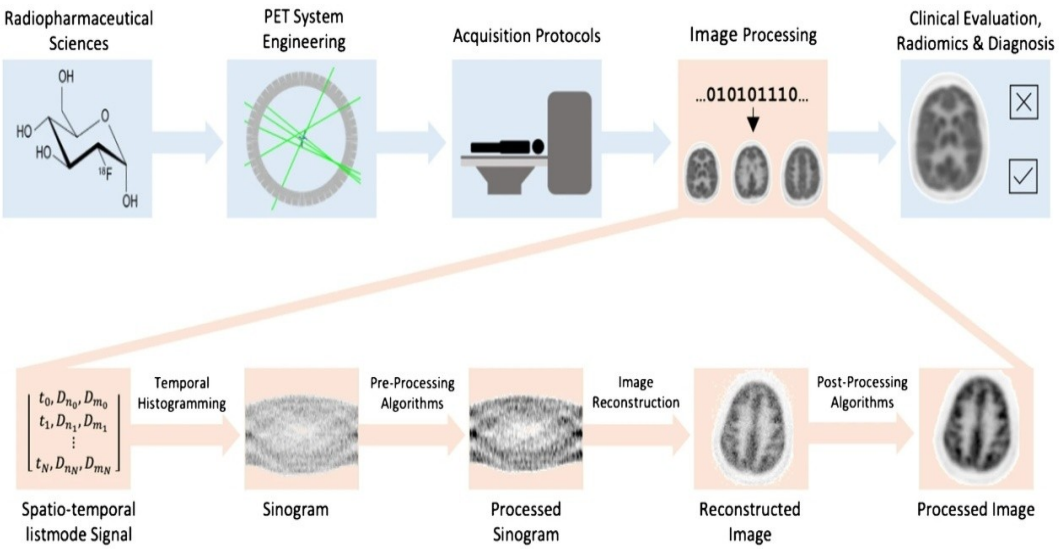

Abbildung 18: KI-Bildverarbeitung im Gesamtkontext der PET. Fortschritte in verschiedenen Teilbereichen tragen ganzheitlich zur Weiterentwicklung und Qualitätsverbesserung der PET als bildgebende Modalität bei. modifiziert nach Pain et al. (CCBY)[52].

1.7 Spezifische Anwendungen von KI in der interventionellen Radiologie

KI-Anwendungen im Bereich der interventionellen Radiologie umfassen nicht nur die Bildqualitätsverbesserung, sondern auch die Automatisierung von Arbeitsabläufen, die Segmentierung von Organen und Läsionen, die Navigation von Instrumenten und die Vorhersage von Behandlungsergebnissen[53].

Auf dem Gebiet der Bildqualitätsverbesserung ermöglicht KI-Denoising in der interventionellen Radiologie die Durchführung von Verfahren mit geringerer Strahlenexposition, ohne die diagnostische Qualität zu beeinträchtigen. Dies ist besonders wichtig bei komplexen und langwierigen Eingriffen, bei denen sowohl Patienten als auch medizinisches Personal einer erheblichen Strahlenexposition ausgesetzt sein können. Durch die Reduktion von Rauschen und Artefakten können interventionelle Radiologen kleinere Strukturen besser erkennen, was die Genauigkeit bei der Platzierung von Kathetern, Drähten und anderen Geräten verbessert. [54].

Ein weiteres wichtiges Anwendungsgebiet ist die Automatisierung der Bildanalyse. KI-Algorithmen können dazu trainiert werden, anatomische Landmarken, Läsionen oder vaskuläre Strukturen automatisch zu erkennen und zu segmentieren. Dies beschleunigt die präoperative Planung und ermöglicht eine genauere intraoperative Führung. Beispielsweise können KI-Modelle die Pfortader und die Lebervenen in CBCT-Bildern automatisch segmentieren, was die Planung des angiographischen Verfahrens erheblich vereinfacht[55,56].

KI kann auch die Instrumentennavigation erheblich verbessern. Durch den Einsatz von KI in Navigationssystemen erhalten interventionelle Radiologen in Echtzeit Unterstützung, die eine sichere und präzise Platzierung von Instrumenten in komplexen anatomischen Bereichen ermöglicht. Das kann Prozedurzeiten verkürzen und Komplikationen reduzieren[57,58].

Schließlich kann KI auch zur Prädiktion von Behandlungsergebnissen und zur Personalisierung der Therapie eingesetzt werden. Durch die Analyse großer Mengen von Patientendaten, einschließlich Bilddaten, klinischer Parameter und genetischer Informationen, können KI-Modelle Muster identifizieren, die mit dem Ansprechen auf die Therapie oder dem Auftreten von Komplikationen korrelieren. Dies ermöglicht eine individuellere Behandlungsplanung, und eine bessere Patientenauswahl für bestimmte interventionelle Verfahren[59,60].

1.8 Zielsetzung und Fragestellung

Die CBCT wird zunehmend in der interventionellen Radiologie eingesetzt, da sie eine hochauflösende, dreidimensionale Bildgebung direkt periinterventionell ermöglicht. Insbesondere bei komplexen Interventionen erlaubt sie eine präzise Navigation und anatomische Orientierung. Gleichzeitig ist die CBCT jedoch mit spezifischen Limitationen wie erhöhter Rauschanfälligkeit, Artefakten und Dosisrestriktionen konfrontiert. Eine Reduktion der Strahlendosis, wie sie im klinischen Alltag zunehmend angestrebt wird, führt häufig zu einer signifikanten Verschlechterung der Bildqualität. Diese Einschränkungen können zu längeren Prozedurzeiten, Unsicherheiten in der Durchführung und potenziell schlechteren klinischen Ergebnissen führen[54].

In den letzten Jahren kommen zunehmend KI-basierte Methoden, vor allem Deep-Learning-Denoising-Algorithmen, zum Einsatz, um die Bildqualität bei niedrigerer Strahlenbelastung zu verbessern. Sie reduzieren Rauschen effektiv, während wichtige anatomische Details erhalten bleiben. In der klinischen Anwendung der CBCT-Bildgebung steht ihre Validierung allerdings noch am Anfang[53].

Ziel dieser Arbeit ist es, zu untersuchen, ob ein Deep-Learning-Denoising-Algorithmus die Bildqualität von CBCT-Aufnahmen in der klinischen Bildgebung auch bei unterschiedlichen Dosisniveaus verbessern kann.

Dazu werden quantifizierbare Bildparameter wie Hounsfield-Einheiten (HU), CNR vor und nach der Anwendung des KI-Denoising-Algorithmus verglichen und statistisch ausgewertet[61].

2 Material und Methoden

2.1 Studiendesign und Patientenpopulation

Die vorliegende retrospektive monozentrische Studie umfasste Patienten, die sich zwischen dem 1. Januar 2018 und dem 1. Januar 2022 einer interventionell-radiologischen TIPSS-Prozedur (Transjugulärer Intrahepatischer Portosystemischer Shunt) mit begleitender CBCT-Bildgebung unterzogen. Die Studie wurde von der lokalen Ethikkommission genehmigt (#167/2022BO2), die auf die Notwendigkeit einer informierten Einwilligung verzichtete[61].

Zur Fallauswahl wurden insgesamt 8622 CBCT-Untersuchungen aus dem PACS-System gesichtet. Nach Ausschluss von 8554 Untersuchungen, die nicht im Zusammenhang mit TIPSS-Prozeduren standen, verblieben 68 CBCTs, die im Rahmen einer TIPSS-Intervention angefertigt worden waren[61].

Diese 68 Fälle wurden anhand der verwendeten Akquisitionszeit in zwei Gruppen unterteilt: 22 Patienten mit einer 3-Sekunden-Akquisition und 48 Patienten mit einer 6-Sekunden-Akquisition. Um eine vergleichbare Analyse unter Kontrolle relevanter Kovariablen zu ermöglichen, wurde aus der Gruppe der 6-Sekunden-Akquisitionen eine BMI-gematchte Vergleichsgruppe zusammengestellt. Hierzu wurden 24 Patienten ausgeschlossen, für die sich kein passender Match hinsichtlich des Body-Mass-Index (BMI, kg/m²) finden ließ. Die finale Studienkohorte bestand somit aus: 22 Patienten mit 3-Sekunden-CBCT, 22 BMI-gematchten Patienten mit 6-Sekunden-CBCT (Abb. 19)[61].

Für jeden eingeschlossenen Patienten wurden folgende Parameter dokumentiert: Demografische Daten (Alter, Geschlecht), Body-Mass-Index (BMI, kg/m²), Strahlendosisdaten aus dem DICOM-Datensatz (Dosis-Flächen-Produkt, mGy·cm²), CBCT-Rohdaten vor und nach Deep-Learning-Denoising. Die weitere Auswertung umfasste sowohl objektive Messparameter (z. B. Hounsfield-Einheiten, Bildrauschen,

Kontrast-Rausch-Verhältnis) als auch subjektive Bewertungen hinsichtlich diagnostischer Nutzbarkeit und Detailerkennbarkeit[61].

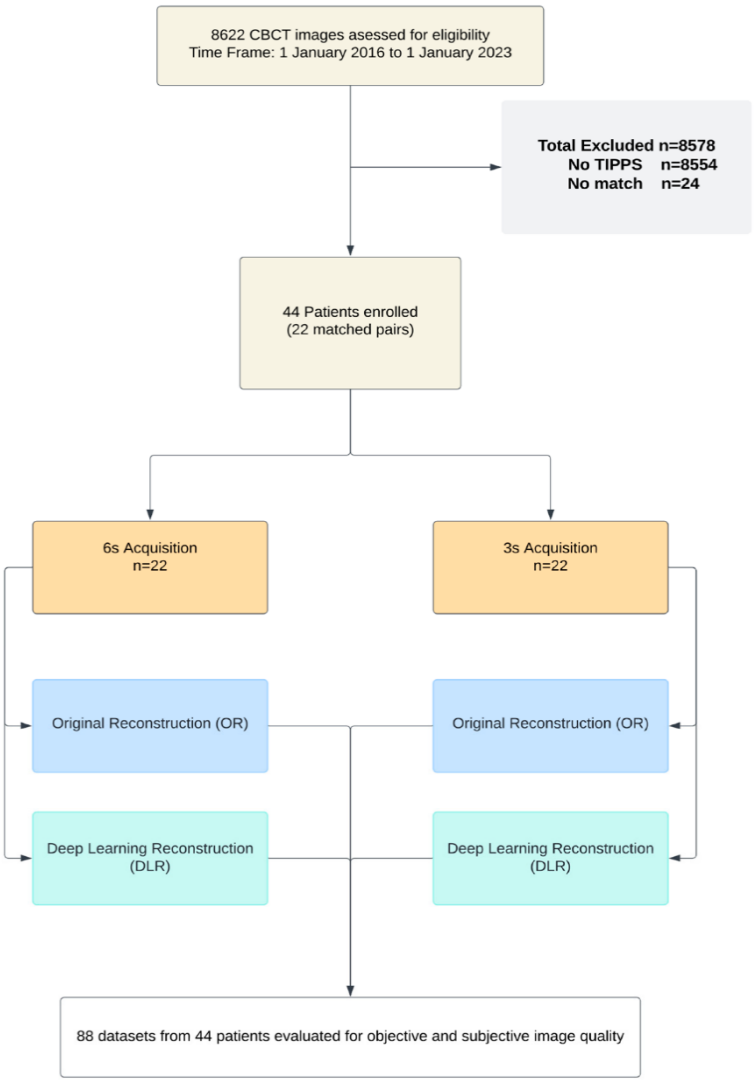

Abbildung 19: Schematische Darstellung des Studien-Workflows. modifiziert nach dehdab et al. (CCBY 4.0)[61]

2.2 Bildakquisition und Rekonstruktion

Alle TIPSS-Verfahren wurden von einem erfahrenen interventionellen Radiologen mit über sechs Jahren Erfahrung im Bereich der interventionellen Radiologie durchgeführt. Jeder Eingriff erfolgte unter Vollnarkose nach einer vorbereitenden Parazentese. Über eine 10 French Schleuse wurde der Zugang zur rechten Lebervene über die rechte Vena jugularis hergestellt. Anschließend wurde die Kartierung der Pfortaderäste mittels CBCT in Arme-unten-Position erleichtert. Die Pfortaderpunktion erfolgte unter 3D-Führung, und ein erfolgreiches Eindringen wurde durch Aspiration von Blut durch die TIPSS-Nadel bestätigt, gefolgt von der Verabreichung von Kontrastmitteln. Ein Standard-TIPSS-Stentgraft (Viatorr, W.L. Gore, Flagstaff, AZ, USA) wurde verwendet, um den TIPSS-Trakt zu sichern, wobei das Kriterium für den technischen Erfolg die erfolgreiche Kontrastmittelabgabe in die Pfortader über einen 4F-Diagnosekatheter war, mit dem Ziel, den portosystemischen Gradienten auf 10 mmHg oder darunter zu reduzieren [61].

Die Bilder wurden mit einer multiaxialen robotischen angiographischen C-Bogen-Suite (Artis Zeego Q, VE40 A, Siemens Healthineers, Forchheim, Deutschland) akquiriert. Ein standardisiertes Kontrastmittelinjektionsprotokoll wurde bei allen Verfahren eingehalten, erleichtert durch einen peripheren Venenzugang mittels einer 18G-Nadel. Das Injektionsprotokoll umfasste die venöse Verabreichung eines verdünnten Kontrastmittels (75 ml Ultravist mit 370 mg/ml; Bayer Vital GmbH, Berlin, Deutschland), gefolgt von einer Kochsalzlösung, die mit einer Flussrate von 4,5 ml/Sekunde durch einen automatisierten Power-Injektor verabreicht wurde. Die Initiierung des C-Bogen-CT-Systems erfolgte automatisiert und wurde 60 Sekunden nach der Injektion ausgelöst [61].

Die Entscheidung zwischen einer Rotationszeit von drei oder sechs Sekunden für das CBCT-System wurde vom operierenden Radiologen getroffen, um die Pfortader präzise anzupeilen. Dieser Ansatz ermöglichte die Akquisition von entweder 397 Projektionsbildern über sechs Sekunden oder 167 Projektionsbildern über drei Sekunden, wobei eine Detektoreingangsdosis von 0,36 µGy/Frame eingehalten und Bilder mit 60 Bildern pro Sekunde aufgenommen

wurden. Die Bildakquisition erfolgte über eine 200° zirkuläre Trajektorie, wobei die CBCT-Bilder mittels Atemanhaltetechnik verarbeitet wurden. Die Bilddaten wurden anschließend an eine kommerziell erhältliche Offline-Workstation (syngo XWP, Siemens Healthcare, Singapur) übertragen. CT-ähnliche axiale Bilder mit einer Schichtdicke von 1 mm und einem Inkrement von 1 mm wurden mittels einer gewichteten gefilterten Rückprojektionstechnik, ergänzt durch einen Medianfilter, rekonstruiert [61].

2.3 KI-Denoising-Algorithmus

Die Nachbearbeitung der rekonstruierten Bilder erfolgte unter Verwendung des KI Denoising-Algorithmus. Dieser Algorithmus basiert auf einem modifizierten U-Net-Typ CNN (ClariCT.AI Ver 1.2.1, ClariPi Inc., Seoul, Republik Korea)[62]. Das U-Net ist eine spezielle Architektur von CNNs, die sich durch ihre symmetrische Encoder-Decoder Struktur und die Verwendung von Skip-Connections auszeichnet. Diese Architektur ermöglicht es dem Netzwerk, sowohl hochauflösende Merkmale aus den frühen Schichten (die Details bewahren) als auch kontextuelle Informationen aus den tieferen Schichten (die das Rauschen besser identifizieren) zu kombinieren (Abb. 20). Dies ist entscheidend für Denoising-Aufgaben, da es die effektive Entfernung von Rauschen bei gleichzeitiger Erhaltung feiner anatomischer Details ermöglicht [63]. ClariCT.AI wurde speziell für die Rauschunterdrückung in medizinischen CT-Bildern entwickelt und hat sich in verschiedenen klinischen Anwendungen als wirksam erwiesen, die Bildqualität zu verbessern und die Dosis zu reduzieren [64].

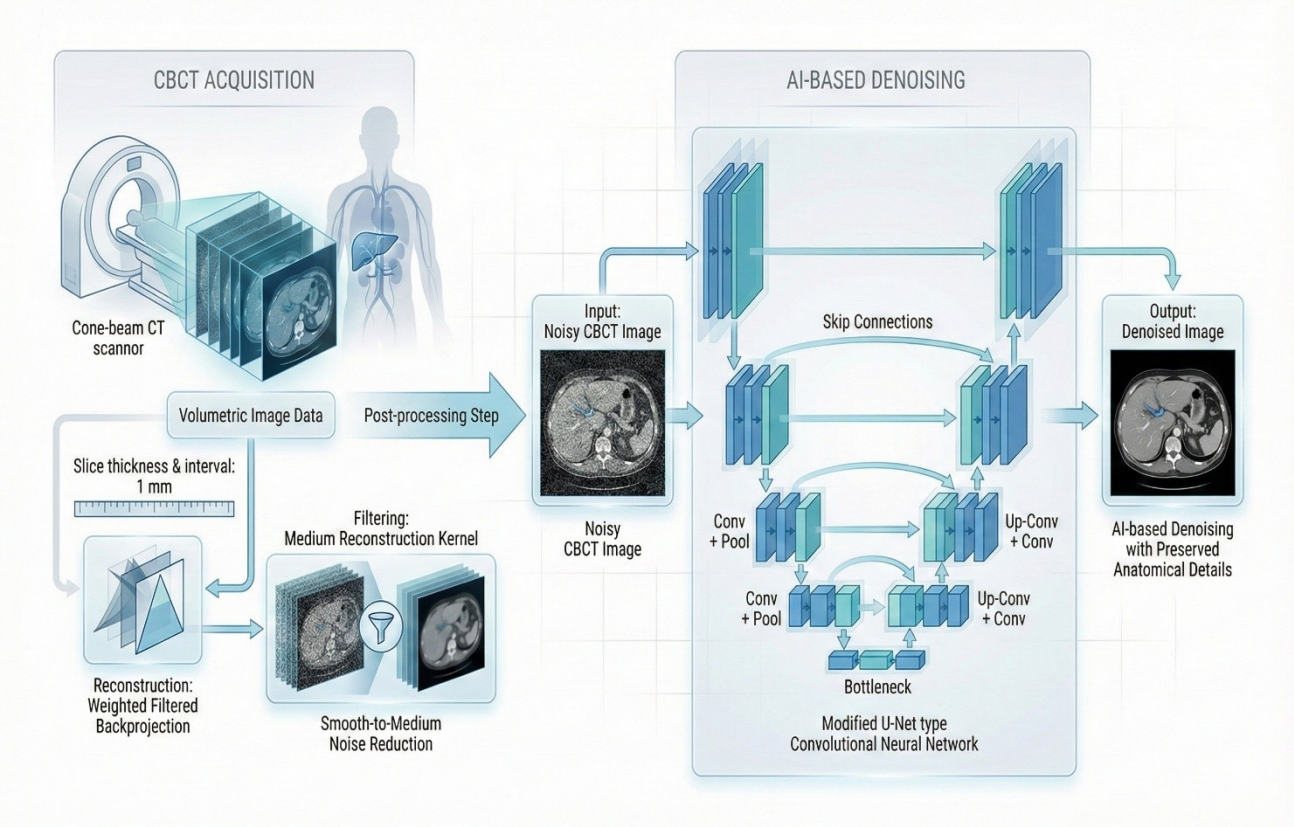

Abbildung 20: Verarbeitungsworkflow der CBCT-Bilddaten im Rahmen der Studie. Nach der Akquisition der volumetrischen CBCT-Daten erfolgte die Rekonstruktion mit einer Schichtdicke und einem Schichtabstand von jeweils 1 mm mittels gewichteter gefilterter Rückprojektion unter Anwendung eines mittleren Rekonstruktionsfilters. Anschließend wurde eine KI-gestützte Nachbearbeitung mit einem modifizierten U-Net-Architekturtyp (CNN) durchgeführt. Grafische Darstellung erstellt mit Gemini pro, eigene Illustration.

2.4 Objektive Bildqualitätsanalyse

Für die objektive Analyse der Bildqualität wurden alle entsprechenden Serien pro Patient (regulär: Maske & Füllung; Denoising: Maske & Füllung) in die Open-Source-ImageJ-Distribution FIJI (Version 1.53k, Wayne Rasband, National Institutes of Health, Bethesda, MD, USA)65 geladen. Aus den unbearbeiteten Füllserien wurden insgesamt 30 Regionen von Interesse (ROI) mit einem Durchmesser von $\geq 1\,cm^2$ in homogenen Bereichen des Leberparenchyms außerhalb von Gefäßen, Gallengängen und malignen Läsionen definiert. Das Programm übertrug diese ROIs automatisch in jede Serie pro Patient und ermittelte konsistente Messwerte der mittleren CT-Werte in Hounsfield-Einheiten (HU) sowie deren Standardabweichung (SD). Die SD der HU diente als Maß für das Bildrauschen. Für jede ROI wurde zudem das Signal-Rausch-Verhältnis (SNR, HU/SD) als umfassendes Maß für die objektive Bildqualität berechnet[61].

Zusätzlich zum SNR wurde das Kontrast-Rausch-Verhältnis (CNR) berechnet, um die Fähigkeit zur Unterscheidung zwischen verschiedenen Geweben zu quantifizieren. Das CNR ist definiert als die Differenz der mittleren HU-Werte zwischen zwei Regionen von Interesse, dividiert durch die Standardabweichung des Rauschens in einer dieser Regionen. Ein höheres CNR weist auf eine bessere Unterscheidbarkeit von Strukturen hin[61,66].

2.5 *Subjektive Bildqualitätsanalyse*

Für die subjektive Bildqualitätsbewertung wurden die Patientendatensätze anonymisiert und von einem Gruppenmitglied randomisiert, das nicht an der Analyse der diagnostischen Konfidenz beteiligt war. Zwei Radiologen mit fünf und zehn Jahren Erfahrung in der interventionellen Radiologie und CBCT bewerteten unabhängig voneinander alle Kombinationen der Datensätze. Jedes Paar bestand aus vier Akquisitionen (zwei von 3-Sekunden-Akquisitionen und zwei von 6-Sekunden-Akquisitionen), die jeweils mit der Original- und der KI-Methode (AID) verarbeitet wurden. Unter Verwendung von ViewDex (Ver. 3.0), einer Software, die für verblindete und randomisierte Bewertungen entwickelt wurde, führten die Radiologen ihre Bewertungen anhand von vier subjektiven Kriterien durch: allgemeine subjektive Bildqualität, Schärfe, Kontrast und Ausmaß der Bewegungsartefakte. Jedes Bild wurde im Vergleich zu seinem Paar als überlegen (+1), gleichwertig (0) oder unterlegen (−1) bewertet (Abb. 21). Dieser Bewertungsrahmen, der die allgemeine subjektive Qualität, das Ausmaß der Bewegungsartefakte, die Schärfe und den Kontrast betont, wurde strategisch aufgrund seiner Relevanz für die Identifizierung der Pfortader während des TIPSS-Verfahrens ausgewählt[61].

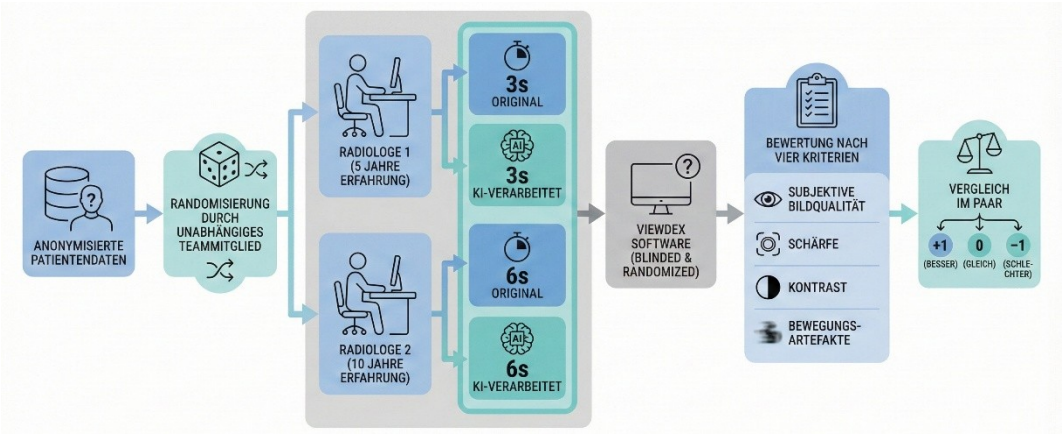

Abbildung 21: Schematischer Workflow der subjektiven Bildqualitätsbewertung. Zwei Radiologen bewerteten anonymisierte, randomisierte Datensätze (Original vs. KI) hinsichtlich Bildqualität, Schärfe, Kontrast und Bewegungsartefakten. Grafische Darstellung erstellt mit Midjourney, eigene Illustration.

2.6 Statistische Analyse

Statistische Auswertungen und visuelle Darstellungen wurden mit GraphPad Prism Version 9.3 für Windows (GraphPad Software, San Diego, CA, USA) durchgeführt. Die Datenverteilung wurde mittels Shapiro-Wilk-Test getestet. Normal verteilte Variablenwurden als Mittelwert ± Standardabweichung und nicht normal verteilte Variablen als Median und Interquartilbereich (IQR) ausgedrückt. Die Datenanalyse erfolgte mittels eines Mixed-Effects-Modells mit Greenhouse-Geisser-Korrektur bei Verletzung der Sphärizität. Post-hoc-Tests wurden für BMI-Untergruppen durchgeführt. Eine zweistufige Step-up-Korrektur nach Benjamini, Krieger und Yekutieli wurde verwendet, um die Zunahme des Typ-1-Fehlers bei multiplen Vergleichen zu kompensieren. Ein angepasster p-Wert ≤ 0,05 wurde als statistisch signifikant angesehen. Eine multiple lineare Regression wurde verwendet, um den Effekt der Variablen „BMI“ (Normalgewicht/Präadipositas/Adipositas, Referenzkategorie: Normalgewicht), „Strahlenexposition“ (Dosis-Flächen-Produkt in mGy*cm²) und „Modus“ (Original/ AID, Referenzkategorie: Original) auf das Signal-RauschVerhältnis zu untersuchen. Die Nützlichkeit und Güte des Modells wurden mittels Varianzanalyse (ANOVA), angepasstem R^2 und der Standardabweichung der Residuen (Sy.x) gemessen. R^2-Werte von <0,13 wurden als Indikator für schlecht, 0,13–0,26 für moderat und ≥0,26 für gut befunden. Der Spearman-Korrelationskoeffizient (r) wurde berechnet, um die Inter-Rater-Übereinstimmung für die diagnostischen Konfidenzbewertungen zu messen. r-Werte von 0–0,5 wurden als Indikator für schlecht, 0,51–0,74 für moderat, 0,75–0,9 für gut und 0,91–1,00 für exzellente Übereinstimmung definiert[61].

3 Ergebnisse

3.1 Patientencharakteristika und Dosis-FlächenProdukt (DAP)

Die Studie umfasste 44 CBCT-Serien von 22 gematchten Patienten, die sich in unserer Einrichtung einem TIPSS-Verfahren unterzogen hatten. Die Patienten wiesen eine mittlere Körpergröße von 166,59 ± 16,16 cm, ein mittleres Gewicht von 67,20 ± 17,92 kg und einen mittleren BMI von 23,80 ± 4,91 kg/m² auf. Das mittlere Dosis-Flächen-Produkt (DAP) für die 6-Sekunden-Akquisitionen betrug 5138,50 ± 1325,57 µGy·m², was signifikant höher war als das DAP von 2514,06 ± 691,59 µGy·m² für die 3-Sekunden-Serien ($p < 0,05$)[61]. Tabelle 1 zeigt die Daten zur Bildakquisition sowie die Charakteristika der Studienpopulation.

Tab.1. Charakteristika der Patienten, modifiziert nach Dehdab et al[61].

Sex	Dataset	*n*	Age	Height	Weight	DAP	BMI
Female	3 s	9	40.89 ± 19.93	160.44 ± 8.13	62.44 ± 12.10	2368.11 ± 501.41	24.23 ± 3.88
	6 s	11	53.91 ± 16.78	165.82 ± 4.56	59.55 ± 7.61	4678.56 ± 644.74	21.67 ± 2.86
	Overall	20	48.05 ± 18.97	163.40 ± 6.80	60.85 ± 9.71	3638.86 ± 1309.73	22.82 ± 3.51
Male	3 s	13	54.23 ± 22.97	172.39 ± 18.72	70.80 ± 19.97	2615.11 ± 801.48	23.09 ± 4.36
	6 s	11	51.27 ± 20.45	165.55 ± 23.42	74.51 ± 23.81	5598.44 ± 1675.99	26.42 ± 6.87
	Overall	24	52.88 ± 21.43	169.25 ± 20.82	72.50 ± 21.41	3982.47 ± 1965.22	24.62 ± 5.77
Overall	3 s	22	48.77 ± 22.32	167.50 ± 16.17	67.38 ± 17.36	2514.06 ± 691.59	23.56 ± 4.12
	6 s	22	52.59 ± 18.31	165.68 ± 16.47	67.03 ± 18.87	5138.50 ± 1325.57	24.05 ± 5.68
	Overall	44	50.68 ± 20.26	166.59 ± 16.16	67.20 ± 17.92	3826.28 ± 1689.29	23.80 ± 4.91

3.2 Objektive Bildqualitätsmetriken (SNR, CNR, Rauschen)

In der objektiven Bildqualitätsanalyse zeigten sich signifikante Interaktionen zwischen der Strahlendosis und der Akquisitionszeit (W = −253; p < 0,0001; Median-Differenz = −38,073 µGy·m²; rs = 0,5562; p (one-tailed) = 0,0036 (Abb. 22))[61].

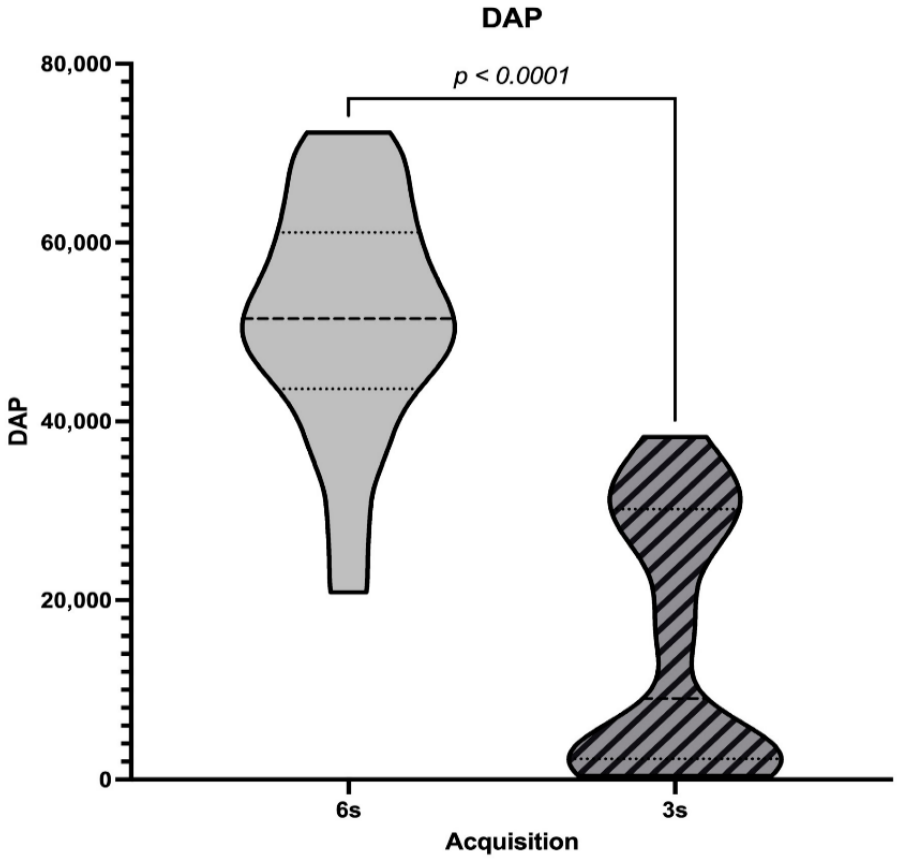

Abbildung 22: Korrelation der CBCT-Akquisitionsdauer mit dem DAP. modifiziert nach dehdab et al. (CCBY 4.0)[61]

Im Rahmen der objektiven Bildqualitätsbewertung zeigten die Analysen mit gemischten Modellen signifikante Interaktionen. Die korrigierten Post-hoc-Vergleiche für den Kontrast zeigten jedoch weder bei der 6-Sekunden- ($p = 0{,}9554$) noch bei der 3-Sekunden-Akquisition($p = 0{,}9998$) (Abb. 23)[61] signifikante Unterschiede zwischen den Original- und den rauschreduzierten Serien

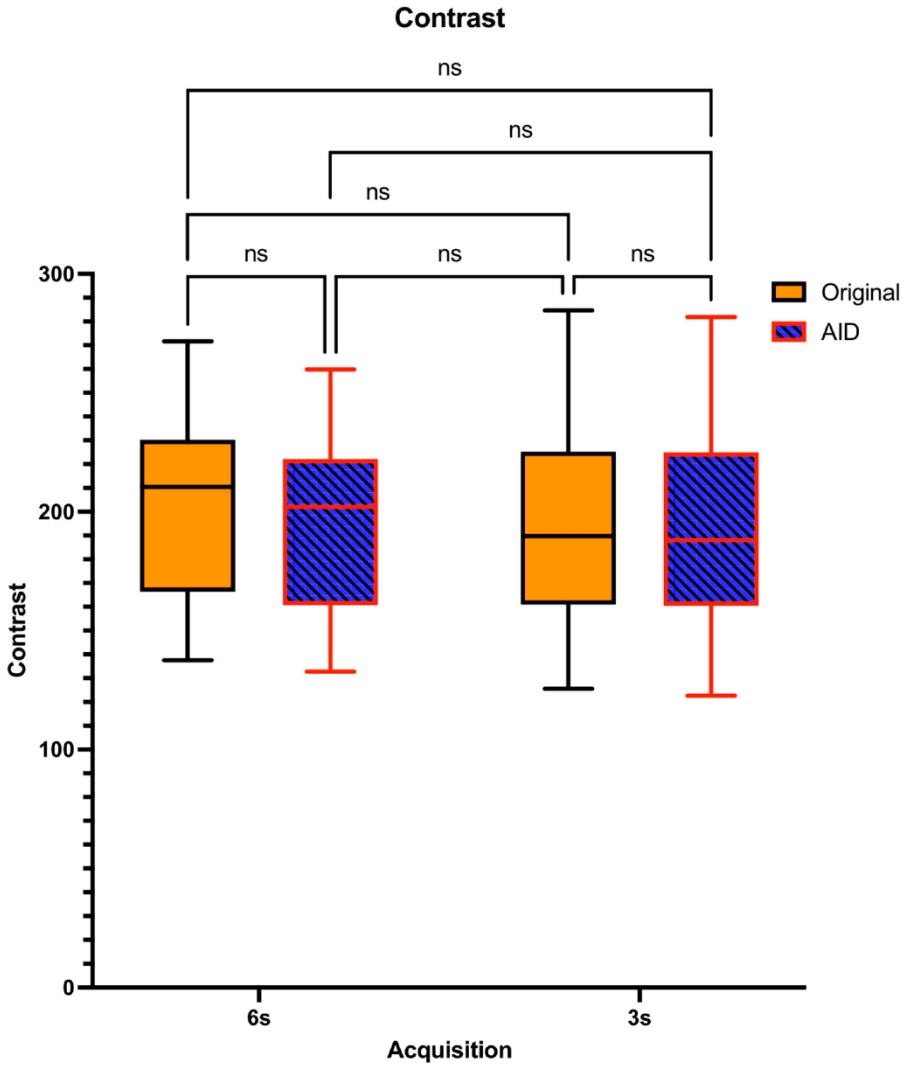

Abbildung 23: Verteilung der Kontrastwerte und paarweise Vergleiche über verschiedene Akquisitionszeiten hinweg. ns = kein statistisch signifikanter Unterschied. modifiziert nach dehdab et al. (CCBY 4.0)[61].

Die geringsten Rauschwerte traten in der 6-s-AID-Serie auf, gefolgt (in dieser Reihenfolge) von der 3-s-AID, der 6-s-Original sowie der 3-s-Original-Serie. Zwischen diesen Gruppen zeigten sich jeweils deutliche Unterschiede ($p < 0{,}0001$), mit Ausnahme des Vergleichs zwischen der 6-s-Original- und der 3-s-AID-Serie, bei dem kein signifikanter Unterschied festgestellt wurde ($p = 0{,}9423$; Abbildung 24)[61].

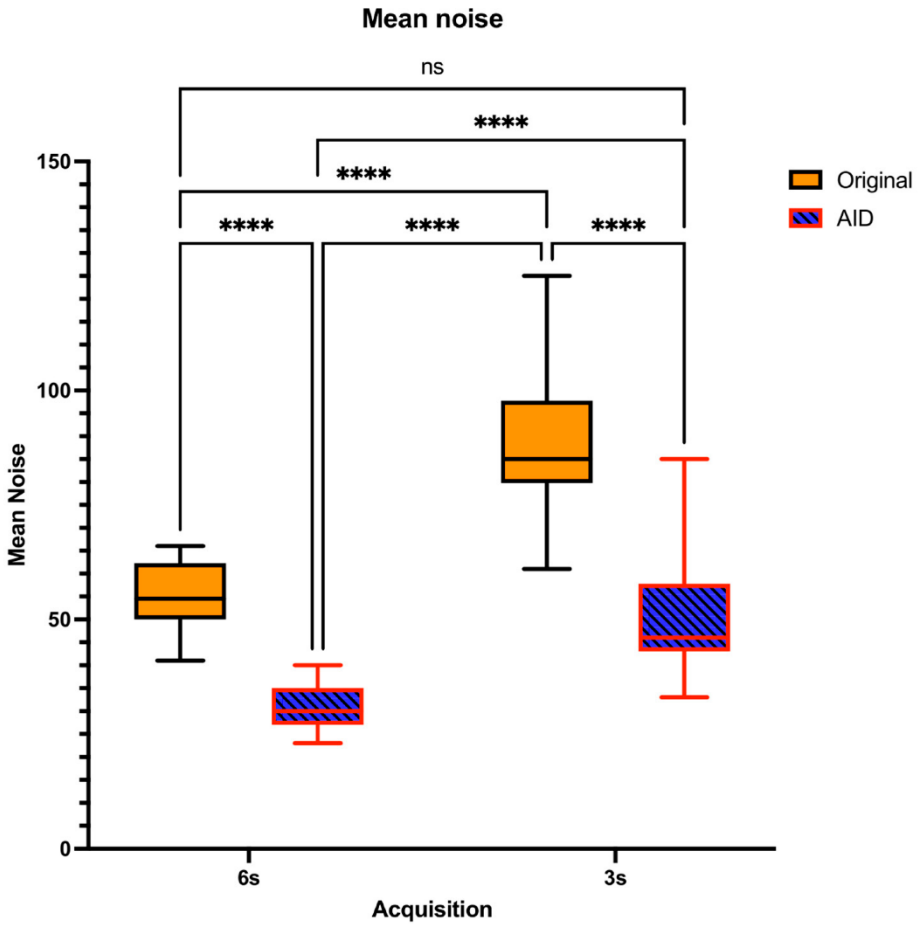

*Abbildung 24: Verteilung der mittleren Rauschwerte und paarweiser Vergleiche über verschiedene Akquisitionszeiten hinweg. ns = kein statistisch signifikanter Unterschied, **** = statistisch signifikanter Unterschied. modifiziert nach dehdab et al. (CCBY 4.0)[61].*

Die höchsten CNR-Werte wurden in der 6-s-AID-Serie gemessen, gefolgt – in absteigender Reihenfolge – von der 3-s-AID-, der 6-s-Original- sowie der 3-s-Original-Serie. Zwischen den Gruppen zeigten sich durchweg signifikante Unterschiede, mit Ausnahme des Vergleichs zwischen der 6-s-Original- und der 3-s-AID-Serie, bei dem kein signifikanter Unterschied festgestellt wurde ($p = 0{,}9968$; Abbildung 25)[61]. Tabelle 2 enthält die Mittelwerte ± Standardabweichung der objektiven Bildanalyse sowie die Signifikanzniveaus der adjustierten Post-hoc-Vergleiche.

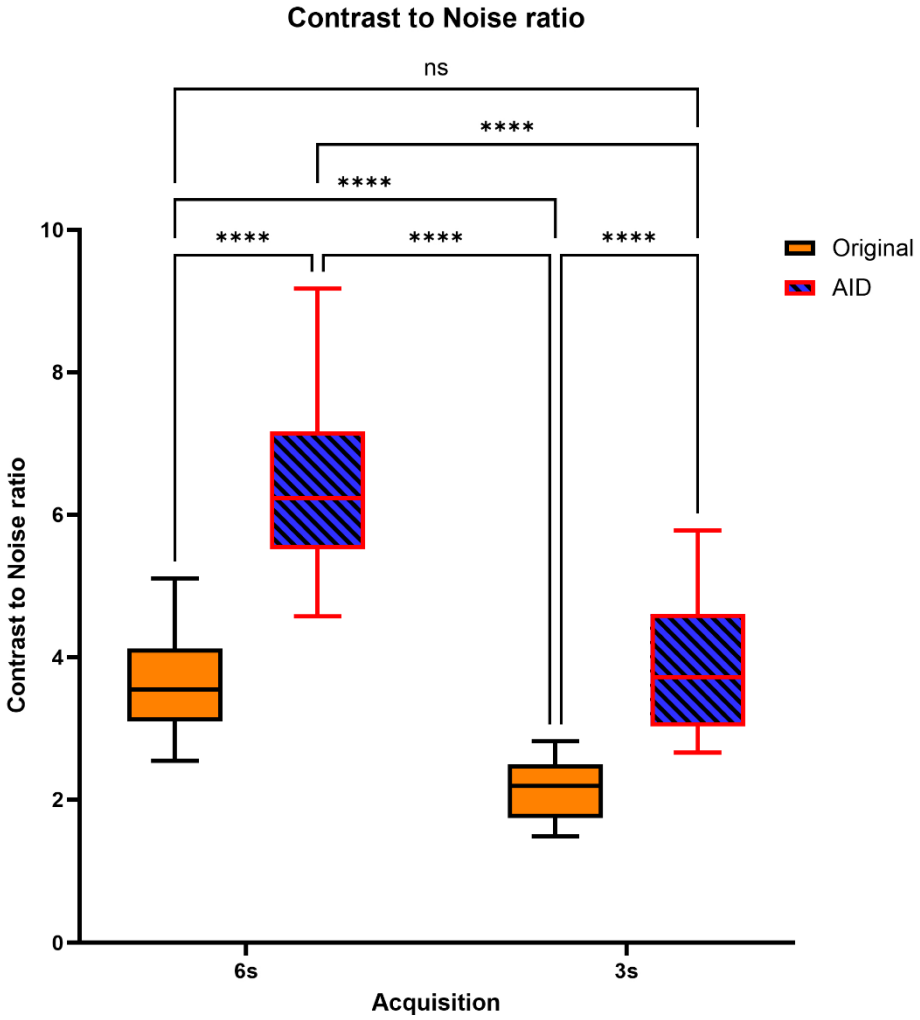

*Abbildung 25: Verteilung der CNR-Werte und paarweise Vergleiche über verschiedene Akquisitionszeiten hinweg. ns = kein statistisch signifikanter Unterschied. **** = statistisch signifikanter Unterschied. Modifiziert nach dehdab et al. (CCBY 4.0)[61].*

Tab.2. Objektive Bildqualitätsmetriken und adjustierte zweiseitige paarweise Vergleiche.

Parameter	Dataset	Reconstruction	Mean ± SD	Adjusted Two-Tailed Pairwise Comparisons (*p*)			
				3 s-AID	3 s-Original	6 s-AID	6 s-Original
CNR	3 s	AID	3.81 ± 0.86	n/a	<0.0001	<0.0001	**0.9968**
		Original	2.15 ± 0.40	<0.0001	n/a	<0.0001	<0.0001
	6 s	AID	6.45 ± 1.23	<0.0001	<0.0001	n/a	<0.0001
		Original	3.65 ± 0.67	**0.9968**	<0.0001	<0.0001	n/a
Contrast	3 s	AID	190.99 ± 44.69	n/a	**>0.9999**	**>0.9999**	**0.9998**
		Original	191.91 ± 42.94	**>0.9999**	n/a	**>0.9999**	**>0.9999**
	6 s	AID	195.16 ± 35.88	**>0.9999**	**>0.9999**	n/a	**0.9554**
		Original	200.34 ± 38.67	**0.9998**	**>0.9999**	**0.9554**	n/a
Mean Noise	3 s	AID	51.23 ± 12.11	n/a	<0.0001	<0.0001	**0.9423**
		Original	89.64 ± 14.44	<0.0001	n/a	<0.0001	<0.0001
	6 s	AID	30.59 ± 4.60	<0.0001	<0.0001	n/a	<0.0001
		Original	55.18 ± 7.06	**0.9423**	<0.0001	<0.0001	n/a

Kontrast = Differenz der Hounsfield-Einheiten (HU) zwischen relevanten Bereichen; Mittleres Rauschen = durchschnittliches Bildrauschen; CNR = Kontrast-zu-Rauschen-Verhältnis (Contrast-to-Noise Ratio); 3 s = 3 Sekunden Akquisition; 6 s = 6 Sekunden Akquisition; AID = KI-gestützte Rauschreduktion (Artificial Intelligence Denoising); SD = Standardabweichung; p = Signifikanzniveau; n. a. = nichtzutreffend. Modifiziert nach dehdab et al. (CCBY 4.0)[61].

3.3 Subjektive Beurteilung der Bildqualität

In der subjektiven Bewertung zeigte sich eine sehr hohe Übereinstimmung zwischen den Befundenden, was durch einen Spearman-Rho-Koeffizienten von 0,977 belegt wurde (jeweils $p < 0{,}001$). Die mittleren subjektiven Bewertungen sowie die zugehörigen Standardabweichungen für jede beurteilende Person sind in Tabelle 3 dargestellt[61].

Tab.3. Einzelbewertungen pro Beurteilende und Übereinstimmung zwischen den Beurteilenden (Spearman-Rho). Modifiziert nach Dehdab et al. (CCBY 4.0)[61].

Parameter	Run	Reconstruction	Rater 1 Mean ± SD	Rater 2 Mean ± SD	Spearman's Rho
Overall Subjective image quality	3 s	AID	0.011 ± 0.750	0.023 ± 0.758	0.990
		Original	−0.750 ± 0.435	−0.750 ± 0.435	1
	6 s	AID	0.750 ± 0.435	0.750 ± 0.435	1
		Original	−0.023 ± 0.758	−0.034 ± 0.765	0.990
Contrast	3 s	AID	−0.023 ± 0.758	−0.034 ± 0.765	0.990
		Original	−0.750 ± 0.435	−0.750 ± 0.435	1
	6 s	AID	0.750 ± 0.435	0.750 ± 0.435	1
		Original	0.045 ± 0.757	0.057 ± 0.764	0.990
Motion Artifacts	3 s	AID	0.557 ± 0.522	0.580 ± 0.519	0.954
		Original	0.330 ± 0.656	0.330 ± 0.690	0.888
	6 s	AID	−0.352 ± 0.644	−0.409 ± 0.600	0.839
		Original	−0.580 ± 0.496	−0.545 ± 0.501	0.794
Sharpness	3 s	AID	0.023 ± 0.727	0.011 ± 0.735	0.990
		Original	−0.750 ± 0.435	−0.750 ± 0.435	1
	6 s	AID	0.750 ± 0.435	0.750 ± 0.435	1
		Original	−0.023 ± 0.727	−0.011 ± 0.735	0.990

AID = KI-gestützte Rauschreduktion; SD = Standardabweichung.

In den zusammengefassten Analysen der subjektiven Bildqualität zeigten die Mixed-Effects-Modelle signifikante Interaktionen. Die 6-s-AID-Serie erzielte die höchste Gesamtbewertung hinsichtlich der subjektiven Bildqualität. Zwischen der 3-s-AID- und der 6-s-Original-Serie bestanden keine signifikanten Unterschiede in der Gesamtqualität ($p > 0{,}9999$); beide wurden jedoch signifikant besser bewertet als die 3-s-Original-Serie, welche die niedrigste Gesamtbewertung erhielt ($p < 0{,}0001$)[61].

Im Einklang mit diesen Ergebnissen erzielte die 6-s-AID-Serie auch hinsichtlich Kontrastes und Schärfe die höchsten Bewertungen ($p < 0{,}0001$). Zwischen der 6-s-Original- und der 3-s-AID-Serie bestanden keine signifikanten Unterschiede in Bezug auf Kontrast und Schärfe ($p > 0{,}9999$). Die 3-s-Original-Serie wurde in beiden Kategorien signifikant schlechter bewertet als alle anderen Gruppen ($p < 0{,}0001$). Bei der Bewertung der Bewegungsartefakte erhielten beide 3-s-Datensätze signifikant bessere Bewertungen, was auf eine geringere Bewegungsunschärfe hinweist ($p < 0{,}0001$). Zwischen den Original- und AID-Serien (sowohl bei 6 s als auch bei 3 s) bestanden keine signifikanten Unterschiede ($p = 0{,}981$ bzw. $p = 0{,}883$)[61].

Abbildung 26 zeigt die Verteilung der Daten sowie die Ergebnisse der Post-hoc-Vergleiche. In Tabelle 4 sind die aggregierten Mittelwerte ± Standardabweichung der subjektiven Bewertungen dargestellt, einschließlich der adjustierten zweiseitigen paarweisen Post-hoc-Vergleiche.

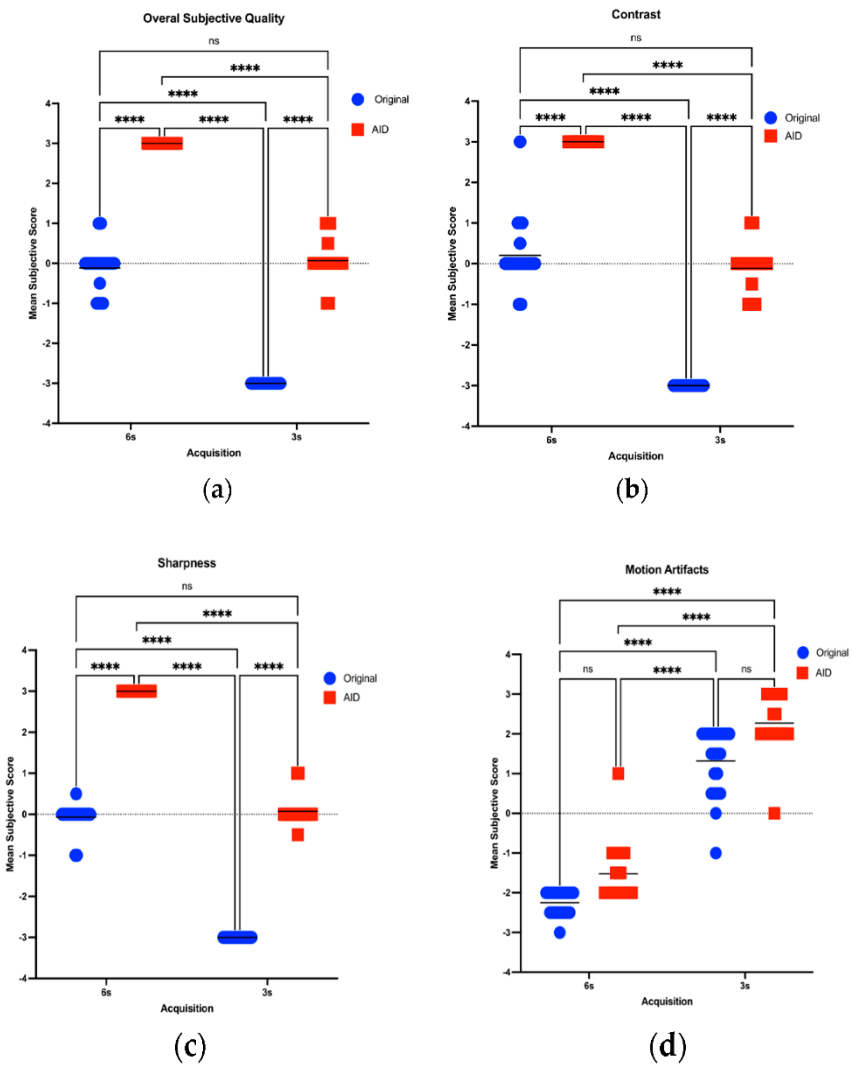

*Abbildung 26: (a–d): Punktdiagramm (Scatter Dot Plot) der mittleren subjektiven Qualitätsbewertungen bei 6-s- und 3-s-Akquisitionen, mit Bewertung von Gesamtbildqualität (a), Kontrast (b), Schärfe (c) und Bewegungsartefakten (d). ns = kein statistisch signifikanter Unterschied; **** = statistisch signifikanter Unterschied. Modifiziert nach dehdab et al. (CCBY 4.0)*[61].

Tab.4. Subjektive Bewertungsparameter der Bildqualität mit adjustierten zweiseitigen Vergleichstests. Modifiziert nach Dehdab et al. (CCBY 4.0)[61].

Parameter	Dataset	Recon	Mean ± SD	Adjusted Two-Tailed Pairwise Comparisons (*p*)			
				3 s AID	3 s Original	6 s AID	6 s Original
Overall Subjective image quality	3 s	AID	0.017 ± 0.752	n/a	<0.0001	<0.0001	**>0.9999**
		Original	−0.750 ± 0.435	<0.0001	n/a	<0.0001	<0.0001
	6 s	AID	0.750 ± 0.435	<0.0001	<0.0001	n/a	<0.0001
		Original	−0.028 ± 0.759	**>0.9999**	<0.0001	<0.0001	n/a
Contrast	3 s	AID	−0.028 ± 0.759	n/a	<0.0001	<0.0001	**0.9971**
		Original	−0.750 ± 0.435	<0.0001	n/a	<0.0001	<0.0001
	6 s	AID	0.750 ± 0.435	<0.0001	<0.0001	n/a	<0.0001
		Original	0.051 ± 0.758	**0.9971**	<0.0001	<0.0001	n/a
Motion Artifacts	3 s	AID	0.568 ± 0.515	n/a	**0.0751**	<0.0001	<0.0001
		Original	0.330 ± 0.656	**0.0751**	n/a	<0.0001	<0.0001
	6 s	AID	−0.381 ± 0.587	<0.0001	<0.0001	n/a	**0.1182**
		Original	−0.562 ± 0.472	<0.0001	<0.0001	**0.1182**	n/a
Sharpness	3 s	AID	0.017 ± 0.729	n/a	<0.0001	<0.0001	**0.9994**
		Original	−0.750 ± 0.435	<0.0001	n/a	<0.0001	<0.0001
	6 s	AID	0.750 ± 0.435	<0.0001	<0.0001	n/a	<0.0001
		Original	−0.017 ± 0.729	**0.9994**	<0.0001	<0.0001	n/a

Datensätze: 3 s = 3 Sekunden; 6 s = 6 Sekunden; AID = KI-gestützte Rauschreduktion; SD = Standardabweichung; n. a. = nichtzutreffend; p = Signifikanzniveau.

Abbildung 27 zeigt Vergleichsbilder, in denen die Pfortader und die Leberkonturen in der 3-s-AID-Serie besser abgegrenzt sind. Diese wurde durch die Reduktion von Rauschen und Bewegungsartefakten in der 3-s-AID-Serie im Vergleich zu den anderen Datensätzen erreicht[61].

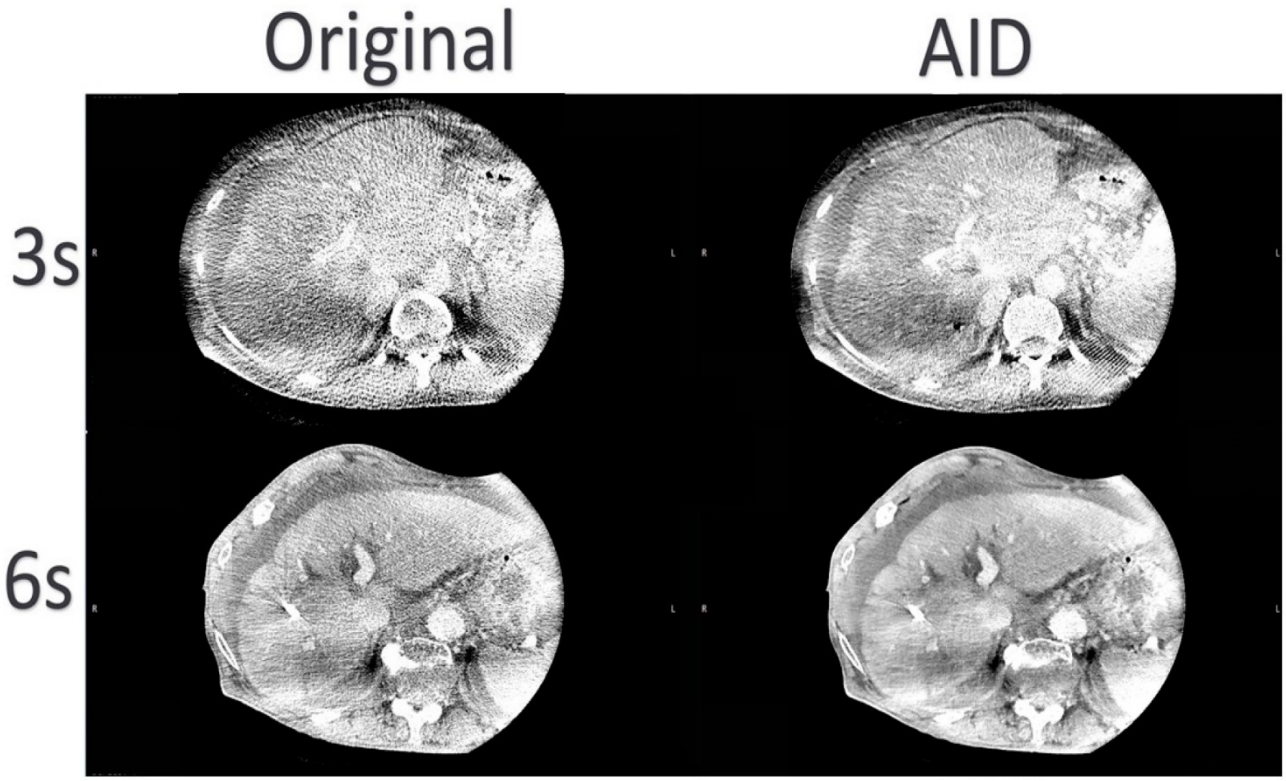

Abbildung 27: Repräsentative TIPSS-CBCT-Aufnahmen: Deutliche Verbesserung der Bildqualität in der AID-Serie durch reduzierte Rausch- und Bewegungsartefakte, was zu einer klareren Darstellung der Pfortader führt. Modifiziert nach dehdab et al. (CCBY 4.0)[61]

4 Diskussion

4.1 Interpretation der Hauptergebnisse

Die vorliegende Dissertation, basierend auf einer retrospektiven Studie, hat die signifikante Rolle eines neuartigen KI-basierten Denoising-Algorithmus bei der Verbesserung der Bildqualität in der CBCT für TIPSS-Verfahren umfassend untersucht.

Die Hauptergebnisse bestätigen die Hypothese, dass dieser Algorithmus den Kompromiss zwischen Strahlendosis, Bildrauschen und Bewegungsartefakten optimieren kann, was zu kürzeren Akquisitionszeiten und einer reduzierten Strahlenexposition bei gleichzeitig erhaltener oder sogar verbesserter diagnostischer Qualität führt[61]. Bei den 3-Sekunden-Akquisitionen ließ sich im Vergleich zu den 6-Sekunden-Akquisitionen eine deutliche Reduktion des Dosis-Flächen-Produkts (DAP) nachweisen, was eine signifikante Dosisersparnis ermöglicht. [61]. Trotz dieser Dosisreduktion zeigten die mittels KI-Denoising verarbeiteten 3-Sekunden-Bilder keine signifikanten Rauschunterschiede im Vergleich zu den 6-Sekunden Originalbildern. Dies belegt, dass die KI-Denoising Technologie in der Lage ist, die durch niedrigere Dosisprotokolle verursachte Bildqualitätsminderung effektiv zu kompensieren[53,61]. Das CNR in der 3s-AID-Serie bestätigt zudem die überlegene Fähigkeit des Algorithmus, den Kontrast bei gleichzeitig geringem Rauschen zu erhalten, was für die Erkennung kleinster anatomischer Details und pathologischer Veränderungen von großer Bedeutung ist[61].

Die subjektiven Einschätzungen erfahrener Radiologen bestätigen die Ergebnisse der objektiven Messungen.

Die Radiologen beurteilten die 3s-AID-Bilder als besser in der Gesamtqualität, und es gab keinen signifikanten Unterschied in der Gesamtqualität zwischen den 6s-Original- und den 3s-AID-Bildern.

Die subjektiven Bewertungen zeigen den Grad der klinischen Akzeptanz und den diagnostischen Wert in der Praxis. Die Fähigkeit, die Akquisitionszeit zu halbieren und die Strahlenexposition zu reduzieren, ohne die diagnostische Konfidenz zu beeinträchtigen, stellt einen Fortschritt in der interventionellen Radiologie dar[61].

4.2 Vergleich mit bestehender Literatur

Die Ergebnisse dieser Studie stehen im Einklang mit der wachsenden Evidenz, dass KI-Denoising das Potential hat, die Bildqualität in der medizinischen Bildgebung zu verbessern. Zahlreiche Studien haben gezeigt, dass Deep-Learning-basierte Denoising-Algorithmen in der Lage sind, die Bildqualität in verschiedenen Modalitäten wie CT, MRT und Ultraschall zu verbessern und gleichzeitig die Dosis zu reduzieren[49,50,67]. Beispielsweise haben Studien im Bereich der Niedrigdosis-CT für Lungenkrebs Screening gezeigt, dass KI-Denoising die Bildqualität soweit verbessern kann, dass Niedrigdosis-Scans diagnostisch äquivalent zu Standarddosis-Scans sind[68]. Ähnliche Ergebnisse wurden in der pädiatrischen CT erzielt, wo die Dosisreduktion aufgrund der erhöhten Strahlenempfindlichkeit von Kindern von erheblicher Bedeutung ist[69]. In der Analyse subjektiver Bewegungsartefakte zeigte sich, dass die 3s-Akquisitionsdatensätze (unabhängig davon, ob sie mit der Original- oder der AID-Methode verarbeitet wurden) weniger Bewegungsartefakte aufwiesen als die 6-s-Datensätze[61]. Dieser Befund wird durch frühere Studien bestätigt, die die Wirksamkeit kürzerer Akquisitionszeiten zur Reduktion von Bewegungsartefakten hervorheben[70]. Die vorliegende Studie erweitert diese Erkenntnisse auf den spezifischen und komplexen Bereich der CBCT bei TIPSS-Verfahren, was die Vielseitigkeit und Robustheit von KI Denoising-Lösungen unterstreicht. Die Fähigkeit des Algorithmus, die Bildqualität über verschiedene BMI-Bereiche hinweg stabil zu halten, ist ebenfalls bemerkenswert. Patienten mit höherem BMI stellen oft eine Herausforderung für die Bildgebung dar, da sie zu erhöhter Streustrahlung und damit zu schlechterer Bildqualität neigen[61]. Die Robustheit des KI-Denoising-Algorithmus in dieser Hinsicht ist ein wichtiger Vorteil, der die Anwendbarkeit der Technologie auf eine breitere Patientenpopulation ausdehnt[61]. Dies wurde auch in anderen Studien beobachtet, die die Wirksamkeit von KI-Denoising bei Patienten mit hohem BMI in der konventionellen CT untersuchten[53].

4.3 Relevanz für die klinische Anwendung

Die Ergebnisse dieser Dissertation liefern plausible Anhaltspunkte für den klinischen Einsatz von KI-basierten Denoising Algorithmen in der interventionellen Radiologie. Die Möglichkeit, die Akquisitionszeit von auf Sekunden zu reduzieren, ohne die diagnostische Kürzere Akquisitionszeiten bedeuten nicht nur eine geringere Strahlenexposition, sondern auch eine Reduzierung von Bewegungsartefakten. Dies ist besonders wichtig bei multimorbiden Patienten, die Schwierigkeiten haben, die Luft anzuhalten oder ruhig zu liegen. Weniger Bewegungsartefakte führen zu klareren Bildern und somit zu einer zuverlässigeren Diagnose und präziseren Intervention. Zudem kann eine verkürzte Akquisitionszeit den Patientenkomfort erhöhen und die Arbeitsabläufe in der interventionellen Suite optimieren [28,61]. Durch die Verbesserung des Signal-Rausch-Verhältnisses und des Kontrast-Rausch-Verhältnisses ermöglicht der KI-gestützte Denoising-Algorithmus eine bessere Visualisierung kleinster anatomischer Strukturen und pathologischer Veränderungen. Eine klarere Darstellung der portalvenösen Anatomie und der umliegenden Leberstrukturen ermöglicht es interventionellen Radiologen, die Punktion der Pfortader präziser zu planen und durchzuführen[28,71]. Dies reduziert das Risiko von Komplikationen wie Gefäßverletzungen oder Blutungen, die mit einer unzureichenden Visualisierung einhergehen können.

Die erhöhte diagnostische Konfidenz, die durch die verbesserte Bildqualität erzielt wird, kann auch zu einer Reduzierung der Notwendigkeit von Wiederholungsuntersuchungen oder zusätzlichen bildgebenden Verfahren führen, was sowohl die Patientenexposition als auch die Gesundheitskosten senkt[53,72]. Darüber hinaus kann die verbesserte Bildqualität die Beurteilung des Shunt-Durchgängigkeit und die frühzeitige Erkennung von Shunt-Dysfunktionen

erleichtern. Eine rechtzeitige Diagnose und Intervention bei Shunt-Stenosen oder -Thrombosen ist entscheidend, um rezidivierende Komplikationen der portalen Hypertension zu verhindern und die langfristige Wirksamkeit des TIPSS-Verfahrens zu gewährleisten. KI-Denoising kann somit indirekt zu besseren klinischen Ergebnissen und einer optimierten Patientenversorgung beitragen[73].

Kürzere Akquisitionszeiten bedeuten eine höhere Patientendurchsatzrate pro CBCT-Gerät. Dies kann die Wartezeiten für Patienten verkürzen und die Auslastung der Geräte optimieren, was zu einer besseren Ressourcennutzung im Krankenhaus führt[74]. Darüber hinaus kann die Reduzierung der Strahlenexposition für das medizinische Personal, das sich während der Akquisition im Kontrollraum aufhält, langfristig zu einer Verringerung berufsbedingter Gesundheitsrisiken beitragen[72,75]. Die Möglichkeit, niedrigere Dosisprotokolle zu verwenden, kann auch den Verschleiß der Röntgenröhre reduzieren und somit die Lebensdauer der Geräte verlängern, was wiederum Wartungs- und Ersatzkosten senkt[76,77].

4.4 Integration in den klinischen Workflow und Akzeptanz

Die erfolgreiche Implementierung von KI-Denoising-Lösungen in den klinischen Alltag hängt maßgeblich von ihrer nahtlosen Integration in bestehende Arbeitsabläufe und der Akzeptanz durch das medizinische Personal ab. Der in dieser Studie verwendete Algorithmus ist ein Post-Processing-Tool, das die rekonstruierten Bilder nach der Akquisition verarbeitet[61]. Dies ermöglicht eine flexible Integration in verschiedene CBCT-Systeme, ohne dass Hardware-Modifikationen erforderlich sind[53]. Die Tatsache, dass die Radiologen in der subjektiven Bewertung keine signifikanten Unterschiede in der Gesamtqualität zwischen den Original- und AID-Bildern feststellten, ist ein starkes Argument für die klinische Akzeptanz. Eine hohe Akzeptanz ist entscheidend für die breite Anwendung neuer Technologien in der Medizin. Schulungen und eine klare Kommunikation

der Vorteile sind jedoch unerlässlich, um Vorbehalte gegenüber KI-basierten Systemen abzubauen und das Vertrauen der Anwender zu gewinnen[78].

4.5 Potenzial für neue interventionelle Verfahren und Techniken

Die Fortschritte in der Bildqualität durch KI-Denoising könnten auch die Entwicklung und Anwendung neuer, komplexerer interventioneller Verfahren ermöglichen, die bisher aufgrund von Bildqualitätseinschränkungen nicht praktikabel waren. Mit präziseren und rauschärmeren Bildern könnten Radiologen noch feinere Strukturen ansteuern und minimal-invasive Eingriffe mit höherer Präzision durchführen. Dies könnte die Grenzen der interventionellen Radiologie erweitern und neue Behandlungsoptionen für Patienten eröffnen, die zuvor nur mit offener Chirurgie behandelt werden konnten [58]. Beispielsweise könnten komplexere Shunt-Konfigurationen oder die Behandlung kleinerer, schwer zugänglicher Läsionen sicherer und effektiver werden.

4.6 Ethische und rechtliche Aspekte der KI-Anwendung

Die zunehmende Integration von KI in die medizinische Bildgebung, einschließlich Denoising-Algorithmen, wirft wichtige ethische und rechtliche Fragen auf, die sorgfältig geprüft werden müssen. Eine zentrale Frage ist die Verantwortlichkeit bei Fehlern oder unerwünschten Effekten, die durch KI-Systeme verursacht werden. Wer trägt die Verantwortung, wenn ein KI-Algorithmus diagnostisch relevante Informationen entfernt oder Artefakte erzeugt, die zu einer Fehldiagnose führen? Ist es der Entwickler des Algorithmus, der Hersteller des Geräts, der Radiologe, der das System verwendet, oder die Institution, die es implementiert? Klare Richtlinien und rechtliche Rahmenbedingungen sind erforderlich, um diese Fragen zu adressieren und die Patientensicherheit zu gewährleisten[79]. Ein weiterer wichtiger Aspekt ist die Transparenz und Erklärbarkeit von KI-Modellen. Viele Deep-Learning-Algorithmen agieren als „Black Boxes“, deren interne Entscheidungsprozesse schwer nachvollziehbar sind. Dies kann das Vertrauen von

Radiologen und Patienten in die Technologie untergraben. Die Entwicklung von Explainable AI (XAI)-Techniken, die Einblicke in die Funktionsweise des Algorithmus geben, ist entscheidend, um die Akzeptanz zu fördern und sicherzustellen, dass diagnostische Entscheidungen auf einer fundierten Basis getroffen werden können[80].

Datenschutz und Datensicherheit sind ebenfalls von größter Bedeutung. Medizinische Bilddaten sind hochsensibel und unterliegen strengen Datenschutzbestimmungen (z.B. DSGVO in Europa, HIPAA in den USA). Die Verwendung großer Datensätze für das Training von KI-Modellen erfordert robuste Anonymisierungs- und Sicherheitsmaßnahmen, um die Privatsphäre der Patienten zu schützen. Zudem müssen die Algorithmen vor Cyberangriffen und Manipulationen geschützt werden, um die Integrität der Bilddaten zu gewährleisten[81]. Schließlich müssen auch Fragen der Gerechtigkeit und Fairness bei der Entwicklung und Anwendung von KI-Denoising-Algorithmen berücksichtigt werden. Wenn KI-Modelle hauptsächlich mit Daten aus bestimmten demografischen Gruppen oder geografischen Regionen trainiert werden, besteht das Risiko, dass sie bei anderen Patientengruppen weniger gut funktionieren oder sogar diskriminierende Ergebnisse liefern. Eine diverse und repräsentative Datengrundlage ist entscheidend, um solche Verzerrungen zu vermeiden und sicherzustellen, dass die Vorteile der KI allen Patienten zugutekommen[82].

4.7 Limitationen

Obwohl die vorliegende Studie wichtige Erkenntnisse liefert, weist sie auch einige Limitationen auf, die bei der Interpretation der Ergebnisse berücksichtigt werden müssen.

Zum einen handelt es sich um eine retrospektive Studie, bei der die Daten aus bereits vorhandenen Patientenakten und Bildgebungen entnommen wurden. Dieses Studiendesign birgt das Risiko eines Selektionsbias und kann die Generalisierbarkeit der Ergebnisse einschränken. Um die Aussagekraft zu erhöhen und die Resultate zu validieren, wären prospektive Studien mit randomisierten Kontrollgruppen wünschenswert[61].

Darüber hinaus wurde die Untersuchung als monozentrische Studie durchgeführt. Dies bedeutet, dass die Ergebnisse möglicherweise nicht direkt auf andere Einrichtungen übertragbar sind, insbesondere, wenn dort unterschiedliche CBCT-Systeme, Bildgebungsprotokolle oder Patientenpopulationen zum Einsatz kommen. Zur Erhöhung der externen Validität wären multizentrische Studien erforderlich[61].

Ein weiterer limitierender Faktor betrifft den verwendeten KI-Denoising-Algorithmus (ClariCT.AI). Die Resultate dieser Studie beziehen sich auf diesen spezifischen Algorithmus, weshalb eine direkte Übertragbarkeit auf andere KI-basierte Rauschreduktionstools nicht gewährleistet ist. Unterschiedliche Architekturen und Trainingsdatensätze könnten zu abweichenden Ergebnissen führen[61].

Darüber hinaus sind die Ergebnisse dieser Studie spezifisch für TIPSS-Verfahren. Obwohl die Prinzipien des KI Denoising übertragbar sind, müssen die spezifischen Auswirkungen auf die Bildqualität und die klinischen Vorteile für andere interventionelle radiologische Verfahren (z.B. Embolisationen, Ablationen) separat evaluiert werden[61].

Desweiteren konzentrierte sich die Studie auf die unmittelbare Bildqualität. Es fehlen Daten darüber, ob die verbesserte Bildqualität zu besseren Langzeitergebnissen für die Patienten

z.B. hinsichtlich der Shunt-Offenheit, der Reduktion von Komplikationen oder der Überlebensrate führt. Zukünftige Studien sollten diese klinisch relevanten Endpunkte prospektiv erfassen[61].

Schließlich ist auch die subjektive Bildbewertung eine mögliche Limitation der Studie. Zwar erfolgte die Bewertung durch erfahrene, verblindete Radiologen, doch bleibt sie naturgemäß subjektiv. Die Anwendung einer Likert-Skala kann eine gewisse Variabilität mit sich bringen. Zwar wurde dieser Einfluss durch die ergänzende Analyse objektiver Bildqualitätsmetriken reduziert, jedoch nicht vollständig eliminiert[53,61].

4.8 Ausblick

Die in dieser Arbeit erzielten Ergebnisse belegen das Potenzial von KI-gestütztem Denoising zur Verbesserung der Bildqualität in CBCT-Untersuchungen im interventionellen Kontext. Insbesondere konnten bei der 3-s-AID-Serie eine deutlich verbesserte Darstellung anatomischer Strukturen sowie eine Reduktion von Bewegungs- und Rauschartefakten im Vergleich zu den herkömmlichen Datensätzen beobachtet werden[61].

Diese Befunde werfen die Frage auf, inwieweit solche KI-gestützten Optimierungsansätze künftig routinemäßig in die klinische Praxis integriert werden können. Zur Klärung dieser Fragestellung wären weiterführende, prospektiv angelegte und multizentrisch durchgeführte Studien notwendig. Diese sollten nicht nur die Reproduzierbarkeit der beobachteten Effekte prüfen, sondern auch untersuchen, in welchem Maße sich die Bildverbesserung auf klinische Endpunkte wie diagnostische Sicherheit, Interventionsplanung, Komplikationsraten oder sogar auf ökonomische Aspekte wie Durchsatzzeit und Materialverbrauch auswirkt.

Auch der direkte Vergleich verschiedener KI-Denoising-Algorithmen erscheint vielversprechend, um deren relative Leistungsfähigkeit im klinischen Einsatzkontext zu bewerten. Hierbei könnten sowohl klassische CNN-basierte Modelle als auch neuere Transformer- oder GAN-Architekturen miteinander verglichen werden.

Darüber hinaus wäre es von Bedeutung, KI-Verfahren nicht isoliert zu betrachten, sondern ihre Kombination mit anderen Bildoptimierungstechnologien zu evaluieren etwa mit Metallartefakt-Reduktion, Bewegungskompensation oder iterativen Rekonstruktionsverfahren. Solche multimodalen Ansätze könnten synergistisch wirken und die Bildqualität nochmals deutlich verbessern.

Ein weiterer zukunftsweisender Aspekt ist die Entwicklung von adaptiven Denoising-Systemen, die sich patientenspezifisch an Faktoren wie Körperstatur, Alter, Leberdichte

oder Interventionsart anpassen. Damit könnten individualisierte Protokolle geschaffen werden, die bei minimaler Strahlendosis eine maximal verwertbare Bildinformation ermöglichen. Langfristig wird die Integration dieser KI-Tools in den klinischen Workflow eine zentrale Rolle spielen[83]. Nur wenn die Algorithmen in bestehende PACS-/Workstation-Infrastrukturen eingebunden und vollautomatisiert in Echtzeit nutzbar sind, wird ihr Potenzial in der täglichen Routine vollständig ausgeschöpft werden können. Auch Fragen der regulatorischen Zulassung, IT-Sicherheit und Anwenderschulung müssen dabei berücksichtigt werden[84].

Die in dieser Arbeit gewonnenen Daten liefern somit eine Grundlage für weiterführende Untersuchungen, die das Potenzial von KI-Denoising für die interventionelle Radiologie nicht nur technisch, sondern auch klinisch und systemisch erschließen und langfristig nutzbar machen könnten.

5 Zusammenfassung

Die Cone-Beam-Computertomographie (CBCT) hat sich insbesondere bei komplexen Gefäßeingriffen wie TIPSS-Prozeduren (Transjugulärer Intrahepatischer Portosystemischer Shunt) als wesentliche Modalität in der interventionellen Radiologie etabliert. Trotz ihrer Vorteile ist die CBCT aufgrund von Bildrauschen, Bewegungsartefakten und limitierter Dosissteuerung anfällig für Qualitätsverluste, insbesondere bei kurzzeitigen Niedrigdosisprotokollen. Untersucht wurde, inwiefern der Deep Learning-Denoising-Algorithmus ClariCT.AI die Qualität von CBCT-Bildern inbesondere bei verkürzten 3 Sekunden-Akquisitionen steigerte.

In einer retrospektiven, monozentrischen Analyse wurden 44 CBCT-Datensätze von 22 TIPSS-Untersuchungen mit zwei Akquisitionszeiten (6 Sekunden und 3 Sekunden) ausgewertet. Die Rekonstruktion erfolgte einerseits konventionell (gewichtete gefilterte Rückprojektion; „Original“) und andererseits nach KI-basierter Rauschreduktion („AID“). Die Datensätze wurden mittels objektiver Metrik (Rauschen, Kontrast, Kontrast Rausch-Verhältnis (CNR)) sowie subjektiver Bewertung durch erfahrene Radiologen beurteilt. Die KI-bearbeiteten Datensätze zeigten eine deutliche Reduktion des Bildrauschens und ein deutlich verbessertes CNR. Besonders hervorzuheben ist, dass die 3-s-AID-Serie trotz deutlich niedrigerer Strahlenexposition subjektiv als gleichwertig zur 6-s-Original-Serie bewertet wurde. Die Übereinstimmung der Befundenden war exzellent (Spearman-Rho = 0,977).

KI-gestütztes Denoising ermöglicht eine bessere Bildqualität bei CBCT bei gleichzeitig geringerer Strahlenbelastung. Der untersuchte KI-Algorithmus war in der Lage, auch bei verkürzter Akquisitionszeit eine bessere diagnostische Bildqualität zu gewährleisten. Im klinischen Alltag könnte dies nicht nur die Patientensicherheit durch reduzierte Strahlenexposition erhöhen, sondern auch die Effizienz und Präzision in der interventionellen Radiologie verbessern. Zur weiteren Validierung dieser Ergebnisse sind

prospektive, multizentrische Studien erforderlich, die auch klinische Endpunkte wie Komplikationsraten, Prozedurzeit und Therapieerfolg systematisch einbeziehen. Die vorliegende Arbeit liefert eine Grundlage für die zukünftige Integration KI-gestützter Bildoptimierung in den klinischen Routinebetrieb.

6 Literaturverzeichnis

1. Smith KA, Kim HS. Interventional radiology and image-guided medicine: Interventional oncology. *Semin Oncol*. 2011;38(1):151-162. doi:10.1053/j.seminoncol.2010.11.011

2. Yu H, Stavas JM. The role of interventional radiology in management of benign and malignant gynecologic diseases. *Obstet Gynecol Surv*. 2013;68(10):691-701. doi:10.1097/OGX.0b013e3182a878c6

3. Kausch L, Thomas S, Kunze H, et al. Toward automatic C-arm positioning for standard projections in orthopedic surgery. *Int J Comput Assist Radiol Surg*. 2020;15(7):1095-1105. doi:10.1007/S11548-020-02204-0

4. Jones AK, Balter S, Rauch P, Wagner LK. Medical imaging using ionizing radiation: optimization of dose and image quality in fluoroscopy. *Med Phys*. 2014;41(1). doi:10.1118/1.4835495

5. Dargel S, Stenzel M, Stöver B, et al. Guideline adherence and quality assurance in radiological diagnostics in cases of suspected child abuse in Germany. *Radiologe*. 2021;61(10):947. doi:10.1007/S00117-021-00872-W

6. Scarfe WC, Farman AG. What is Cone-Beam CT and How Does it Work? *Dent Clin North Am*. 2008;52(4):707-730. doi:10.1016/j.cden.2008.05.005

7. Siewerdsen JH. Cone-Beam CT with a Flat-Panel Detector: From Image Science to Image-Guided Surgery. *Nucl Instrum Methods Phys Res A*. 2011;648(Suppl 1):S241. doi:10.1016/J.NIMA.2010.11.088

8. Li M, Qu W, Zhang D, et al. Evaluation of Radiation Exposure and Influential Factors in Cone-Beam Computed Tomography (CBCT) of the Head and Abdomen during Interventional Procedures. *Tomography*. 2024;10(3):320. doi:10.3390/TOMOGRAPHY10030025

9. Loubele M, Maes F, Jacobs R, Van Steenberghe D, White SC, Suetens P. Comparative study of image quality for MSCT and CBCT scanners for dentomaxillofacial radiology applications. *Radiat Prot Dosimetry*. 2008;129(1-3):222-226. doi:10.1093/rpd/ncn154

10. Key BM, Tutton SM, Scheidt MJ. Cone-Beam CT With Enhanced Needle Guidance and Augmented Fluoroscopy Overlay: Applications in Interventional Radiology. *AJR Am J Roentgenol*. 2023;221(1):92-102. doi:10.2214/AJR.22.28712

11. Posadzy M, Desimpel J, Vanhoenacker F. Cone beam CT of the musculoskeletal system: clinical applications. *Insights Imaging*. 2018;9(1):35-45. doi:10.1007/S13244-017-0582-1/FIGURES/14

12. Solomon J, Samei E. Quantum noise properties of CT images with anatomical textured backgrounds across reconstruction algorithms: FBP and SAFIRE. *Med Phys*. 2014;41(9). doi:10.1118/1.4893497

13. X-ray Contrast To Noise (CNR) Illustrated Examples Of Image Noise (SNR, Quantum Mottle) For Radiologic Technologists • How Radiology Works. Accessed November 1, 2025. https://howradiologyworks.com/x-ray-cnr/

14. Duan X, Wang J, Leng S, et al. Electronic Noise in CT Detectors: Impact on Image Noise and Artifacts. *https://www.ajronline.org/*. 2013;201(4). doi:10.2214/AJR.12.10234

15. Fukuda T, Yonenaga T, Akao R, et al. Comparison of Bone Evaluation and Metal Artifact between Photon-Counting CT and Five Energy-Integrating-Detector CT under Standardized Conditions Using Cadaveric Forearms. *Diagnostics*. 2024;14(4):350. doi:10.3390/DIAGNOSTICS14040350/S1

16. Trapp P, Maier J, Susenburger M, Sawall S, Kachelrieß M. Empirical scatter correction: CBCT scatter artifact reduction without prior information. *Med Phys*. 2022;49(7):4566-4584. doi:10.1002/MP.15656

17. Boas FE, Fleischmann D. CT artifacts: causes and reduction techniques. *Imaging Med*. 2012;4(2):229-240. Accessed November 1, 2025. https://www.openaccessjournals.com/articles/ct-artifacts-causes-and-reduction-techniques.html

18. Venkatesh E, Elluru SV. Cone beam computed tomography: basics and applications in dentistry. *J Istanb Univ Fac Dent*. 2017;51(3 Suppl 1):S102. doi:10.17096/JIUFD.00289

19. Bryce-Atkinson A, De Jong R, Marchant T, et al. Low dose cone beam CT for paediatric image-guided radiotherapy: Image quality and practical recommendations. *Radiotherapy and Oncology*. 2021;163:68-75. doi:10.1016/j.radonc.2021.07.027

20. Yan H, Cervino L, Jia X, Jiang SB. A comprehensive study on the relationship between image quality and imaging dose in low-dose cone beam CT. *Phys Med Biol*. 2012;57(7):2063. doi:10.1088/0031-9155/57/7/2063

21. Goulston R, Davies J, Horner K, Murphy F. Dose optimization by altering the operating potential and tube current exposure time product in dental cone beam CT: a systematic review. *Dentomaxillofacial Radiology*. 2016;45(3):20150254. doi:10.1259/DMFR.20150254

22. Lew KL, Kew CY, Sim KS, Tan SC. Adaptive Gaussian Wiener Filter for CT-Scan Images with Gaussian Noise Variance. *Journal of Informatics and Web Engineering*. 2024;3(1):169-181. doi:10.33093/JIWE.2024.3.1.11

23. Sayin H, Aksoy B, Özsoy K, Yildirim D. Optimization of CBCT data with image processing methods and production with fused deposition modeling 3D printing. *Med Biol Eng Comput*. 2025;63(8):2235-2246. doi:10.1007/S11517-023-02889-W

24. Gardner SJ, Mao W, Liu C, et al. Improvements in CBCT Image Quality Using a Novel Iterative Reconstruction Algorithm: A Clinical Evaluation. *Adv Radiat Oncol*. 2019;4(2):390-400. doi:10.1016/j.adro.2018.12.003

25. Zhong J, Ning R, Conover D. Image denoising based on multiscale singularity detection for cone beam CT breast imaging. *IEEE Trans Med Imaging*. 2004;23(6):696-703. doi:10.1109/TMI.2004.826944

26. Setiawan I, Hidayat R, Najar AM, Jaya AI, Rosiyadi D. Low-dose computed tomography image denoising using graph wavelet transform with optimal base. *International Journal of Electrical and Computer Engineering (IJECE)*. 2025;15(2):1696. doi:10.11591/IJECE.V15I2.PP1696-1708

27. Rusanov B, Hassan GM, Reynolds M, et al. Deep learning methods for enhancing cone-beam CT image quality toward adaptive radiation therapy: A systematic review. *Med Phys*. 2022;49(9):6019-6054. doi:10.1002/MP.15840

28. Brendlin AS, Estler A, Plajer D, et al. AI Denoising Significantly Enhances Image Quality and Diagnostic Confidence in Interventional Cone-Beam Computed Tomography. *Tomography*. 2022;8(2):933. doi:10.3390/TOMOGRAPHY8020075

29. Arndt C, Güttler F, Heinrich A, Bürckenmeyer F, Diamantis I, Teichgräber U. Deep Learning CT Image Reconstruction in Clinical Practice. *RöFo - Fortschritte auf dem Gebiet der Röntgenstrahlen und der bildgebenden Verfahren*. 2021;193(03):252-261. doi:10.1055/A-1248-2556

30. Ylisiurua S, Sipola A, Nieminen MT, Brix MAK. Deep learning enables time-efficient soft tissue enhancement in CBCT: Proof-of-concept study for dentomaxillofacial applications. *Physica Medica*. 2024;117:103184. doi:10.1016/J.EJMP.2023.103184

31. Schmidhuber J. Deep Learning in neural networks: An overview. *Neural Networks*. 2015;61:85-117. doi:10.1016/j.neunet.2014.09.003

32. Li M, Jiang Y, Zhang Y, Zhu H. Medical image analysis using deep learning algorithms. *Front Public Health*. 2023;11:1273253. doi:10.3389/FPUBH.2023.1273253

33. Alzubaidi L, Zhang J, Humaidi AJ, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data*. 2021;8(1). doi:10.1186/S40537-021-00444-8

34. Das S, Tariq A, Santos T, Kantareddy SS, Banerjee I. Recurrent Neural Networks (RNNs): Architectures, Training Tricks, and Introduction to Influential Research. *Neuromethods*. 2023;197:117-138. doi:10.1007/978-1-0716-3195-9_4

35. Lu H, She Y, Tie J, Xu S. Half-UNet: A Simplified U-Net Architecture for Medical Image Segmentation. *Front Neuroinform*. 2022;16. doi:10.3389/FNINF.2022.911679

36. Gong M, Chen S, Chen Q, Zeng Y, Zhang Y. Generative Adversarial Networks in Medical Image Processing. *Curr Pharm Des*. 2020;27(15):1856-1868. doi:10.2174/1381612826666201125110710

37. Lan L, You L, Zhang Z, et al. Generative Adversarial Networks and Its Applications in Biomedical Informatics. *Front Public Health*. 2020;8. doi:10.3389/FPUBH.2020.00164

38. Choi SR, Lee M. Transformer Architecture and Attention Mechanisms in Genome Data Analysis: A Comprehensive Review. *Biology (Basel)*. 2023;12(7):1033. doi:10.3390/BIOLOGY12071033

39. Cheng L. Attention mechanism models for precision medicine. *Brief Bioinform*. 2024;25(4). doi:10.1093/BIB/BBAE156

40. Farooq Y, Savaş S. Noise Removal from the Image Using Convolutional Neural Networks-Based Denoising Auto Encoder. *Journal of Emerging Computer Technologies*. 2024;3(1):21-28. doi:10.57020/JECT.1390428

41. Kascenas A, Pugeault N, O'neil AQ. Denoising Autoencoders for Unsupervised Anomaly Detection in Brain MRI. *Proceedings of Machine Learning Research-Under Review*. Published online 2022:1-12.

42. Zhou SK, Le HN, Luu K, V Nguyen H, Ayache N. Deep reinforcement learning in medical imaging: A literature review. *Med Image Anal*. 2021;73. doi:10.1016/j.media.2021.102193

43. Jonsson A. Deep Reinforcement Learning in Medicine. *Kidney Dis (Basel)*. 2019;5(1):18-22. doi:10.1159/000492670

44. Zhang XM, Liang L, Liu L, Tang MJ. Graph Neural Networks and Their Current Applications in Bioinformatics. *Front Genet*. 2021;12:690049. doi:10.3389/FGENE.2021.690049

45. Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-444. doi:10.1038/NATURE14539

46. Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017;42:60-88. doi:10.1016/j.media.2017.07.005

47. Shin YJ, Chang W, Ye JC, et al. Low-Dose Abdominal CT Using a Deep Learning-Based Denoising Algorithm: A Comparison with CT Reconstructed with Filtered Back Projection or Iterative Reconstruction Algorithm. *Korean J Radiol*. 2020;21(3):356. doi:10.3348/KJR.2019.0413

48. Zhang J, Gong W, Ye L, Wang F, Shangguan Z, Cheng Y. A Review of deep learning methods for denoising of medical low-dose CT images. *Comput Biol Med*. 2024;171:108112. doi:10.1016/J.COMPBIOMED.2024.108112

49. Singh R, Singh N, Kaur L. Deep learning methods for 3D magnetic resonance image denoising, bias field and motion artifact correction: a comprehensive review. *Phys Med Biol*. 2024;69(23). doi:10.1088/1361-6560/AD94C7

50. Cammarasana S, Nicolardi P, Patanè G. Real-time denoising of ultrasound images based on deep learning. *Med Biol Eng Comput*. 2022;60(8):2229. doi:10.1007/S11517-022-02573-5

51. Hashimoto F, Onishi Y, Ote K, Tashima H, Reader AJ, Yamaya T. Deep learning-based PET image denoising and reconstruction: a review. *Radiological Physics and Technology 2024 17:1*. 2024;17(1):24-46. doi:10.1007/S12194-024-00780-3

52. Pain CD, Egan GF, Chen Z. Deep learning-based image reconstruction and post-processing methods in positron emission tomography for low-dose imaging and resolution enhancement. *European Journal of Nuclear Medicine and Molecular Imaging 2022 49:9*. 2022;49(9):3098-3118. doi:10.1007/S00259-022-05746-4

53. Brendlin AS, Dehdab R, Stenzl B, et al. Novel Deep Learning Denoising Enhances Image Quality and Lowers Radiation Exposure in Interventional Bronchial Artery Embolization Cone Beam CT. *Acad Radiol*. Published online 2023. doi:10.1016/J.ACRA.2023.11.003

54. Brendlin AS, Estler A, Plajer D, et al. AI Denoising Significantly Enhances Image Quality and Diagnostic Confidence in Interventional Cone-Beam Computed Tomography. *Tomography*. 2022;8(2):933. doi:10.3390/TOMOGRAPHY8020075

55. Alirr OI, Rahni AAA. Hepatic vessels segmentation using deep learning and preprocessing enhancement. *J Appl Clin Med Phys*. 2023;24(5):e13966. doi:10.1002/ACM2.13966

56. Balaguer-Montero M, Marcos Morales A, Ligero M, et al. A CT-based deep learning-driven tool for automatic liver tumor detection and delineation in patients with cancer. *Cell Rep Med*. 2025;6(4):102032. doi:10.1016/J.XCRM.2025.102032

57. Suganyadevi S, Seethalakshmi V, Balasamy K. A review on deep learning in medical image analysis. *International Journal of Multimedia Information Retrieval 2021 11:1*. 2021;11(1):19-38. doi:10.1007/S13735-021-00218-1

58. Glielmo P, Fusco S, Gitto S, et al. Artificial intelligence in interventional radiology: state of the art. *Eur Radiol Exp*. 2024;8(1). doi:10.1186/S41747-024-00452-2

59. Bahaaeldin M, Kütting D. The future of interventional radiology: more than just imaging. *Radiologie (Heidelberg, Germany)*. 2025;65(12):969. doi:10.1007/S00117-025-01534-X

60. The Lancet. AI in medicine: creating a safe and equitable future. *The Lancet*. 2023;402(10401):503. doi:10.1016/S0140-6736(23)01668-9

61. Dehdab R, Brendlin AS, Grözinger G, et al. Enhancing Cone-Beam CT Image Quality in TIPSS Procedures Using AI Denoising. *Diagnostics 2024, Vol 14, Page 1989*. 2024;14(17):1989. doi:10.3390/DIAGNOSTICS14171989

62. Hong JH, Park EA, Lee W, Ahn C, Kim JH. Incremental Image Noise Reduction in Coronary CT Angiography Using a Deep Learning-Based Technique with Iterative Reconstruction. *Korean J Radiol*. 2020;21(10):1165-1177. doi:10.3348/KJR.2020.0020

63. Weng W, Zhu X. INet: Convolutional Networks for Biomedical Image Segmentation. *IEEE Access*. 2021;9:16591-16603. doi:10.1109/ACCESS.2021.3053408

64. ClariCT.AI | AI-Powered Image Clarity for Ultra-Low-Dose CT Scans. Accessed December 6, 2025. https://claripi.com/clarict-ai/

65. Schindelin J, Arganda-Carreras I, Frise E, et al. Fiji: an open-source platform for biological-image analysis. *Nature Methods 2012 9:7*. 2012;9(7):676-682. doi:10.1038/nmeth.2019

66. Mahesh M. The Essential Physics of Medical Imaging, Third Edition. *Med Phys*. 2013;40(7). doi:10.1118/1.4811156

67. Shin YJ, Chang W, Ye JC, et al. Low-Dose Abdominal CT Using a Deep Learning-Based Denoising Algorithm: A Comparison with CT Reconstructed with Filtered Back Projection or Iterative Reconstruction Algorithm. *Korean J Radiol*. 2020;21(3):356. doi:10.3348/KJR.2019.0413

68. Wang H, Li LL, Shang J, Song J, Liu B. Application of deep learning image reconstruction in low-dose chest CT scan. *Br J Radiol*. 2022;95(1133):20210380. doi:10.1259/BJR.20210380

69. Park HS, Jeon K, Lee JE, You SK. Denoising of pediatric low dose abdominal CT using deep learning based algorithm. *PLoS One*. 2022;17(1):e0260369. doi:10.1371/JOURNAL.PONE.0260369

70. Lau BKF, Dillon O, Vinod SK, O'Brien RT, Reynolds T. Faster and lower dose imaging: evaluating adaptive, constant gantry velocity and angular separation in fast low-dose 4D cone beam CT imaging. *Med Phys*. 2024;51(2):1364-1382. doi:10.1002/MP.16585;ISSUE:ISSUE:DOI

71. Bahaaeldin M, Kütting D. The future of interventional radiology: more than just imaging. *Radiologie (Heidelberg, Germany)*. 2025;65(12):969. doi:10.1007/S00117-025-01534-X

72. Brenner DJ, Hall EJ. Computed Tomography — An Increasing Source of Radiation Exposure. *New England Journal of Medicine*. 2007;357(22):2277-2284. doi:10.1056/NEJMRA072149;WGROUP:STRING:MMS

73. Bettinger D, Janoschke M, Jenkner C, et al. Early implantation of a transjugular intrahepatic portosystemic shunt (TIPS) in patients with liver cirrhosis and ascites (eTIPS): a multicentre, randomised controlled trial. *Trials*. 2025;26(1):385. doi:10.1186/S13063-025-09038-8

74. Bryce-Atkinson A, Marchant T, Rodgers J, et al. Quantitative evaluation of 4D Cone beam CT scans with reduced scan time in lung cancer patients. *Radiotherapy and Oncology*. 2019;136:64. doi:10.1016/J.RADONC.2019.03.027

75. Iwazawa J, Ohue S, Hashimoto N, Mitani T. Comparison of the Number of Image Acquisitions and Procedural Time Required for Transarterial Chemoembolization of Hepatocellular Carcinoma with and without Tumor-Feeder Detection Software. *Radiol Res Pract*. 2013;2013:580839. doi:10.1155/2013/580839

76. Li G. Patient radiation dose and protection from cone-beam computed tomography. *Imaging Sci Dent*. 2013;43(2):63. doi:10.5624/ISD.2013.43.2.63

77. Pauwels R, Beinsberger J, Collaert B, et al. Effective dose range for dental cone beam computed tomography scanners. *Eur J Radiol*. 2012;81(2):267-271. doi:10.1016/j.ejrad.2010.11.028

78. Jahn J, Weiß J, Bamberg F, Kotter E. [Applications of artificial intelligence in radiology]. *Radiologie (Heidelberg, Germany)*. 2024;64(10):752-757. doi:10.1007/S00117-024-01357-2

79. Ii NWP, Gerke S, Glenn Cohen I. Liability for Use of Artificial Intelligence in Medicine. Accessed December 6, 2025. https://repository.law.umich.edu/book_chapters/564

80. Borys K, Schmitt YA, Nauta M, et al. Explainable AI in medical imaging: An overview for clinical practitioners – Saliency-based XAI approaches. *Eur J Radiol*. 2023;162:110787. doi:10.1016/J.EJRAD.2023.110787

81. Weiner EB, Dankwa-Mullan I, Nelson WA, Hassanpour S. Ethical challenges and evolving strategies in the integration of artificial intelligence into clinical practice. *PLOS Digital Health*. 2025;4(4):e0000810. doi:10.1371/JOURNAL.PDIG.0000810

82. Mehraeen E, Siami H, Montazeryan S, et al. Artificial Intelligence Challenges in the Healthcare Industry: A Systematic Review of Recent Evidence. *Healthc Technol Lett*. 2025;12(1):e70017. doi:10.1049/HTL2.70017

83. Nazir N, Sarwar A, Saini BS. Recent developments in denoising medical images using deep learning: An overview of models, techniques, and challenges. *Micron*. 2024;180. doi:10.1016/j.micron.2024.103615

84. Ravin CE. Digital Radiography and PACS. *Medical Imaging III: PACS System Design and Evaluation*. 1989;1093:362. doi:10.1117/12.953349

7 Anhang

7.1 Abbildungsverzeichnis

ABBILDUNG 1: ANGIOGRAPHIEEINHEIT (CBCT) ZUR INTERVENTIONELLEN BILDGEBUNG....6

ABBILDUNG 2: PRINZIP VON CBCT UND MEHRZEILEN-CT (MDCT) 7

ABBILDUNG 3: QUANTENRAUSCHEN 8

ABBILDUNG 4: PHOTON-COUNTING-CT VS. ENERGIE-INTEGRIERENDER DETEKTOR 9

ABBILDUNG 5: BEWEGUNGSARTEFAKTE....11

ABBILDUNG 6: RINGARTEFAKTE 12

ABBILDUNG 7: AUFHÄRTUNGSARTEFAKTE 13

ABBILDUNG 8: SCHEMATISCHE DARSTELLUNG DES CNR 14

ABBILDUNG 9: ITERATIVES REKONSTRUKTIONSVERFAHREN IN DER CT 16

ABBILDUNG 10: KÜNSTLICHES NEURONALES NETZWERK (ARCHITEKTUR 8–5–5) 18

ABBILDUNG 11: REKURRENTE NEURONALE NETZE (RNN)....20

ABBILDUNG 12: ENCODER-DECODER-ARCHITEKTUR (U-NET) 21

ABBILDUNG 13: GAN-MODELL FÜR MEDIZINISCHE BILDGEBUNG .... .22

ABBILDUNG 14: TRANSFORMERMODELL FÜR RADIOLOGISCHE BILDANALYSE.... .23

ABBILDUNG 15: AUTOENCODER-ARCHITEKTUREN .... .24

ABBILDUNG 16: DEEP REINFORCEMENT LEARNING (DRL) .... .25

ABBILDUNG 17: GRAPH NEURAL NETWORKS (GNN) .... .26

ABBILDUNG 18: KI-BILDVERARBEITUNG IM KONTEXT DER PET .... .29

ABBILDUNG 19: STUDIEN-WORKFLOW .... .34

Anhang

ABBILDUNG 20: VERARBEITUNGSWORKFLOW DER CBCT-BILDDATEN.....37

ABBILDUNG 21: WORKFLOW DER SUBJEKTIVEN BILDQUALITÄTSBEWERTUNG.....39

ABBILDUNG 22: KORRELATION DER CBCT-AKQUISITIONSDAUER MIT DEM DAP 42

ABBILDUNG 23: KONTRASTWERTE – VERTEILUNG UND PAARWEISE VERGLEICHE.....43

ABBILDUNG 24: RAUSCHWERTE – VERTEILUNG UND PAARWEISE VERGLEICHE.....44

ABBILDUNG 25: CNR-WERTE – VERTEILUNG UND PAARWEISE VERGLEICHE..... 45

ABBILDUNG 26: SUBJEKTIVE QUALITÄTSBEWERTUNGEN (SCATTER-PLOTS) 49

ABBILDUNG 27: REPRÄSENTATIVE TIPSS-CBCT-AUFNAHMEN.....51

7.2 Tabellenverzeichnis

TABELLE 1: CHARAKTERISTIKA DER PATIENTEN.....41

TABELLE 2: OBJEKTIVE BILDQUALITÄTSMETRIKEN.....46

TABELLE 3: EINZELBEWERTUNGEN PRO BEURTEILENDE 47

TABELLE 4: SUBJEKTIVE BEWERTUNGSPARAMETER DER BILDQUALITÄT 50

8. Erklärung zum Eigenanteil

Die Promovierende war eigenständig an der retrospektiven Auswertung klinischer CBCT-Datensätze von Patienten beteiligt, die im Zeitraum vom 01.01.2018 bis 01.01.2022 am Universitätsklinikum Tübingen im Rahmen interventionell-radiologischer TIPSS-Eingriffe untersucht wurden. Diese Arbeit erfolgte unter der Anleitung von Prof. Dr.med. Saif Afat (Geschäftsführender Oberarzt der Radiologie), PD. Dr. med. Andreas Brendlin (Oberarzt der Radiologie).

Die Hypothesenentwicklung, Literaturrecherche und Interpretation der Ergebnisse wurden eigenständig in enger Zusammenarbeit mit Prof. Dr. med. Saif Afat und PD Dr. med. Andreas Brendlin erarbeitet. Sämtliche Auswertungen der klinischen Bilddatensätze wurden nach Einarbeitung durch PD Dr. med. Andreas Brendlin eigenständig von der Promovierenden durchgeführt.

Die statistische Auswertung sowie die Auswahl der geeigneten statistischen Verfahren wurden in enger Beratung mit PD Dr. med. Andreas Brendlin. Die Ausführung der statistischen Auswertung erfolgte eigenständig durch die Promovierende in Rücksprache mit PD Dr. med. Andreas Brendlin und Prof. Dr. med. Saif Afat.

Die Diskussion der Ergebnisse fand regelmäßig in persönlichen Treffen und in Rücksprache mit den Betreuenden PD Dr. med. Andreas Brendlin und Prof. Dr. med. Saif Afat statt.

Zur sprachlichen Optimierung (Grammatik, Satzbau und Ausdruck) wurde unterstützend die Software ChatGPT (OpenAI, Stand 2025) eingesetzt, wobei die inhaltliche Ausarbeitung, Struktur und wissenschaftliche Argumentation der Arbeit vollständig eigenständig und ohne inhaltliche Einflussnahme von Künstlicher Intelligenz (KI) -basierter Software erstellt wurde.

Ich versichere, dass das vorliegende Manuskript selbstständig unter der Supervision von PD Dr. med. Andreas Brendlin und Prof. Dr. med. Saif Afat verfasst wurde und keine weiteren Quellen als die angegebenen verwendet wurden. Teile dieser Dissertation basieren auf bereits veröffentlichten Ergebnissen, die im Rahmen einer früheren wissenschaftlichen

Erklärung zum Eigenanteil

Arbeit publiziert wurden. Alle verwendeten Quellen und Daten sind entsprechend zitiert und korrekt angegeben.

9. Veröffentlichungen

Teilergebnisse dieser Arbeit wurden im Journal Diagnostics publiziert und als Abstract beim European Congress of Radiology (ECR) 2024 präsentiert:

Publikation:

Dehdab, R.; Brendlin, A.S.; Grözinger, G.; Almansour, H.; Brendel, J.M.; Gassenmaier, S.; Ghibes, P.; Werner, S.; Nikolaou, K.; Afat, S. Enhancing Cone-Beam CT Image Quality in TIPSS Procedures Using AI Denoising. Diagnostics 2024, 14, 1989. https://doi.org/10.3390/diagnostics14171989

10. Danksagungen

An dieser Stelle möchte ich allen beteiligten Personen meinen großen Dank aussprechen, die mich bei der Anfertigung meiner Dissertation unterstützt haben.

Mein besonderer Dank gilt meinem Doktorvater Prof. Dr. Saif Afat, dessen fachliche Expertise, konstruktive Unterstützung und kontinuierliche Motivation diese Arbeit entscheidend geprägt haben.

Darüber hinaus möchte ich allen beteiligten Kolleginnen und Kollegen danken, die durch ihre Mithilfe bei der Datenerhebung, Analyse und Diskussion wesentlich zum Gelingen der Arbeit beigetragen haben. Auch dem gesamten Team des Instituts für Diagnostische und Interventionelle Radiologie gilt mein Dank für die stets angenehme Zusammenarbeit und die Unterstützung während des gesamten Projekts.

Schließlich danke ich meiner Familie und meinen Freunden für ihren Rückhalt, ihre Geduld und ihre Zuversicht, die mich jederzeit begleitet haben.