

Aus der

Universitätsklinik und Poliklinik für Mund-, Kiefer- und
Gesichtschirurgie

Department für Zahn-, Mund- und Kieferheilkunde

**Die Generierung von synthetischen, nicht-
personenbezogenen Orthopantomogrammen (OPGs) mit
Generativen Adversalen Netzwerken (GANs), Analyse der
Authentizität und Machbarkeitsanalyse für Forschung,
klinische Anwendung und Lehre.**

**Inaugural-Dissertation
zur Erlangung des Doktorgrades
der Zahnmedizin**

**der Medizinischen Fakultät
der Eberhard Karls Universität
zu Tübingen**

vorgelegt von

Schönhof, Rouven Jan Michael

2025

Dekan: Professor Dr. B. Pichler

1. Berichterstatter: Privatdozent Dr. Dr. S. Hoefert

2. Berichterstatter: Professor Dr. F. Springer

Tag der Disputation: 28.04.2025

Für meine Familie

Inhaltsverzeichnis

1	EINLEITUNG	9
1.1	Planare Röntgendiagnostik in der Jahrhundertwende	9
1.2	Zahnfilm (Intraoraler Röntgenfilm)	10
1.3	Orthopantomogramme (OPGs)	11
1.3.1	Definition	11
1.3.2	Historie	11
1.3.3	Grundlagen	13
1.3.4	Interpretation	16
1.3.5	Vergleich von Zahnfilm zum OPG	20
1.3.6	Anwendung in der Medizin	22
1.3.7	Bedeutung des OPG in dem Studium der Zahnmedizin	23
1.4	Neuronale Netze	23
1.4.1	Definition	23
1.4.2	Grundlagen	23
1.5	Generative Adversale Netzwerke (GANs)	25
1.5.1	Definition	25
1.5.2	Historie	25
1.5.3	Funktionsweise	26
1.5.4	Anwendungen	27
1.6	Personen-bezogene Daten	28
1.6.1	Definition (juristisch)	28
1.6.2	Datenschutzgrundverordnung (DSGVO)	29
1.6.3	Personen-bezogene Daten in Gesundheitsdaten	29
1.6.4	Konsequenzen bei Missachtung des Datenschutzes	30
1.7	Synthetische Daten	31
1.7.1	Definition	31
1.7.2	Arten von synthetischen Daten	31
1.7.3	Rechtsgrundlage von synthetischen Daten	32
1.7.4	Vorteile	34

1.8	Fragestellung und Zielsetzung	35
2	MATERIAL UND METHODEN	37
2.1	Erstellung des OPG-GAN	37
2.1.1	Kollektiv der echten OPGs	37
2.1.2	Style-GAN-ADA, NVIDIA©	37
2.1.3	Kollektiv der synthetischen OPGs in der Studie	39
2.2	Studie	39
2.2.1	Ein- und Ausschlusskriterien	39
2.3	Studienablauf	40
2.3.1	Durchführung	40
2.3.2	Follow up	41
2.4	Statistik	42
2.4.1	Fallzahlplanung	42
2.4.2	Gruppen	42
2.4.3	Auswertung	43
3	ERGEBNISSE	45
3.1	Studienpopulation	45
3.2	Sensitivität und Spezifität	49
3.3	Score	50
3.4	Selbstbewertung	52
3.5	Subjektive Erkennungsmerkmale	53
3.6	Einzel OPG-Befundung/Interpretation	55
3.6.1	Bildqualität	55
3.6.2	Zähne	56
3.6.3	Knochenstruktur und Mineralisation	61
3.6.4	Extraktionsalveolen	62
3.6.5	Konservierende Füllungen	63
3.6.6	Apikale Aufhellungen	63
3.6.7	Wurzelkanal-gefüllte Zähne	64

Inhaltsverzeichnis

3.6.8	Nicht-erhaltungswürdige Zähne.....	65
3.6.9	Alveolarkammresorption (PA).....	65
3.6.10	Processus condylaris rechts und links	66
3.6.11	Knochenkontinuität.....	67
3.6.12	Canalis n. alveolaris inferioris.....	68
3.7	Bedeutung von synthetischen, medizinischen Bildern	69
3.7.1	Im Hinblick auf den Beruf	69
3.7.2	Im Hinblick auf die Gesellschaft	69
3.8	Follow up	70
4	DISKUSSION	72
4.1	Diskussion von Material und Methode	72
4.1.1	Allgemeine Problematik.....	72
4.1.2	OPG-GAN.....	72
4.1.3	Studie (Stärken und Limitationen)	73
4.2	Diskussion der Ergebnisse.....	74
4.2.1	Studienpopulation.....	74
4.2.2	Sensitivität, Spezifität und Score	74
4.2.3	Selbstbewertung.....	75
4.2.4	Subjektive Unterscheidungsmerkmale	75
4.2.5	Einzel OPG-Befundung	75
4.2.6	Follow up	76
4.2.7	Einschätzung der Wichtigkeit von synthetischen, medizinischen Bildern für den Beruf und Bedeutung für die Gesellschaft	76
4.3	Einfluss der Studie in die aktuelle Forschung	77
4.3.1	Personen-bezogene Daten in OPGs	79
4.4	Urheberrecht von synthetischen OPGs.....	84
4.5	Zusammenfassendes Anwendungskonzept von synthetischen, radiologischen Bildern in der medizinischen Klinik, Forschung und Lehre	86
5	ZUSAMMENFASSUNG	88
6	LITERATUR- UND ABBILDUNGSVERZEICHNIS	90

7	ERKLÄRUNG ZUM EIGENANTEIL.....	98
8	LISTE DER VERÖFFENTLICHUNGEN.....	99
9	DANKSAGUNG.....	100
10	ANHANG	101
10.1	OPT – StyleGAN2-ADA© Quellcode – Trainingsprotokoll	101
10.2	Studienaufklärung	105
10.3	Studieneinverständnis	108

Abkürzungsverzeichnis

ADA	adaptive discriminator augmentation
BDSG	Bundesdatenschutzgesetz
DSGVO	Datenschutz-Grundverordnung
DSM	Digital Single Market
GAN	Generative Adversarial Network
JAE	Jahre der Arbeitserfahrung
KI	Künstliche Intelligenz
MKG	Mund-, Kiefer- und Gesichtschirurgie
PACS	Picture Archiving and Communication System
OPG/OPT	Orthopantomogramm
PA	Parodontitis
reOPG	reales Orthopantomogramm
RöV i.S.	Röntgenopake Verschattung im Sinne von
SD	Standard deviation/Standardabweichung
syOPG	Synthetisches Orthopantomogramm
syOPGKontrolle	Synthetisches Orthopantomogramm - Kontrolle
TG18-OIQ	Test graphic 18 – overall image quality
UrhG	Urheberrechtsschutzgesetz

1 Einleitung

1.1 Planare Röntgendiagnostik in der Jahrhundertwende

Am 8. November 1895 in Würzburg entdeckte Wilhelm Conrad Röntgen mit dem bloßen Auge unsichtbare Strahlen. Er führte Experimente mit einer fast luftleeren Kathodenstrahlröhre aus Glas durch. Obwohl er die Röhre mit Pappe abdeckte, durchdrangen die Strahlen diese und projizierten das Bild eines zufällig auf dem Tisch liegenden Objekts auf einen Fluoreszenzschirm. Am 28. Dezember legte er seine erste schriftliche Abhandlung mit dem Titel „Über eine neue Art von Strahlen“ der Physikalisch-Medizinischen Gesellschaft zu Würzburg vor. Am 23. Januar 1896 demonstrierte er seine Entdeckung erstmals öffentlich. Röntgen verzichtete auf eine Patentierung, um die Verbreitung und den Einsatz der Röntgenapparate zu beschleunigen. Für seine bahnbrechende Entdeckung, die ab 1896/1897 weltweit genutzt wurde, erhielt er 1901 den ersten Nobelpreis für Physik [1].

Die ersten Aufnahmen von Zähnen wurden wahrscheinlich bereits Ende Januar und Anfang Februar 1896 gemacht. Der Zahnarzt Walkhoff fertigte Aufnahmen an, bei denen er sich wegen der langen Belichtungszeit von 25 Minuten auf den Boden legte, um ein Verwackeln zu verhindern. Durch den Einsatz einer Röhre mit einer Anode aus Platinblech konnte die Belichtungszeit halbiert werden. Im Jahr 1896 stellte C. Edmund Kells eine Zahnaufnahme vor, die mit einem Filmhalter aus besonders durchlässigem Aluminium angefertigt wurde. Damit begründete Kells die Paralleltechnik. Üblicherweise wurden jedoch Glasplatten, die als Bildempfänger dienten, von den Ärzten im Mund gehalten. 1897 wurden die ersten doppelseitig beschichteten Filme auf Zelluloidbasis hergestellt. Diese wurden in Deutschland jedoch erst ab 1923 routinemäßig verwendet. Im selben Jahr entwickelten Edison und Gehler Verstärkungsfolien, die mit Kalziumwolframat beschichtet waren. Die Halbwinkeltechnik für intraorale Zahnaufnahmen wurde unabhängig voneinander von Price im Jahr 1904 und Cieszynski im Jahr 1907 vorgestellt. Das erste zahnärztliche Röntgengerät gab

es 1904, Garretson entwickelte jedoch erst 1919 die Winkelröhre, die ab 1925 in zahnärztlichen Röntgengeräten installiert wurde. Diese technische Verbesserung ermöglichte eine präzisere Ausrichtung der verschiedenen Einstrahlwinkel. Der Franzose A. Bocage legte 1921 mit seiner Patentschrift den Grundstein für die konventionelle Tomografie. Da geeignete Halter für die Paralleltechnik fehlten, schlug Le Master 1921 vor, eine Watterolle zwischen Film und Zahn zu befestigen, um den Winkel zwischen Zahn und Film zu verringern. 1925 führte Raper die Bissflügeltechnik ein, die es ermöglichte, die approximalen Bereiche der Kronen optimal für die Kariesdiagnostik abzubilden. Ab 1928 kamen die ersten Dentalstrahler mit Hochspannungsschutz auf den Markt. Im Jahr 1931 entwickelten Hofrath und Broadbent die Technik für die Fernröntgenaufnahme. Ab 1933 wurden Geräte entwickelt, bei denen Strahler und Generator in einem Gehäuse untergebracht waren. Die Siemens-Röntgenkugel ist der bekannteste Vertreter dieser Dentalstrahler. Mit der sogenannten Einkesselbauweise wurde diese Technik in das zahnärztliche Röntgen eingeführt [2].

1.2 Zahnfilm (Intraoraler Röntgenfilm)

Der Zahnfilm ist ein klassisches bildgebendes Verfahren in der zahnärztlichen Praxis. Es basiert auf konventioneller Röntgentechnik mit einer gerichteten Strahlenquelle und einem Medium (z.B. einem Röntgenfilm), das die Strahlen aufzeichnet und ein zweidimensionales Röntgenbild erzeugt. In der heutigen Praxis kommen beim Zahnfilm zwei Technologien zum Einsatz:

- Die klassische Röntgenfilmtechnik, bei der der Film entwickelt werden muss, und
- Die digitale Speicherung mittels Speicherfolie oder Sensor.

Der Zahnfilm ist üblicherweise in den Größen 3x4 cm und 2x3 cm. Um den gewünschten Zahn im Röntgenbild darzustellen, wird der Röntgenfilm, der Sensor oder die Speicherfolie zungenseitig direkt hinter dem Zahn im Mund des Patienten positioniert. Dies geschieht entweder durch den Finger des Patienten oder spezielle Röntgenbildhalter, die den Film an Ort und Stelle halten. Das

Röntgengerät mit Tubus wird dann in der sogenannten Rechtwinkeltechnik auf den Zahnfilm ausgerichtet und ausgelöst. Alle Strukturen im Strahlengang werden präzise aufgezeichnet, wodurch der Zahnfilm detailreich und scharf ist. Ein Zahnfilm kann für gewöhnlich bis zu vier Zähne abbilden. Für eine vollständige Aufnahme aller Zähne (Zahnfilmstatus) sind in der Regel 9-10 Zahnfilme erforderlich [3].

1.3 Orthopantomogramme (OPGs)

1.3.1 Definition

Das Orthopantomogramm (OPG, OPT), auch als Panoramascichtaufnahme (PSA) bezeichnet, ist eine zweidimensionale Röntgenaufnahme, die den Ober- und Unterkiefer in einem halbkreisförmigen Bogen von einem Ohr zum anderen das Mittelgesicht/die Kiefer abbildet. Diese Methode ist ein etabliertes Verfahren in der zahnärztlichen radiologischen Bildgebung seit 1922. Sie ermöglicht eine umfassende Untersuchung der Knochen und dentalen Ober- und Unterkieferstrukturen, einschließlich aller Zähne, der benachbarten Kieferbereiche sowie teilweise der Kiefergelenke und der rechten und linken Kieferhöhle. Zusätzlich umfasst das OPG auch den seitlichen Halsbereich, was beispielsweise eine nebenbefundliche Diagnose von u.a. Arterienverkalkungen in den großen Halsschlagadern ermöglicht [4].

1.3.2 Historie

Die ersten OPGs wurden 1922 von Zulauf [5] und Numata [6] entwickelt. Dieses Verfahren, bekannt als Panographie, nutzte einen Film, der hinter einer Bleiplatte positioniert und der inneren Krümmung des Zahnbogens angepasst wurde. Die Belichtung erfolgte kontinuierlich durch ein schmales Strahlenbündel, das durch eine Schlitzblende begrenzt war und von einer Seite zur anderen bewegt wurde [7]. Anfänglich nutzte auch Paatero [8, 9] dieses intraorale Verfahren, wechselte

jedoch später zu einem außerhalb des Mundes positionierten Film. Während der Aufnahme drehte sich der Patient, dessen Gesicht eng an den gebogenen Film angelegt war, um 180 Grad, und wurde am schmalen Strahlenfeld vorbeigeführt. Diese Methode führte jedoch zu störenden Überlagerungseffekten, insbesondere durch die Schädelbasis. Um ausschließlich die Zahn- und Kieferbereiche abzubilden, wurde eine zusätzliche Bewegungskomponente in das System eingeführt. Die Anerkennung, das erste als Pantomographie zu bezeichnende Gerät entwickelt zu haben, gebührt Heckmann und nicht, wie allgemein angenommen, Paatero. Heckmann [10] legte 1939 die theoretischen Grundlagen dar, scheiterte jedoch an der Herstellung eines klinisch einsatzfähigen Gerätes. Paatero stellte erst 1951, vermutlich ohne Kenntnis von Heckmanns Arbeit, das erste funktionstüchtige Pantomographiegerät vor [7]. Film und Röntgengerät rotierten während der Aufnahme um zwei separate Drehachsen für die linke und rechte Seite, wodurch die Schichtung besser an die Form des Zahnbogens angepasst war [11].

Das erste serienreife Orthopantomographiegerät wurde 1961 auf den Markt gebracht [12]. Seitdem hat sich die Bildqualität durch die Weiterentwicklung der Generatoren, die Verkleinerung des Brennflecks, die Optimierung des Bewegungsablaufs und elektronische Steuerung deutlich verbessert. In Bezug auf die Zeichenschärfe erreichen die Bilder jedoch nicht die Qualität von Zahnfilmen, weshalb diese nicht immer ersetzt werden können. Neben den standardmäßigen Übersichtsaufnahmen wurden zusätzliche spezielle Einstellungen für die Kieferhöhlen, Kiefergelenke, transversalen Schnitte und die isolierte orthogonale Darstellung der Zahnbögen entwickelt. Auch die Durchführung von OPGs bei liegenden Patienten, die insbesondere in der Traumatologie von Vorteil sein kann, wurde mit einer aufwändigen Röntgenanlage realisiert [11].

1.3.3 Grundlagen

Das Verfahren des OPGs beruht auf dem Einsatz einer Schlitzblende und der koordinierten Bewegung einzelner oder mehrerer Komponenten des Fokus-Objekt-Film-Systems [11].

Das OPG beinhaltet die simultane Rotation eines Röntgenstrahlgenerators und eines Detektorsystems auf einer drehbaren Gantry, die zu beiden Seiten des Patienten positioniert sind. Dieses Verfahren wird auch als gekrümmte Rotations-Dickschichttomographie bezeichnet. Dabei umkreist die Röntgenröhre den Kopf des Patienten im Uhrzeigersinn von rechts nach links, bewegt sich hinter den Schultern entlang und vollzieht einen Bogen von etwa 270°. Das finale Bild resultiert aus den Rekonstruktionen einzelner Bildausschnitte des Kiefer-Gesichtsbereichs [6, 9, 13-18]. Die genaue Zuordnung jedes durch den kollimierten Strahl erreichten Punktes der Zahnbögen zu seiner Projektion auf den Detektor bildet die Basis der Panorama-Bildgebung. Siehe Abbildung 1.




Abbildung 1: Schematische Ansicht der Beziehungen zwischen der Röntgenquelle, dem Patienten, dem sekundären Kollimator und dem Bildempfänger nach Hughes et al.. Während der Röntgenröhrenkopf um eine Seite des

Patienten herum bewegt wird, bewegt sich die Empfängereinheit zur gegenüberliegenden Seite. Der Bildempfänger gleitet am Kollimator vorbei und erzeugt nacheinander ein latentes Bild [19].

Während der Untersuchung kann der Patient stehen oder sitzen. Der Kopf wird mittels Kinn- und Stirnstütze sowie seitlichen Kopfstützen fixiert. Lichtmarker weisen den Weg für eine korrekte Patientenpositionierung, wobei die Midsagittalebene in der Rotationsmittellinie des Geräts zentriert und senkrecht zum Boden ausgerichtet sein sollte [9, 14, 18]. Die Frankfurter-Horizontale, die Linie vom oberen Rand des äußeren Gehörgangs zum infraorbitalen Rand, sollte horizontal und parallel zum Boden verlaufen [18, 20-22]. Ein gekerbtes Aufbissstück hilft, die Position der Ober- und Unterkiefer-Schneidezähne zu führen, sodass sie sich in derselben Ebene innerhalb des Fokustrogs befinden. Dies ist notwendig, damit die Strahlung durch diese Zähne passieren kann. Aufbissstücke schaffen auch Abstand zwischen den Zähnen, um Überlagerungen der Kronen zu vermeiden [18, 23, 24]. Siehe Abbildung 2.




Abbildung 2: Während sich die Röntgenquelle hinter dem Patienten bewegt, wandert das Drehzentrum entlang des Bogens nach vorne (gestrichelte Linie). Die Abbildung zeigt die Richtungen des Röntgenstrahls in verschiedenen

Intervallen für die erste Hälfte des Belichtungszyklus. Die Röntgenquelle bewegt sich dann weiter um den Patienten, um die gegenüberliegende Seite zu erfassen. Nach Hughes et al. [19].

Während der Untersuchung sollte die Wirbelsäule so gerade wie möglich gehalten und der Hals gestreckt werden, was durch eine leichte Neigung des Kinns erreicht werden kann. Die Füße des Patienten sollten parallel und vor dem Körper positioniert sein, damit die Halswirbelsäule innerhalb des Fokustrogs bleibt [18, 25, 26]. Bei Personen mit großer Statur oder ausgeprägter Kyphose muss darauf geachtet werden, dass die Röntgenröhre nicht auf den Rücken oder die Schultern trifft. Zudem ist es wichtig, dass die Patienten ihre Zunge gegen den Gaumen drücken, um Überbelichtung zu vermeiden und den Schatten des Luftraums auf den oberen Zahnsitzen zu eliminieren [9, 14, 17, 18, 26]. Siehe Abbildung 3 und 4.




Abbildung 3: (A–C) Die Belichtung beginnt mit dem Röntgenröhrenkopf auf der rechten Seite des Patienten und setzt sich fort, wobei der Röhrenkopf hinter dem Patienten entlang bewegt wird und auf der linken Seite endet. Die gestrichelte Linie stellt den Weg des sich bewegenden Drehzentrums

während des Belichtungszyklus dar. (D) Strukturen zwischen dem sich bewegenden Drehzentrum und dem Detektor bilden echte Bilder (blaue Zone). (E) Strukturen, die zwischen den sich bewegenden Drehzentren und dem Detektor liegen und zweimal abgebildet werden (grüne Zone), erzeugen Doppelbilder. (F) Strukturen, die sich zwischen der Röntgenquelle und dem sich bewegenden Drehzentrum befinden (orange Zone), erzeugen Geisterbilder. Nach Hughes et al. [19].



Abbildung 4: Veraviewepocs 2D Panorama-Einheit mit Kephalmetrie-Arm [19].

1.3.4 Interpretation

Die Interpretation von OPGs folgt ähnlichen Prinzipien wie die Auswertung anderer bildgebender Verfahren. Hierbei ist ein methodisches und wiederholbares Vorgehen essenziell, um sicherzustellen, dass alle relevanten Befunde erfasst werden. Ein Beobachter sollte sich nicht darauf verlassen, dass Auffälligkeiten von selbst ins Auge fallen. Stattdessen ist eine gründliche Prüfung

aller anatomischen Strukturen notwendig, um deren Vorhandensein und Normalität zu bestätigen. Im Vergleich zu intraoralen Aufnahmen zeigt das OPG einen weit größeren Bereich der anatomischen Strukturen der Mund-, Kiefer- und Gesichtsregion. Die umfassende Beurteilung dieser Strukturen erfordert mehr Zeit, wird jedoch mit der Entwicklung einer Routine schneller und intuitiver. Ein tiefes Verständnis der normalen Anatomie ist unerlässlich, um Abnormitäten zu erkennen. Ein hilfreicher Ansatz ist der Vergleich der linken und rechten Bildseite, um festzustellen, ob ein Befund normal ist. Asymmetrien können auf eine Krankheit oder einen Entwicklungsfehler hinweisen [27]. Siehe Abbildung 5 und 6.

Folgende Schritte empfehlen sich für eine systematische Analyse der anatomischen Strukturen im OPG:

- Beurteilung der Bildperipherie und Ecken: Augenhöhlen, Gelenkfortsätze der Schläfenbeine, Halswirbelsäule, Styloidfortsätze, Pharynx, Zungenbein.
- Untersuchung der äußeren Kortikalis des Unterkiefers: Kontinuität und Ebenheit.
- Untersuchung der Kortikalis des Oberkiefers: Die posterioren und medialen Wände sowie den Boden jeder Kieferhöhle, die umgebenden Strukturen wie den Jochbeinfortsatz und die Pterygomaxillarfissur.
- Beurteilung der inneren Dichte der Kieferhöhlen.
- Untersuchung der Strukturen der Nasenhöhle und des Gaumens: Nasenboden, harter Gaumen, die Nasenscheidewand und das Gaumensegel.

- Analyse des Knochenmusters und der Trabekelstruktur von Ober- und Unterkiefer.
- Alveolarfortsätze und Zähne: Die geringere räumliche Auflösung eines OPG macht eine detaillierte Beurteilung schwieriger, dennoch ist sie für eine vollständige Befundung notwendig. Die systematische Bewertung sollte von einem Quadranten zum nächsten im Uhrzeigersinn erfolgen, wobei jeder Befund sorgfältig wiederholt wird. Die Schritte umfassen die Beurteilung der krestalen Knochenposition, die Untersuchung der parodontalen Ligamenträume und die Beurteilung von Zahnkronen und -wurzeln hinsichtlich Vorhandensein, Position, Füllungen, Restaurationen, Karies, Anomalien und Entwicklung [27].



Abbildung 5: Die Knochen des Unterkiefers, des Mittelgesichts, der Halswirbelsäule und der Schädelbasis entsprechend der Anordnung auf einem OPG. Das Bild besteht aus links- und rechts-lateralen Ansichten der Gesichtsknochen distal der Eckzähne und einer Frontalansicht zwischen Prämolaren [19].




Abbildung 6: (A) Korrekt erstelltes und dargestelltes OPG eines erwachsenen Patienten. Die linke Seite des Patienten ist auf dem Bild markiert und das Bild ist so ausgerichtet, als ob der Kliniker dem Patienten gegenübersteht. Diese Ausrichtung wird auch bei einem vollständigen Zahnfilmstatus verwendet. (B) Invertiertes Bild desselben OPG zur Identifizierung der anatomischen Strukturen im Mittelgesicht und Unterkiefer [19].

1.3.5 Vergleich von Zahnfilm zum OPG

Ein Zahnfilm und ein OPG sind beides radiologische Verfahren, die in der Zahnmedizin zur Diagnose und Planung verwendet werden. Folgend die Vor- und Nachteile beider Methoden im Vergleich:

1.3.5.1 Zahnfilm (*Intraoraler Röntgenfilm*)

Vorteile:

- Hohe Detailgenauigkeit: Zahnfilme bieten eine hohe Auflösung und Detailgenauigkeit, was sie ideal für die Erkennung von Karies, Wurzelkanalstrukturen und kleinen Läsionen macht.
- Gezielte Aufnahmen: Sie ermöglichen gezielte Aufnahmen einzelner Zähne oder kleiner Zahngruppen, was eine detaillierte Untersuchung spezifischer Problemstellen ermöglicht.
- Geringere Strahlenbelastung: Da sie nur einen kleinen Bereich des Mundes abdecken, ist die Strahlenbelastung im Vergleich zu einem OPG geringer.
- Kosten: Zahnfilme sind in der Regel kostengünstiger als ein OPG [28-30].

Nachteile:

- Begrenztes Sichtfeld: Zahnfilme decken nur kleine Bereiche ab und bieten keinen umfassenden Überblick über das gesamte Gebiss oder Kieferstrukturen.
- Unangenehme Anwendung: Die Platzierung der Filme im Mund kann für Patienten unangenehm sein und ist bei Kindern oder Patienten mit starkem Würgereiz schwieriger durchzuführen.

- Zeitaufwändig: Für eine umfassende Diagnose müssen mehrere Aufnahmen gemacht werden, was zeitaufwändiger ist als eine einzige OPG-Aufnahme [28-30].

1.3.5.2 OPG

Vorteile:

- Umfassendes Sichtfeld: Ein OPG zeigt den gesamten Mundbereich, einschließlich aller Zähne, Kieferknochen und angrenzender Strukturen, in einer einzigen Aufnahme.
- Bequemlichkeit: Für den Patienten ist die Durchführung weniger unangenehm, da kein Film im Mund platziert werden muss.
- Zeitsparend: Eine einzige Aufnahme liefert eine umfassende Übersicht, was weniger Zeit in Anspruch nimmt als mehrere intraorale Aufnahmen.
- Breitere Diagnosemöglichkeiten: Es ermöglicht die Erkennung von Kiefergelenkproblemen, impaktierten Zähnen, Zysten, Tumoren und anderen großflächigen Anomalien, die in intraoralen Aufnahmen möglicherweise nicht sichtbar sind [28-30].

Nachteile:

- Geringere Detailgenauigkeit: Die Auflösung eines OPG ist geringer als die eines Zahnfilms, was es schwieriger macht, kleine Details wie beginnende Karies oder feine Wurzelkanalstrukturen zu erkennen.
- Höhere Strahlenbelastung: Da ein größeres Gebiet abgedeckt wird, ist die Strahlenbelastung höher als bei einzelnen Zahnfilmen.
- Kosten: OPGs sind in der Regel teurer als intraorale Röntgenaufnahmen [28-30].

Zahnfilme sind ideal für detaillierte Untersuchungen einzelner Zähne und kleiner Zahngruppen, bieten aber ein begrenztes Sichtfeld und sind zeitaufwändiger. OPGs bieten eine umfassende Übersicht über das gesamte Gebiss und die Kieferstrukturen, sind jedoch weniger detailliert und strahlenintensiver. Die Wahl zwischen beiden Methoden hängt von der spezifischen diagnostischen

Anforderung und der individuellen Patientensituation ab. In vielen Fällen ergänzen sich beide Methoden und werden in Kombination verwendet, um eine umfassende Diagnose und Behandlungsplanung zu ermöglichen [3, 28-30].

1.3.6 Anwendung in der Medizin

1.3.6.1 Anwendung in der Zahnmedizin

Das OPG ist in der zahnmedizinischen Diagnostik von großer Bedeutung. Es unterscheidet sich von konventionellen Röntgenaufnahmen dadurch, dass es einen umfassenden Überblick über den gesamten, hartgewebigen Kauapparat bietet. Dazu gehören die Zahnreihen, die Kiefer, die Kiefergelenke sowie die benachbarten Strukturen wie die Kieferhöhlen. Aufgrund dieser umfangreichen Darstellung spielt das OPG eine zentrale Rolle in der Diagnostik sämtlicher zahnmedizinischer Disziplinen [31].

Zudem dient das OPG während des Behandlungsverlaufs zur Überwachung der Therapiefortschritte und zur abschließenden Bewertung des Behandlungsergebnisses [32].

1.3.6.2 Anwendung in der Rechtsmedizin (forensische Odontostomatologie)

Die Analyse von zahnmedizinischen Röntgenaufnahmen, die post mortem erstellt wurden, wie zum Beispiel OPGs, sind in der forensischen Odontologie von entscheidender Bedeutung für die Identifikation von Verstorbenen. Diese Art der Diagnostik liefert wertvolle Informationen über interne Strukturen wie Wurzelfüllungen und Entzündungen im Bereich der Wurzelspitzen, die auf anderen Wegen oft nicht erkennbar sind. Besonders bei Opfern von Bränden, bei denen die Zähne angebrannt sein können, sind Röntgenaufnahmen unerlässlich, um Füllungen und andere zahnmedizinische Arbeiten zu beurteilen, die mit bloßem Auge schwer zu erkennen sind. Solche Details ermöglichen oft die Identifikation des Opfers, besonders wenn andere Untersuchungsmethoden wie die visuelle Inspektion oder die Sektion keine klaren Ergebnisse liefern. In

Situationen, in denen nur wenige Zähne erhalten sind oder es nur wenige oder keine Füllungen gibt, können Röntgenbilder die letzte verfügbare Methode zur Identifizierung darstellen. Bei Massenkatastrophen spielen zahnmedizinische Röntgenaufnahmen eine wichtige Rolle, da sie das Verfahren zur Identifizierung der Opfer erheblich beschleunigen können [33-35].

1.3.7 Bedeutung des OPG in dem Studium der Zahnmedizin

Das Röntgen gehört seit jeher zu den wichtigsten diagnostischen Verfahren in der Zahnmedizin. Daher erlernen Zahnmedizinstudierende die Grundlagen bereits im ersten klinischen Semester. Diese Grundlagen umfassen sowohl Kenntnisse über die verschiedenen Röntgentechniken (bspw. Zahnfilme, OPG und Fernröntgen seitlich) als auch den Strahlenschutz [36].

1.4 Neuronale Netze

1.4.1 Definition

Neuronale Netzwerke, die ebenfalls unter den Bezeichnungen künstliche neuronale Netze oder simulierte neuronale Netze bekannt sind, gehören zum Fachgebiet des maschinellen Lernens und bilden die Kernkomponente von Deep-Learning-Algorithmen. Sie sind in ihrem Namen und ihrer Struktur vom menschlichen Gehirn inspiriert und simulieren, wie biologische Neuronen Signale untereinander austauschen [37].

1.4.2 Grundlagen

Künstliche neuronale Netze sind aus verschiedenen Schichten aufgebaut, die aus einer Eingabeschicht, mehreren verborgenen Schichten und einer Ausgabeschicht bestehen. Jedes künstliche Neuron innerhalb dieser Schichten ist mit anderen Neuronen verbunden und hat spezifische Gewichtungen und

einen Schwellenwert zugeordnet. Neuronen in künstlichen neuronalen Netzen erhalten multiple Inputs, addieren diese und verarbeiten die Summe mit einer Aktivierungsfunktion. Aktivierungsfunktionen, wie bspw. eine Sigmoidfunktion, werden verwendet, um dem neuronalen Netzwerk eine nicht lineare Eigenschaft zu verleihen. Auf diese Weise kann das Netz komplexere Beziehungen und Muster in den Daten modellieren. Ein Neuron wird aktiviert und übermittelt Informationen an die nächste Schicht, wenn seine Ausgabe den festgelegten Schwellenwert übersteigt. Falls nicht, erfolgt keine Weiterleitung der Daten an die folgende Schicht. Im Laufe der Zeit verbessern neuronale Netze durch das Training mit spezifischen Daten ihre Genauigkeit. Einmal präzise eingestellt, werden sie zu effektiven Werkzeugen in den Bereichen der Computerwissenschaften und künstlichen Intelligenz. Sie ermöglichen eine schnelle Klassifizierung und Gruppierung von Daten [38, 39]. Siehe Abbildung 7.

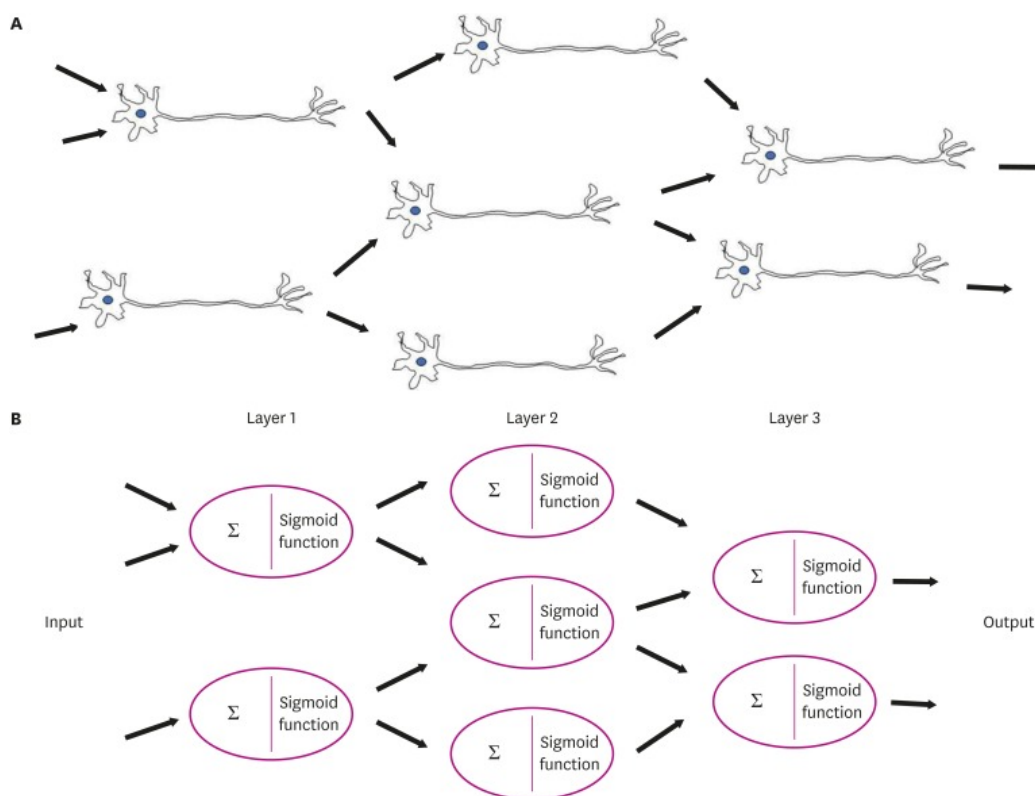


Abbildung 7: Neuronen in künstlichen neuronalen Netzen erhalten multiple Inputs, addieren diese und verarbeiten die Summe mit einer Sigmoidfunktion. Wenn die Summe der Inputs A, B und C den Schwellenwert überschreitet, generiert dieses Neuron einen Output. Der von der Sigmoidfunktion

verarbeitete Output wird dann zum neuen Inputwert für weitere Layers [40].

1.5 Generative Adversale Netzwerke (GANs)

1.5.1 Definition

Generative Adversarial Networks (GANs) sind virtuelle algorithmische Architekturen, die auf dem Einsatz zweier neuronaler Netze beruhen. Diese Netze stehen in einem kompetitiven Verhältnis zueinander, um neue, synthetische Dateninstanzen zu generieren, die von echten Daten kaum zu unterscheiden sind [41].

Der Ausdruck "generativ" bezieht sich darauf, etwas zu erzeugen oder herzustellen. Hierbei bezeichnet dies den Aspekt, aus bestimmten Eingabebildern ein Resultat mit einem speziellen Merkmal zu kreieren. Zum Beispiel könnte man ein Pferd mit hinreichender Präzision in ein Zebra umwandeln. Das Endprodukt ist abhängig von den eingegebenen Daten und der Effektivität der Trainingsschichten des generativen Modells für den spezifischen Einsatzbereich [42].

Der Ausdruck "adversarial" beschreibt das Prinzip, bei dem ein Element im Wettbewerb mit einem anderen steht. In Bezug auf GANs bezieht sich dies auf das Zusammenspiel von generierten Bildern (unechte Bilder) mit echten Bildern aus dem Datensatz. Der dafür zuständige Mechanismus wird als Diskriminator bezeichnet. Dies ist ein Modell, das darauf ausgelegt ist, zwischen den echten und den gefälschten Bildern zu differenzieren [42].

1.5.2 Historie

Ursprünglich wurden GANs im Jahr 2014 von Ian Goodfellow und anderen Forschern, einschließlich Yoshua Bengio, an der Universität von Montreal in

einem wissenschaftlichen Artikel vorgestellt. GAN-Modelle haben die Art und Weise, wie Maschinen lernen und kreativ tätig sind, grundlegend verändert und werden in zahlreichen Anwendungsbereichen eingesetzt [41].

1.5.3 Funktionsweise

Ein GAN setzt sich aus zwei tiefen neuronalen Netzen zusammen: Dem Generatornetz und dem Diskriminatornetz. Diese beiden Netzwerke befinden sich in einem fortwährenden Wettstreit, in dem der Generator neue Daten erschafft, während der Diskriminator beurteilt, ob die erzeugten Daten echt oder gefälscht sind [42, 43].

Die Funktionsweise eines GAN lässt sich technisch folgendermaßen beschreiben. Es basiert auf einer komplexen mathematischen Gleichung, die den Kern des Berechnungsprozesses bildet. Hier ist eine vereinfachte Darstellung dieses Prozesses:

1. Das Generatornetz analysiert den Trainingsdatensatz und erkennt Merkmale der Daten.
2. Das Diskriminatornetz analysiert ebenfalls die Ausgangsdaten des Trainings und macht unabhängige Unterscheidungen zwischen den Merkmalen.
3. Der Generator modifiziert einige der Datenmerkmale, indem er zufällige Änderungen oder "Rauschen" hinzufügt.
4. Der Generator übermittelt die modifizierten Daten an den Diskriminator.
5. Der Diskriminator berechnet, wie wahrscheinlich es ist, dass die vom Generator erzeugten Daten zum ursprünglichen Datensatz gehören.
6. Der Diskriminator liefert dem Generator Feedback, um in zukünftigen Durchgängen die Zufälligkeit des Rauschens zu minimieren [42, 43].

Das Ziel des Generators ist es, die Fehlerrate des Diskriminators zu maximieren, während der Diskriminator bestrebt ist, seine eigene Fehlerrate zu minimieren. Über zahlreiche Trainingsiterationen hinweg entwickeln sich sowohl der

Generator als auch der Diskriminator kontinuierlich weiter und treiben einander an, bis ein Gleichgewicht erreicht ist. In diesem Zustand kann der Diskriminator nicht mehr zwischen synthetisierten und echten Daten unterscheiden, was das Ende des Trainingsprozesses markiert [42, 43]. Siehe Abbildung 8.

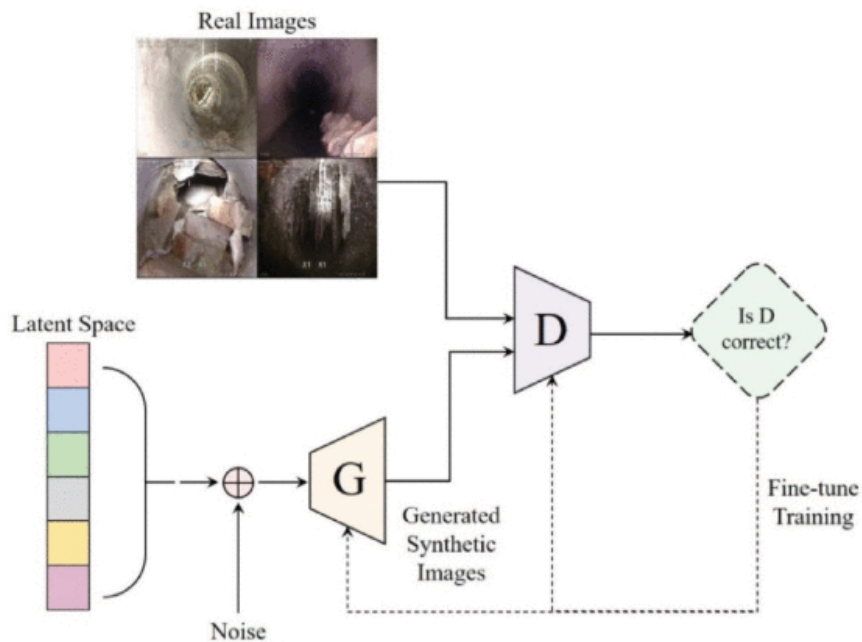


Abbildung 8: Die Abbildung zeigt, wie das Generator-Netzwerk (G) und das Diskriminator-Netzwerk (D) in einem generativen adversarialen Netzwerk (GAN) zusammenarbeiten. Das Generator-Netzwerk erzeugt neue Datenproben, während das Diskriminator-Netzwerk versucht, echte Datenproben von den durch das Generator-Netzwerk erzeugten zu unterscheiden [44].

1.5.4 Anwendungen

GANs können zu einer Vielzahl von unterschiedlichen Anwendungen konzipiert und trainiert werden. Hierzu gehört unter anderem:

- Die Generierung von Bildern: GANs sind in der Lage realistische Bilder durch textbasierte Eingaben oder durch Modifizierung existierender Bilder zu erzeugen oder zu bearbeiten.

- Das Generieren von Trainingsdaten für andere Modelle: GANs können vorhandene Datenmodelle künstlich erweitern, indem sie synthetische Daten erzeugen, die vergleichbare Merkmale echter Daten aufweisen.
- Das Vervollständigen von fehlenden Informationen: GANs können fehlende Daten auf Basis von vorhanden Datenkorrelationen ergänzen (Bspw. Verbesserung von Bildern) [43].

1.6 Personen-bezogene Daten

1.6.1 Definition (juristisch)

Personen-bezogene Daten definieren sich als Informationen, welche eine Person eindeutig identifizierbar machen. Personen gelten als identifizierbar, wenn sie direkt oder indirekt durch eine Zuordnung zu bestimmten Merkmalen wie Name, Identifikationsnummer, Standortdaten, Online-Identifikatoren oder andere charakteristische Attribute, die physische, physiologische, genetische, psychologische, wirtschaftliche, kulturelle oder soziale Eigenschaften einer natürlichen Person widerspiegeln, erkannt werden können. Praktisch gesehen bezieht sich dies auf jegliche Daten, die einer Person jetzt oder zukünftig zugeordnet werden könnten. Aufgrund der Formulierung „alle Informationen“ im Gesetzestext, sollte der Begriff „personenbezogene Daten“ weit ausgelegt werden [45, 46].

Daten, die zwar anonymisiert, verschlüsselt oder pseudonymisiert wurden, jedoch immer noch die Möglichkeit bieten, eine Person wieder zu erkennen, zählen weiterhin als personenbezogene Daten und unterliegen der Datenschutz-Grundverordnung. Werden Daten dagegen so anonymisiert, dass die betreffende Person nicht mehr erkennbar ist, gelten sie nicht länger als personenbezogene Daten. Eine solche Anonymisierung muss endgültig sein, um als gültig zu gelten [46, 47].

1.6.2 Datenschutzgrundverordnung (DSGVO)

Die DSGVO legt Regeln zum Schutz von natürlichen Personen bei der Verarbeitung ihrer personenbezogenen Daten sowie zur Gewährleistung des freien Datenverkehrs fest. Sie soll dem Schutz der Grundrechte und Grundfreiheiten von natürlichen Personen, insbesondere des Rechts auf Datenschutz, dienen [46, 48].

Zudem stellt sie klar, dass sich personenbezogene Informationen ausschließlich auf natürliche Personen beziehen, wodurch juristische Personen wie Unternehmen oder Stiftungen ausgeschlossen sind. Der Datenschutz beginnt mit der Rechtsfähigkeit einer Person, die mit der Geburt einsetzt und mit dem Tod endet. Allerdings ist noch nicht geklärt, wem die Daten nach dem Tod der Person gehören. Daten müssen somit lebenden, bestimmten oder bestimmbar Personen zuordenbar sein [45, 46].

1.6.3 Personen-bezogene Daten in Gesundheitsdaten

Gemäß Artikel 9 der DSGVO genießen Patientendaten aufgrund ihrer besonderen persönlichen Bedeutung einen erhöhten rechtlichen Schutz. Diese Daten umfassen sämtliche Informationen über den Gesundheitszustand eines Patienten, wie Gewicht, Körpergröße, Vorerkrankungen und die Frequenz von Arztbesuchen, sowie die Tatsache, dass jemand Patient ist. Der besondere Schutz dieser Daten spiegelt sich in strengen Regelungen für deren Verarbeitung wider. In der Regel dürfen Patientendaten nur mit ausdrücklicher Einwilligung der betroffenen Personen erhoben, gespeichert, genutzt oder an Dritte weitergegeben werden. Es gibt jedoch gesetzliche Ausnahmen, etwa wenn die Verarbeitung zur medizinischen Behandlung notwendig ist oder für Forschungszwecke unter Einhaltung von Pseudonymisierung und Anonymisierung. Weiterhin sind Patientendaten durch das Arztgeheimnis abgesichert und unterliegen strafrechtlichem Schutz. Angesichts ihrer Sensibilität müssen medizinische Einrichtungen wie Krankenhäuser und Arztpraxen

umfassende Sicherheitsmaßnahmen ergreifen, um zu verhindern, dass Unbefugte Zugang oder Einsicht in diese Daten erhalten [45, 49].

1.6.4 Konsequenzen bei Missachtung des Datenschutzes

Alle Einzelheiten zu Verstößen und den damit verbundenen Bußgeldern sind in der DSGVO und im Bundesdatenschutzgesetz (BDSG) festgelegt. Konkrete Sanktionen sind beispielsweise in §42 BDSG (Strafvorschriften) und §43 BDSG (Bußgeldvorschriften) beschrieben. Diese Bestimmungen sehen vor, dass Datenschutzverstöße mit einer Freiheitsstrafe von bis zu drei Jahren bestraft werden können. Die Bußgeldvorschriften des BDSG legen fest, dass Verstöße mit bis zu 50.000 Euro geahndet werden können.

Es gibt zwei Gruppen von Bußgeldtatbeständen:

I. Nach Art. 83 DSGVO können Verstöße mit einem Bußgeld von bis zu 10.000.000 Euro (bzw. 2 % des gesamten Vorjahresumsatzes, falls dieser Betrag höher ist) geahndet werden. Dies betrifft Verstöße gegen:

- Pflichten der Verantwortlichen und der Auftragsverarbeiter (Art. 8, 11, 25 bis 39, 42 und 43)
- Pflichten der Zertifizierungsstelle (Art. 42 und 43)
- Pflichten der Überwachungsstelle (Art. 41 Absatz 4) [46, 50, 51].

II. Bußgelder von bis zu 20.000.000 Euro (bzw. 4 % des gesamten Vorjahresumsatzes) drohen bei:

- Verstößen gegen die Grundsätze für die Verarbeitung, einschließlich der Bedingungen für die Einwilligung (Art. 5, 6, 7 und 9)
- Verstößen gegen die Rechte der betroffenen Person (Art. 12 bis 22)
- Übermittlung personenbezogener Daten an einen Empfänger in einem Drittland oder an eine internationale Organisation (Art. 44 bis 49)
- Verstößen gegen alle Pflichten gemäß den Rechtsvorschriften der Mitgliedstaaten, die im Rahmen des Kapitels IX erlassen wurden

- Verstößen gegen eine Anweisung oder eine vorübergehende oder endgültige Beschränkung oder Aussetzung der Datenübermittlung durch die Aufsichtsbehörde (Art. 58 Absatz 2)
- Nichtgewährung des Zugangs (Art. 58 Absatz 1)
- Verstößen gegen eine Anweisung der Aufsichtsbehörde (Art. 58 Absatz 2) [46, 50, 51]

1.7 Synthetische Daten

1.7.1 Definition

Synthetische Daten sind künstlich erzeugte Datensätze, die von Algorithmen und Simulationen generiert werden, um reale Daten nachzubilden. Sie entstehen durch den Einsatz von Technologien generativer künstlicher Intelligenz. Obwohl ein synthetischer Datensatz die gleichen mathematischen Eigenschaften wie die Originaldaten aufweist, enthält er nicht die exakten Informationen der ursprünglichen Daten. Diese Art von Daten wird vor allem eingesetzt, um Datenschutz zu gewährleisten, während gleichzeitig realistische Daten für Analysen und Trainingsprozesse bereitgestellt werden [52].

1.7.2 Arten von synthetischen Daten

Es gibt zwei Hauptarten synthetischer Daten: teilweise synthetische und vollständig synthetische Daten.

1.7.2.1 Teilweise synthetische Daten

Diese Art der Datenmodifikation schützt sensible Bereiche eines Datensatzes, indem sie lediglich Teile der realen Daten durch synthetische Informationen ersetzt. Beispielsweise kann bei der Analyse von Kundendaten für Datenschutzzwecke entschieden werden, persönliche Informationen wie Namen, Kontaktdetails und andere identifizierbare Daten zu synthetisieren. Dadurch

bleibt die Grundstruktur des Datensatzes erhalten, während die Vertraulichkeit gewahrt wird [52].

1.7.2.2 Vollständige synthetische Daten

Im Gegensatz zu teilweise synthetischen Daten werden bei vollständig synthetischen Daten komplette Datensätze neu erstellt, die keine realen Daten enthalten. Sie imitieren jedoch die Beziehungen, Verteilungen und statistischen Eigenschaften realer Daten, was bedeutet, dass sie für wissenschaftliche Studien und Modelltests nützlich sind, ohne dass auf echte Daten zurückgegriffen werden muss. Diese Methode ist besonders vorteilhaft beim Testen und Entwickeln neuer Machine-Learning-Modelle, wenn nicht ausreichend reale Daten vorhanden sind, um die Genauigkeit der Modelle zu trainieren und zu verbessern. Sie ermöglicht es Forschern und Entwicklern, Modelle unter kontrollierten Bedingungen zu optimieren, ohne Datenschutzrichtlinien zu verletzen oder die Integrität realer Personen zu gefährden [52].

1.7.3 Rechtsgrundlage von synthetischen Daten

1.7.3.1 Urheber- und Eigentumsrecht

Um urheberrechtlichen Schutz für KI-erzeugte Inhalte zu erhalten, müssen diese als „Werk“ gemäß § 2 Abs. 2 des Urheberrechtsgesetzes (UrhG) gelten, was bedeutet, dass sie eine persönliche geistige Schöpfung darstellen. Diese Schöpfung gilt nur dann als „persönlich“, wenn sie auf menschlicher kreativer Tätigkeit beruht. Wenn eine KI eigenständig den urheberrechtlich relevanten Inhalt erstellt und alle wichtigen gestalterischen Entscheidungen trifft, wird dieser Output meist nicht als urheberrechtlich geschützt angesehen, da keine „persönliche geistige Schöpfung“ vorliegt. Wenn sowohl Menschen als auch KIs am Schaffensprozess beteiligt sind ist entscheidend, ob der menschliche Beitrag zur Gestaltung des Endprodukts ausreichend ist, um als Urheber anerkannt zu werden. Es kommt darauf an, ob die KI lediglich als Werkzeug diente, um vom Schöpfer vorgegebene Entscheidungen umzusetzen, oder ob die KI die Kontrolle

über den gesamten kreativen Prozess hat. Im letzteren Fall fehlt es an einer persönlichen geistigen Schöpfung, was den urheberrechtlichen Schutz ausschließt. Aus diesen Überlegungen ergeben sich mehrere Herausforderungen für das Urheberrecht: Zum einen die Frage, wie genau bestimmt wird, ob ein Werk einem Menschen oder einer KI zuzurechnen ist. Zum anderen die praktische Schwierigkeit, ohne genaue Kenntnis des Entstehungsprozesses, zu beurteilen, wie groß der menschliche Anteil am KI-Output ist. Darüber hinaus ist zu unklar, wie mit Werken umgegangen wird, die nicht den Anforderungen des § 2 Abs. 2 UrhG entsprechen und somit keinen urheberrechtlichen Schutz genießen [53].

Um künstliche Intelligenzen (KI) effektiv trainieren zu können, müssen Algorithmen mit umfangreichen Datensätzen trainiert werden, ein Vorgang bekannt als Text- und Data-Mining. Dies wirft rechtliche Fragen auf, da viele der Daten, die für das Training genutzt werden – wie Bilder, Texte, Videos – urheberrechtlich geschützt sein können. Der Einsatz solcher Daten für das Training einer KI kann unter Umständen Urheberrechte verletzen, da hierfür Daten in den Arbeitsspeicher geladen werden müssen, was Vervielfältigungen und möglicherweise auch Modifikationen nach sich zieht. Diese Handlungen können gegen das Vervielfältigungsrecht (§ 16 UrhG) oder gegen das Bearbeitungsrecht (§ 23 UrhG) verstoßen. Bis Juni 2021 benötigte man in Deutschland die Erlaubnis des Urhebers für derartige Vervielfältigungen, außer sie dienen wissenschaftlichen Zwecken (§ 60d UrhG a.F.). Zur Lösung dieser Problematik und zur Förderung technologischer Innovationen führte der europäische Gesetzgeber 2019 mit der DSM-Richtlinie (RL (EU) 2019/790 vom 17. April 2019) eine Regelung ein, die in Deutschland als § 44b UrhG umgesetzt wurde und am 07. Juni 2021 in Kraft trat. Diese Regelung erlaubt die Vervielfältigung rechtlich zugänglicher Werke für Text- und Data-Mining, vorausgesetzt der Rechtsinhaber hat sich die Nutzung nicht explizit vorbehalten. Die Erlaubnis gilt nicht nur für Forschungszwecke, sondern auch für kommerzielle Anwendungen [53].

1.7.3.2 Personen-bezogene Daten hinsichtlich synthetischer Daten

Kaulartz et al. (2020) erörtern in ihrem Werk „Rechtshandbuch Artificial Intelligence und Machine Learning“ die Erstellung von synthetischen Daten im Zusammenhang mit KI-gestützter Datenverarbeitung. Das Ziel dabei ist, den Trainingsprozess für maschinelles Lernen nicht auf Basis von echten personenbezogenen Daten, sondern mit Hilfe von Ersatzdaten durchzuführen. Diese Ersatzdaten, die mittels GANs erzeugt werden, sollen dieselben statistischen Eigenschaften wie die echten Daten haben, jedoch ohne personenbezogen zu sein. Auf diese Weise lässt sich aus einer geringen Menge echter personenbezogener Daten eine große Anzahl synthetischer Daten generieren, wodurch der Trainingsprozess ohne personenbezogene Daten möglich ist. Dafür benötigen die GANs zunächst eine bestimmte Menge an echten, personenbezogenen und sensiblen Daten gemäß Art. 9 Abs. 1 DSGVO, die hauptsächlich zum Zweck der Herstellung synthetischer Daten erhoben werden [54, 55].

1.7.4 Vorteile

Synthetische Daten ermöglichen die Erzeugung nahezu unbegrenzter Datensätze auf Abruf und bieten eine kostengünstige Alternative, um umfangreiche Datensammlungen für unterschiedliche Anwendungsfälle, insbesondere im Bereich des maschinellen Lernens, zu generieren. Diese Technologie kann Daten automatisch vorverarbeiten, indem sie sie kategorisiert oder markiert, wodurch strukturierte und annotierte Daten zur Verfügung stehen, ohne dass eine Neubearbeitung der Ursprungsdaten notwendig ist. Zudem lassen sich synthetische Daten in bestehende Datensätze einfügen, um die Menge an Trainingsdaten für Analysen zu erhöhen. Im Hinblick auf den Datenschutz bieten synthetische Daten eine effektive Lösung, insbesondere in sensiblen Bereichen wie dem Gesundheits-, Finanz- und Rechtswesen, die strengen Datenschutz- und Compliance-Vorgaben unterliegen. Durch die Verwendung synthetischer Daten, die die statistischen Eigenschaften

personenbezogener Daten nachbilden, aber keine sensiblen Informationen enthalten, können Organisationen Daten für Forschung und Analyse nutzen, ohne private Daten preiszugeben. Ein Beispiel hierfür ist die Erzeugung synthetischer medizinischer Datensätze, die biologische Merkmale und genetische Marker des Originaldatensatzes widerspiegeln, jedoch ohne persönliche Identifikatoren wie Namen oder Adressen. Darüber hinaus können synthetische Daten dazu beitragen, Verzerrungen in KI-Trainingsmodellen zu reduzieren. Oft basieren große KI-Modelle auf öffentlich zugänglichen Datensätzen, die voreingenommene Informationen enthalten können. Durch die Erstellung synthetischer Datensätze, die eine ausgewogene Darstellung verschiedener Merkmale und Perspektiven bieten, lassen sich bestehende Verzerrungen korrigieren und die Fairness der Modelle verbessern. Dies ist besonders nützlich in Fällen, in denen Daten Verzerrungen aufweisen, die bestimmte Gruppen bevorzugen oder benachteiligen [52].

1.8 Fragestellung und Zielsetzung

Im Hinblick auf die o.g. Leistungen und Vorteile von GANs stellen OPGs eine geeignete Trainings-Anwendung dar. OPGs besitzen ein hohes Maß an Standardisierung (z. B. Format, Kontrast, Konfiguration usw.), während sie gleichzeitig eine Vielzahl an individuellen Abweichungen aufweisen (z. B. Zahnanordnung, Prothetik, Füllungen usw.). Man könnte dies als eine Art radiologischen Fingerabdruck betrachten, welcher eine Person z. T. allein durch klinische Inspektion identifizierbar macht. Aus diesem Grund kann davon ausgegangen werden, dass OPGs trotz der Standardisierung eine Fülle von individuellen, personenbezogenen Daten enthalten.

Zum Zeitpunkt der Studie weist die Literatur nur wenige Belege für die Authentizität synthetischer, radiologischer Bilder auf, während die Weiterentwicklung von GANs im medizinischen Bereich ein Forschungszweig mit hohem Wachstumspotential darstellt. Aus diesem Grund haben wir in dieser Studie aus einem Datensatz echter OPGs (reOPGs) synthetische OPGs

(syOPGs) erstellt und eine Umfrage zur Bewertung synthetischer Bilddaten im Bereich der zahnmedizinischen Radiologie durchgeführt.

Es wurden die folgenden Ziele dieser Studie definiert:

1. Training eines StyleGAN für OPGs, welches in der Lage ist, realitätsnahe Abbildungen von OPGs zu generieren.
2. Re-Evaluation der computergenerierten OPGs gegen echte OPGs durch Zahnärzte und Studierende zur Prüfung der Authentizität.
3. Erstellung einer Datenbank für synthetische OPGs mit nicht-personenbezogenen Abbildungen.
4. Bereitstellung der computer-generierten Bilder für:
 - a. das Training von neuronalen Netzwerken zur Ermöglichung der automatischen radiologischen Bildanalyse und Befundung sowie Verbesserung der KI-unterstützten Diagnosequalität.
 - b. DGSVO-konforme Abbildungen für Forschung, klinische Anwendung und Lehre (Vorlesungen, Seminare, Patientenaufklärung, wissenschaftliche Vorträge etc.).

Eine vergleichbare Anwendung im Bereich der (zahn)medizinischen Radiologie ist zum Zeitpunkt der Studie nicht bekannt, womit diese Studie nach aktueller Kenntnis der Wissenschaft die erste ihrer Art darstellt.

Von einer geplanten, frei zugänglichen Datenbank für synthetische OPGs könnten Ärzt/-innen, Kliniker/innen, Wissenschaftler/-innen, Entwickler/-innen, Lehrende und Studierende profitieren, da keine personenbezogenen Daten enthalten sind und somit eine vereinfachte Rechtsprechung vorliegt.

2 Material und Methoden

2.1 Erstellung des OPG-GAN

2.1.1 Kollektiv der echten OPGs

Von August 2012 bis Juni 2022 wurden insgesamt 10.349 OPG-Bilder aus dem Picture Archiving and Communication System (PACS) der Universität Tübingen gesammelt und als JPEG-Dateien gespeichert. Von diesen Bildern wurden 750 OPGs aufgrund des Vorhandenseins extremer Artefakte sowie partielle OPGs ausgeschlossen. Die verbleibenden 9599 OPGs wurden zentriert und auf eine Größe von 2048×1024 Pixel beschnitten. Genehmigt wurde die Erstellung des OPG-GAN von der klinischen Ethik-Kommission des Universitätsklinikums Tübingen, konform der Deklaration von Helsinki (231/2022BO2).

2.1.2 Style-GAN-ADA, NVIDIA©

Anschließend wurden o.g. Bilder als Trainingsset für ein GAN verwendet. Als GAN wurde StyleGAN2-ADA© (adaptive discriminator augmentation) verwendet, das von NVIDIA© (USA) im März 2020 entwickelt wurde. StyleGAN2-ADA© ist ein Open-Source-GAN, welches zur Zeit dieser Dissertation Spitzenleistungen bei der datengesteuerten unbedingten generativen Bildmodellierung erbringt [11]. StyleGAN2-ADA© wurde eingesetzt, um qualitativ hochwertige Bilder auf der Grundlage der verfügbaren Trainingsdaten aus dem PACS der Universität zu erzeugen. Siehe Abbildung 9.

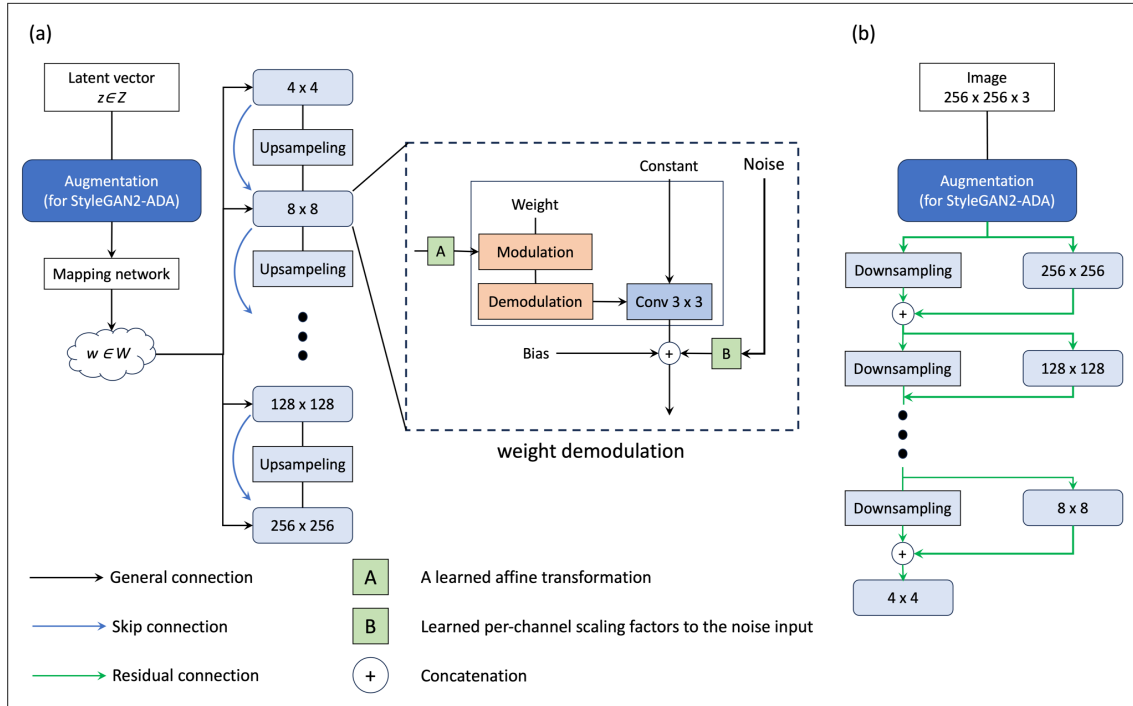


Abbildung 9: (a) Der Generator und (b) der Diskriminator der StyleGANs. Zu beachten ist, dass StyleGAN2-ADA[©] die Datenaugmentation nach dem Eingangsvektor für beide Komponenten durchführt.

Generator (a): Der Generator von StyleGAN2[©] ist dafür verantwortlich, realistische Bilder aus zufälligen Eingangsvektoren zu erzeugen. Er nutzt ein Mapping-Netzwerk, das den Eingangsvektor in einen latenten Vektor transformiert, der dann durch mehrere Schichten verarbeitet wird, um das endgültige Bild zu erzeugen.

Diskriminator (b): Der Diskriminator von StyleGAN2[©] unterscheidet zwischen echten und vom Generator erzeugten Bildern. Er nimmt Bilder als Eingabe und verarbeitet sie durch mehrere Schichten, um zu entscheiden, ob das Bild echt oder künstlich ist.

Datenaugmentation bei StyleGAN2-ADA[©]: StyleGAN2-ADA[©] führt eine Datenaugmentation nach dem Eingangsvektor für sowohl den Generator als auch den Diskriminator durch. Diese Technik verbessert die Robustheit des Modells, indem sie die Menge der Trainingsdaten effektiv erhöht und dadurch die Leistung des GANs bei begrenzten Datenmengen verbessert. Modifiziert nach [44].

2.1.3 Kollektiv der synthetischen OPGs in der Studie

Mit StyleGAN2-ADA© wurden 1000 syOPGs-Bilder erzeugt. Daraus wurden 20 syOPGs, welche nach erstem Eindruck authentisch erschienen, selektiert. Zusätzlich wurden fünf weitere syOPGs ausgewählt, welche offensichtliche logische Fehler enthielten. Diese fünf syOPGs wurden als Kontrolle (syOPGkontrollen) für die Testpersonen verwendet (z. B. ausgehöhlte Metallplatten, biologische Kronen auf künstlichen Implantaten, isoliert geschnittene Wurzeln ohne Wurzelfüllmaterial usw.). Dazu wurden noch 20 reOPGs aus dem OPG-Pool, welche für das Training des GAN verwendet wurden, ausgewählt. Die Bilder wurden in Bezug auf Format, Helligkeit, Kontrast und Bildrauschen standardisiert. Damit ergaben sich für die u. g. Studie insgesamt 45 radiologische Bilder (20 reOPGs, 20 syOPGs und 5 syOPGkontrollen), welche pro StudienprobandInn bewertet wurden. Für die Einzel OPG Interpretation wurde zusätzlich ein separates syOPG ausgewählt.

2.2 Studie

Die erzeugten computergenerierten OPTs wurden nun in einer randomisierten doppelt-verblindeten Studie auf ihre Authentizität überprüft. In Form eines Folgeantrages zur o. g. Genehmigung des OPG-GAN erfolgte ebenfalls die Genehmigung der Studie von der klinischen Ethik-Kommission des Universitätsklinikums Tübingen, konform der Deklaration von Helsinki (231/2022BO2). Die Teilnehmenden an der Umfrage gaben eine informierte, schriftliche Einwilligung.

2.2.1 Ein- und Ausschlusskriterien

Berechtigt zur Teilnahme waren ÄrztInnen in Weiterbildung zur MKG-Chirurgie und FachärztInnen der MKG-Chirurgie, ÄrztInnen in Weiterbildung zur Radiologie und FachärztInnen der Radiologie, Approbierte ZahnärztInnen und Studierende

der Zahnmedizin im klinischen Abschnitt nach Erhalt des Röntgen-Scheins (Nebenanalyse).

2.3 Studienablauf

2.3.1 Durchführung

Eine prospektive Befragung wurde bei 54 approbierten (Zahn)ÄrztInnen (einschließlich ZahnärztInnen, ÄrztInnen in der Ausbildung für Mund-, Kiefer- und Gesichtschirurgie und AssistenzärztInnen für Mund-, Kiefer- und Gesichtschirurgie) und 33 Studierende der Zahnmedizin im klinischen Abschnitt, die ihre Röntgenlizenz bereits erworben hatten, durchgeführt.

Initial erfolgte die mündliche und schriftliche Aufklärung und sowie Unterzeichnung des Einverständnisses der Teilnehmenden.

Der Fragebogen wurde randomisiert und doppelt-verblindet in drei verschiedenen Sequenzen (A, B und C), die dieselben 45 Bilder in unterschiedlicher Reihenfolge enthielten, angewendet. Die Teilnehmenden bewerteten reOPGs und syOPGs auf ihre Authentizität (real oder synthetisch) und beantworteten Fragen zu einem syOPG. Die Bewertung fand immer nur für eine Person und in einem Raum mit radiologischen Beurteilungsbedingungen statt [56]. Auf einem lizenzierten Befundungsmonitor klickten sich die Teilnehmenden durch eine Powerpoint-Datei (Fragebogen) und gaben ihre Antworten in eine Excel-Tabelle auf einem nebenstehenden Monitor (Antwortbogen). Zu Beginn jedes Befragungstages erfolgte die Konstanzprüfung für Befundungsmonitore mittels TG18-OIQ-Test [57].

Zu Beginn wurden die Teilnehmenden zu grundlegenden Informationen befragt: Geschlecht, Altersgruppe, Beruf, gruppierte Berufserfahrung (JAE). Anschließend wurden den Teilnehmern nacheinander die 45 Bilder auf einem Beurteilungsmonitor gezeigt. Die Teilnehmenden hatten je 10 Sekunden Zeit, um ein Bild zu betrachten und dann unbegrenzt Zeit, ihre Bewertung abzugeben (real oder synthetisch). Eine maximale Punktzahl von 40 Punkten (ohne syOPG-Kontrollen) konnte erreicht werden.

Als nächstes wurden die Teilnehmenden gebeten, die folgenden Aspekte zu bewerten: Wie sicher sie bei der Identifizierung von reOPGs aus syOPGs/Selbstbeurteilung waren (Likert-Skala: 0-10), was sie für Indikatoren zur Identifizierung von syOPGs hielten und wie wichtig sie den Zugang zu nicht personalisierten radiologischen Bildern für ihren Beruf bzw. für die Gesellschaft hielten (Likert-Skala: 0-10).

Anschließend wurde den Teilnehmenden ein Einzelbild eines ausgewählten syOPG ohne Zeitlimit gezeigt, welches sie anhand vorgegebener Antwortmöglichkeiten zu folgenden Parametern interpretieren sollten: Bildqualität (Likert-Skala: 0-10), Knochenstruktur und Mineralisierung (physiologisch, sklerotisch, osteoporotisch oder heterogen), ausgewählte Zähne (vorhanden, nicht vorhanden, vorhanden mit Krone, vorhanden mit Füllung, vorhanden mit Artefakt oder Zwischenglied), Anzahl der wahrgenommenen Extraktionsalveolen, Anzahl der wahrgenommenen konservierenden Füllungen, Anzahl der wahrgenommenen apikalen Aufhellungen, Anzahl der wahrgenommenen Wurzelkanal-gefüllten Zähne, Anzahl der wahrgenommenen nicht-erhaltungswürdigen Zähne, Resorption des Alveolarkamms (physiologisch, Oberkiefer, Unterkiefer oder beide Kiefer), rechter und linker Kondylus (rund/glatt oder abgerundet), Knochenkontinuität (durchgängig intakt oder unterbrochen) und Canalis alveolaris inferior beidseits (auf beiden Seiten sichtbar, nur rechts sichtbar, nur links sichtbar oder nicht sichtbar).

2.3.2 Follow up

4-8 Wochen später wurde ein zweiter Durchgang mit 16 der approbierten (Zahn)ÄrztInnen und 13 der Studierenden durchgeführt, um die Test-Retest-Reliabilität zu messen. Die Teilnehmenden wurden erneut gebeten, Bilder von OPGs (real oder synthetisch) zu bewerten. Für diesen zweiten Durchlauf waren 23 Bilder aus dem ersten Erhebungspool zu bewerten (10 reOPGs, 10 syOPGs und 3 syOPG-Kontrollen). Diese wurden wieder in drei verschiedenen Sequenzen (A, B und C) angeordnet.

2.4 Statistik

2.4.1 Fallzahlplanung

Die primären Messgrößen für das Studienergebnis waren die Genauigkeit der Unterscheidung zwischen syOPGs und reOPGs und der für die korrekte Bewertung erreichte Punktwert von maximal 40 Punkten. Die Sensitivität wurde als Maß für die Genauigkeit der Unterscheidung verwendet, ergänzend zusätzlich die Spezifität. Die Bestimmung des Stichprobenumfangs basierte auf der Schätzung der Sensitivität für die Erkennung von syOPGs bzw. reOPGs, bei einem Konfidenzniveau von 95 % mit einem Konfidenzintervall von 0,05 als Schärfe der Schätzung [58]. In Anbetracht des Fall-Kontroll-Ansatzes der Studie mit einer Hälfte syOPGs und einer Hälfte reOPGs und unter der Annahme einer Sensitivität von 80 % für die korrekte Erkennung (gegenüber einer reinen Ratewahrscheinlichkeit von 50 %) ergab dies eine erforderliche Mindestanzahl von 2000 OPGs (jeweils 1000 synthetische und echte). Bei entsprechendem Studiendesign mit 40 Bewertungen pro ProbandInn, erforderte dies mindestens 50 Studienteilnehmende. Unter der Annahme, dass approbierte (Zahn)ÄrztInnen besser in der Lage sein sollten, reOPGs von syOPGs zu unterscheiden, wurde die Anzahl von 2000 Bewertungen bezogen auf approbierte (Zahn)ÄrztInnen als Maßstab für die Authentizitätsprüfung verwendet. Für die ergänzende Analyse wurde eine zusätzliche Gruppe von Studierenden für die Teilnahme rekrutiert. Das Follow up basierte auf einer Unterstichprobe von mindestens 10 % aller Teilnehmer. Siehe Abbildung 10.

2.4.2 Gruppen

Die Teilnehmenden wurden in folgende drei Gruppen unterteilt:

1. Alle Teilnehmende
2. Nach erworbener (zahn)medizinischer Approbation
 - a. Approbierte (Zahn)Ärztinnen

- b. Studierende der Zahnmedizin im klinischen Abschnitt
- 3. Nach Jahren der Arbeitserfahrung (JAE)
 - a. <10 JAE
 - b. >10 JAE

Siehe Abbildung 10.

2.4.3 Auswertung

Entsprechend den Gruppen wurde die statistische Analyse für die gesamte Stichprobe, in Abhängigkeit vom Vorhandensein eines medizinischen Abschlusses (approbierte (Zahn)ÄrztInnen vs. Studierende) und in Abhängigkeit von JAE (weniger oder mehr als 10 Jahre) durchgeführt. Die Ergebnisse der Authentizitätsprüfung wurden in Prozentsätzen (Sensitivität und Spezifität) und Quantitativ (Score) angegeben. Die Bewertung der Bedeutung für Gesellschaft und Beruf wurde mit dem Median und die Einzel OPG Interpretation wurde je nach Modalität mit dem Mittelwert oder dem Median angegeben. Hinsichtlich der Einzel OPG Interpretation wurden gleiche Antworten von >80 % oder einer SD < $\pm 1,5$ als Übereinstimmung gewertet, andernfalls wurde keine Übereinstimmung erreicht. Der Spearman-Rangkorrelationskoeffizient wurde als Maß für die monotone Beziehung zwischen Selbstbewertung und Score berechnet. Die Test-Retest-Reliabilität zwischen primärer Bewertung und Follow up wurde mit dem Cohen-Kappa-Koeffizienten bestimmt. Für die Analyse wurde die Statistiksoftware JMP 16 (SAS Institute, Cary, NC, USA) verwendet. Siehe Abbildung 10.

Material und Methoden

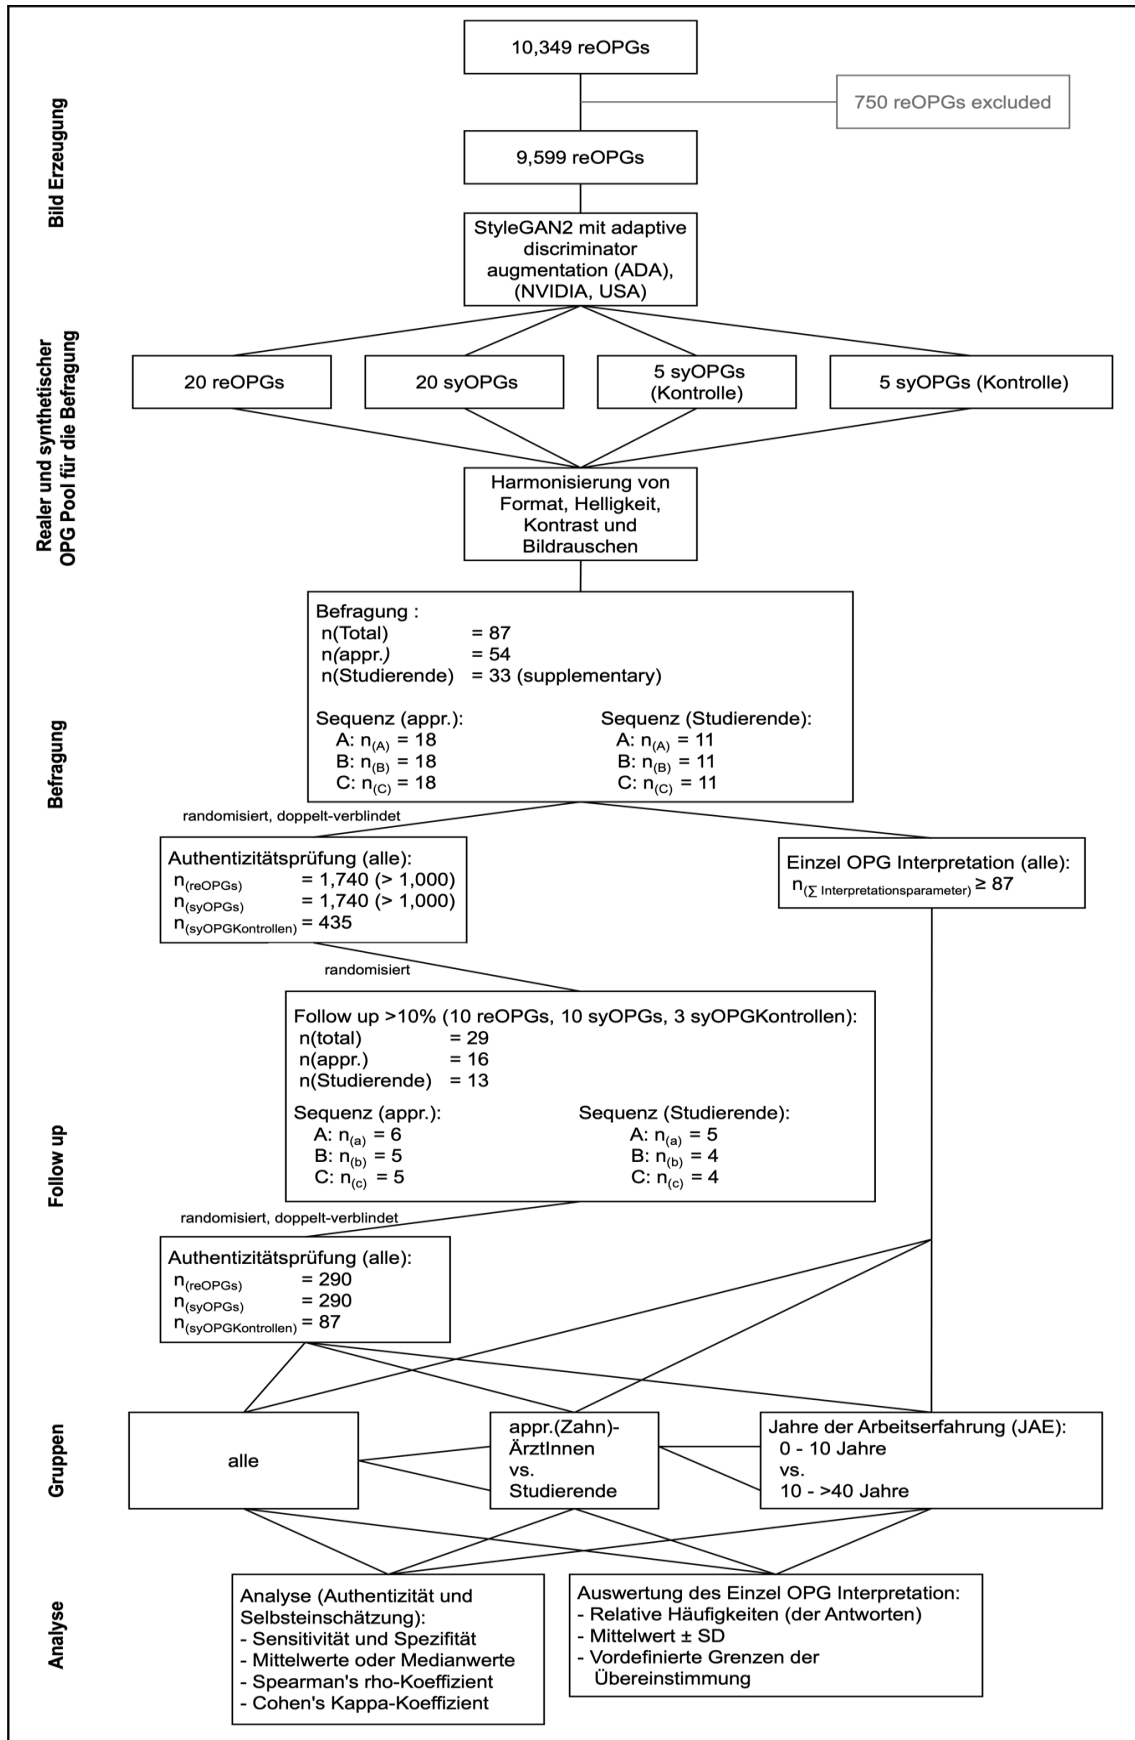


Abbildung 10: Flussdiagramm der Studienplanung.

3 Ergebnisse

3.1 Studienpopulation

Die Studienpopulation bestand aus 87 ProbandInnen. Von allen ProbandInnen waren 54 (62 %) (Zahn)ÄrztInnen und 33 (38 %) Studierende. 55 % der ProbandInnen waren weiblich und 45 % waren männlich. Diverse Teilnehmende waren nicht vorhanden. Siehe Abbildung 11 und 12.

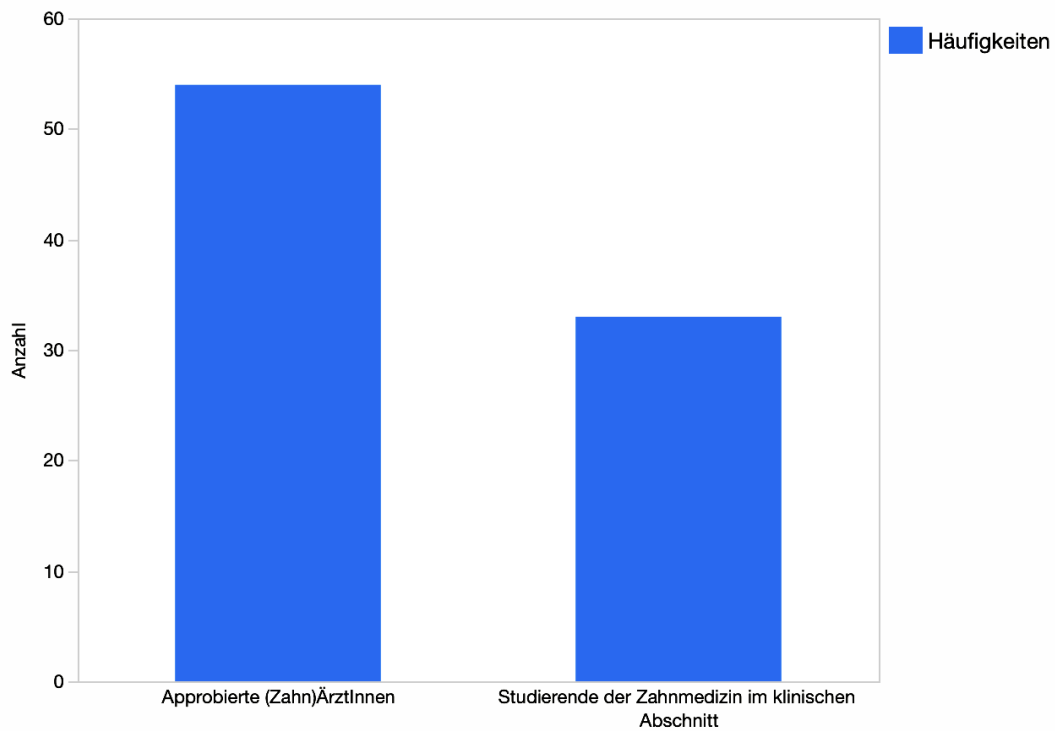


Abbildung 11: Verteilung der Approbierten (Zahn)ÄrztInnen und Studierende der Zahnmedizin im klinischen Abschnitt.

Ergebnisse

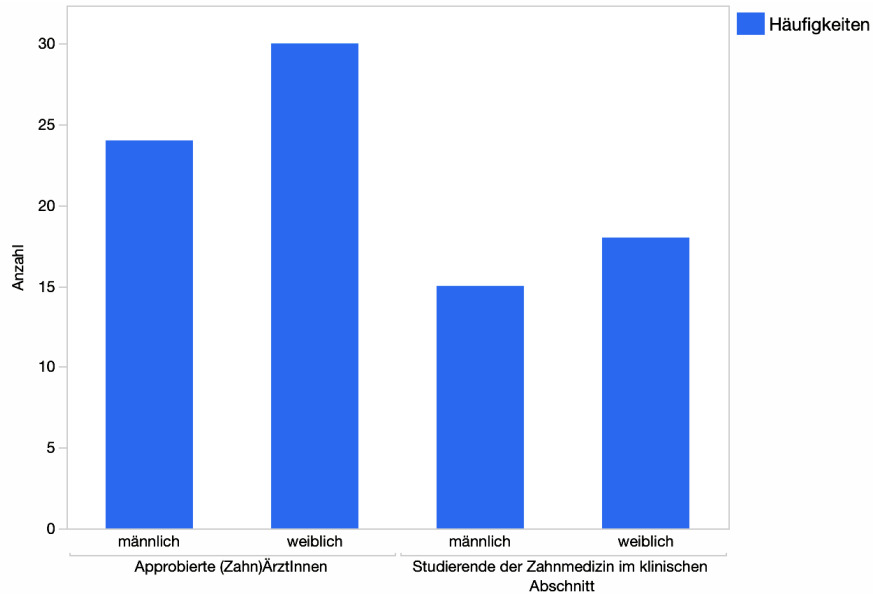


Abbildung 12: Verteilung der Geschlechter nach Approbierten (Zahn)ÄrztInnen und Studierende der Zahnmedizin im klinischen Abschnitt.

Die Altersverteilung der aller ProbandInnen ergab sich wie folgt: 18-25 Jahre: 25 %, 25-35 Jahre: 58 %, 35-45 Jahre: 11 %, 45-55 Jahre: 4 %, 55-65 Jahre: 2 %, und >65 Jahre: 0 %, während sich die Altersverteilung der männlichen ProbandInnen (45 %) wie folgt ergab: 18-25 Jahre: 13 %, 25-35 Jahre: 56 %, 35-45 Jahre: 26 %, 45-55 Jahre: 3 %, 55-65 Jahre: 0 %, und >65 Jahre: 3 %. Siehe Abbildung 13 und 14.




Abbildung 13: Verteilung der Altersgruppen aller Studienteilnehmenden.

Ergebnisse

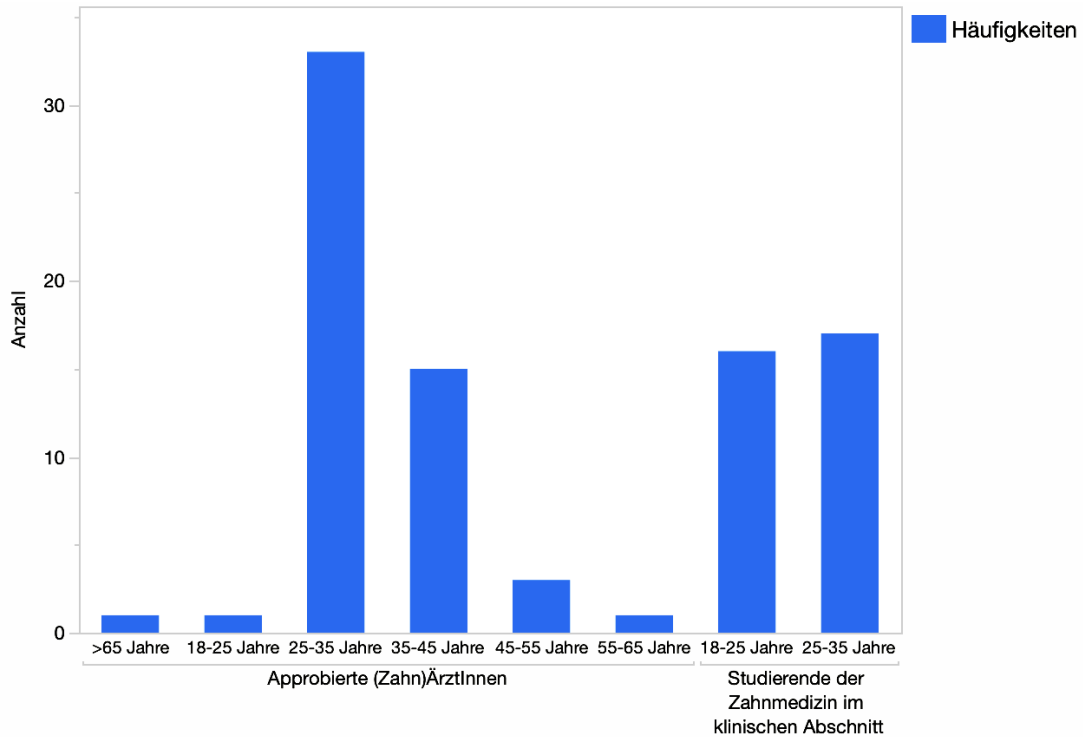


Abbildung 14: Verteilung der Altersgruppen der Approbierten (Zahn)ÄrztInnen und Studierende der Zahnmedizin im klinischen Abschnitt.

Von den approbierten (Zahn)ÄrztInnen waren 32 (59 %) ZahnärztInnen, 9 (17 %) AssistenzärztInnen für MKG-Chirurgie und 9 (17 %) ÄrztInnen in Ausbildung für MKG-Chirurgie und 4 (7 %) OralchirurgInnen. Siehe Abbildung 15.




Abbildung 15: Verteilung der Berufsgruppen innerhalb den approbierten (Zahn)ÄrztInnen.

Ergebnisse

Die Aufteilung nach der Berufserfahrung, aufgeteilt nach JAE (Jahre der Arbeitserfahrung) verteilen sich wie folgt: <1 JAE: 8 %, 1-5 JAE: 54 %, 5-10 JAE: 15 %, 10-20 JAE: 10 % und 20-40 JAE: 13 %. In Bezug auf die Gruppeneinteilung ergeben sich daraus zwei Gruppen auf Grundlage der JAE: 0-10 JAE (n = 41) und >10 JAE (n = 13). Siehe Abbildung 16 und 17.




Abbildung 16: Verteilung der Jahre der Arbeitserfahrung innerhalb den approbierten (Zahn)ÄrztInnen.




Abbildung 17: Verteilung der Jahre der Arbeitserfahrung gemäß den Vergleichsgruppen innerhalb den approbierten (Zahn)ÄrztInnen.

Jede Fragebogensequenz wurde gleichermaßen verwendet (A: 29, B: 29 und C: 29).

3.2 Sensitivität und Spezifität

Insgesamt wurden 3915 Bewertungen abgegeben, davon 1740 zu syOPGs, 1740 zu reOPGs und 435 zu syOPGKontrollen. Auf approbierten (Zahn)ÄrztInnen bezogen, wurden 2430 Beurteilungen abgegeben, davon 1080 zu syOPGs, 1080 zu reOPGs und 270 zu syOPGKontrollen. Siehe Abbildung 26.

Insgesamt lag die Sensitivität für die Erkennung von syOPGs bei 78,2 % und die Spezifität bei 82,5 %. Bei den approbierten (Zahn)ÄrztInnen lag die Sensitivität bei 79,9 % und die Spezifität bei 82,3 %. Bei den Studierenden lag die Sensitivität bei 75,5 % und die Spezifität bei 82,7 %. Hinsichtlich der JAE wies die Gruppe mit 0-10 Jahren JAE eine Sensitivität von 76,8 % und eine Spezifität von 78,5 % auf. Die Gruppe mit mehr als 10 JAE wies dagegen eine Sensitivität von 89,6 % und eine Spezifität von 94,3 % auf. Für alle Gruppen zusammen lag die Sensitivität der sOPGKontrollen bei 92,9 %. Siehe Abbildung 18, 19 und 20.

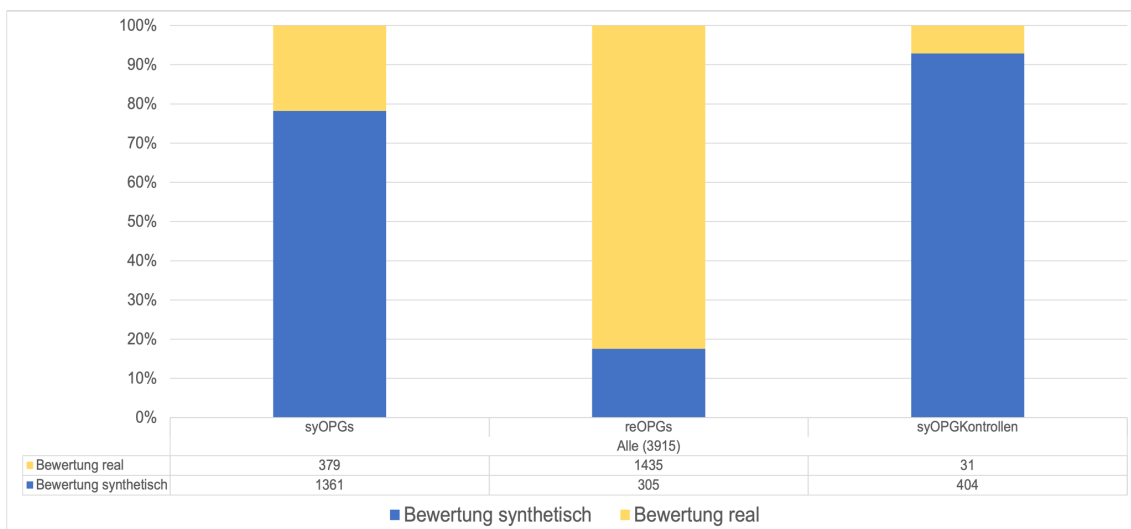


Abbildung 18: Bewertungen der syOPGs, reOPGs und syOPGKontrollen aller Teilnehmenden.

Ergebnisse

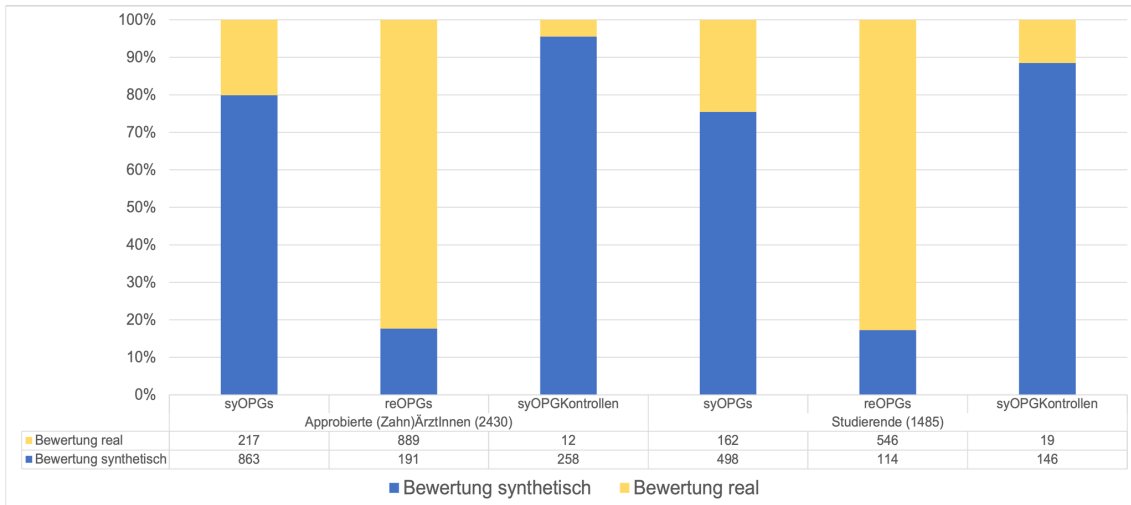


Abbildung 19: Bewertungen der syOPGs, reOPGs und syOPGKontrollen nach approbierten (Zahn)ÄrztInnen und Studierenden.

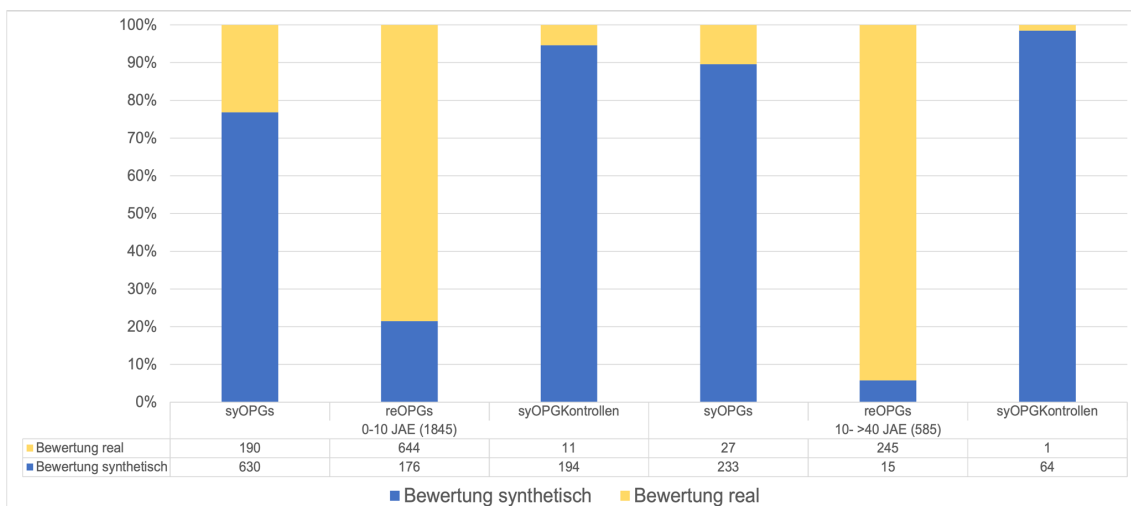


Abbildung 20: Bewertungen der syOPGs, reOPGs und syOPGKontrollen nach Jahren der Arbeitserfahrung.

3.3 Score

Im Durchschnitt wurden $32,1 \pm 5,9$ Punkte erreicht. Approbierten (Zahn)ÄrztInnen erreichten eine mittlere Punktzahl von $32,4 \pm 5,9$ Punkten und Studierende eine mittlere Punktzahl von $31,6 \pm 5,8$ Punkten. Die Gruppe mit 0-10 JAE erreichte eine mittlere Punktzahl von $31,3 \pm 5,8$ Punkten, während die Gruppe mit >10 JAE

Ergebnisse

eine mittlere Punktzahl von $36,8 \pm 3,4$ Punkten hatte. Siehe Abbildung 21, 22 und 23.




Abbildung 21: Ergebnisse des Scores aller Teilnehmenden.

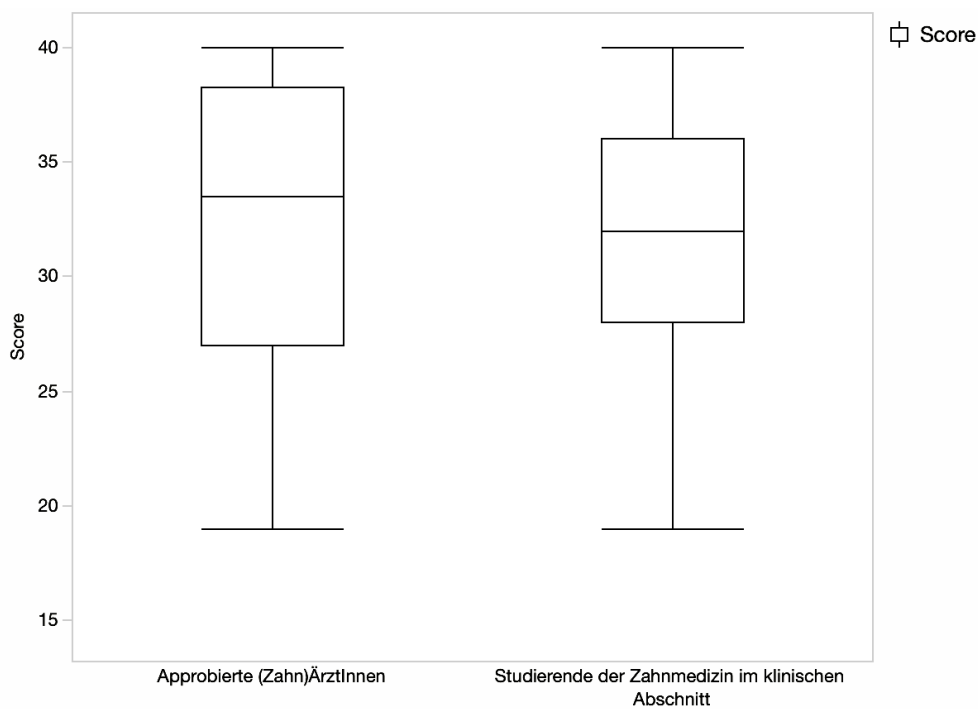


Abbildung 22: Ergebnisse des Scores nach approbierten (Zahn)ÄrztInnen und Studierenden.




Abbildung 23: Ergebnisse des Scores nach Jahren der Arbeitserfahrung.

Da die primären Ergebnisparameter der Studie (Sensitivität, Spezifität und Score) keine nennenswerten, auffälligen Unterschiede zwischen den Gruppen zeigten, wurden die Daten in der weiteren Analyse zusammengefasst.

3.4 Selbstbewertung

Die Teilnehmer bewerteten sich selbst mit einem Median von 6 der Likert-Skala. Die Beziehung zwischen der Selbsteinschätzung und der individuellen Punktzahl wurde mit dem Spearman's rank-order Koeffizienten rho bewertet. Er betrug 0,58 ($p < 0,01$), was auf eine hohe Korrelation der Variablen hinweist. Siehe Abbildung 24.

Ergebnisse




Abbildung 24: Ergebnisse Selbsteinschätzung aller Teilnehmenden (Likert-Skala).

3.5 Subjektive Erkennungsmerkmale

53,1 % nannten die Bildqualität (Graustufen und Bildschärfe), 58,6 % nannten die anatomischen Strukturen (Konfiguration, Wurzeln, Zähne, Zahnschmelz, Pulpakammer, Knochenstruktur, Parodontalräume, hinterer Rand des Unterkiefers, Kiefergelenke, Unterkieferkanal und Wirbelsäule), 25,0 % identifizierten iatrogene Faktoren (Füllungen, Zahnersatz, Metalledarstellung, Wurzelfüllung und Implantate) und 14,6 % identifizierten die Realität/Logik als Unterscheidungsmerkmal. Siehe Abbildung 25.

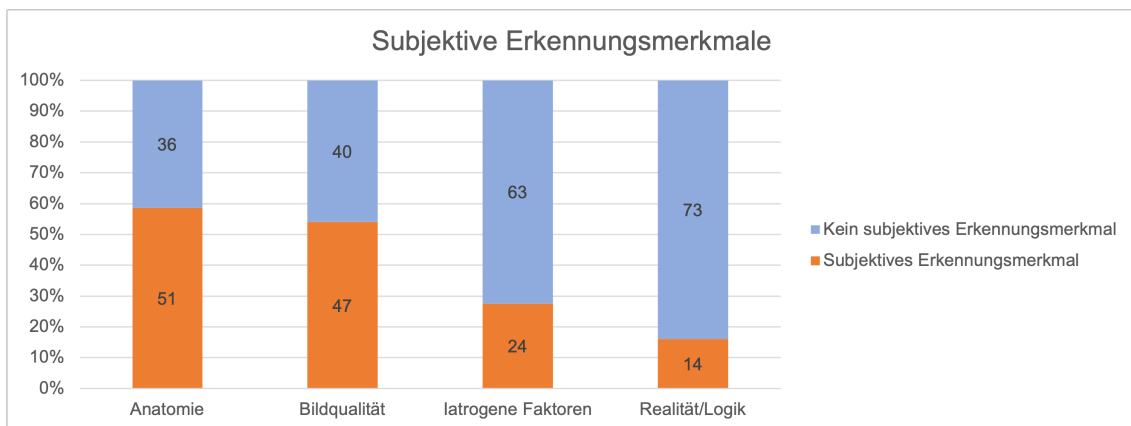


Abbildung 25: Ergebnisse der subjektiven Erkennungsmerkmale aller Teilnehmenden.




Abbildung 26: Beispiele für reale Orthopantomogramme (reOPGs), synthetische Orthopantomogramme (syOPGs) und synthetische Orthopantomogramme - Kontrollen (syOPGKontrollen), die in der Umfrage gezeigt wurden. Die weißen Pfeile markieren offensichtliche anatomische und strukturelle Fehler.

3.6 Einzel OPG-Befundung/Interpretation

In der Einzel OPG Interpretation wurde den Teilnehmenden folgende Abbildung gezeigt. Siehe Abbildung 27.




Abbildung 27: Die Abbildung zeigt das synthetische OPG, welches für die Einzel OPG-Befundung/Interpretation verwendet wurde.

Bei insgesamt 19 zu bewertenden Parametern wurden bei 15 eine Übereinstimmung erreicht. 4 Parameter erbrachten keine Übereinstimmung.

3.6.1 Bildqualität

Die Bewertung der Bildqualität erbrachte einen Median von 6 (Likert-Skala). Siehe Abbildung 28.




Abbildung 28: Ergebnisse der Bewertung der Bildqualität aller Teilnehmenden. „Wie bewerten Sie die Qualität der Abbildung? (0= sehr schlecht; 10=sehr gut)“.

3.6.2 Zähne

3.6.2.1 Zahn 17

Der Zahn 17 wurde wie folgt bewertet: 93,1 % vorhanden mit Krone, 6,9 % vorhanden mit Artefakt. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 29.




Abbildung 29: Ergebnisse zur Interpretation von Zahn 17 aller Teilnehmenden.

3.6.2.2 Zahn 12

Der Zahn 12 wurde wie folgt bewertet: 96,6 % vorhanden, 2,3 % vorhanden mit Artefakt und 1,1 % vorhanden mit Füllung. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 30.




Abbildung 30: Ergebnisse zur Interpretation von Zahn 12 aller Teilnehmenden.

3.6.2.3 Zahn 22

Der Zahn 22 wurde wie folgt bewertet: 6,9 % vorhanden, 1,1 % mit Krone vorhanden, 88,5 % mit Füllung vorhanden und 3,5 % mit Artefakt vorhanden. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 31.

Ergebnisse




Abbildung 31: Ergebnisse zur Interpretation von Zahn 22 aller Teilnehmenden.

3.6.2.4 Zahn 24

Der Zahn 24 wurde wie folgt bewertet: 66,7 % vorhanden mit Füllung, 29,9 % vorhanden mit Artefakt und 3,4 % vorhanden. Damit wurde keine Übereinstimmung erreicht. Siehe Abbildung 32.




Abbildung 32: Ergebnisse zur Interpretation von Zahn 24 aller Teilnehmenden.

3.6.2.5 Zahn 37

Der Zahn 37 wurde wie folgt bewertet: 87,4 % vorhanden mit Krone, 5,7 % vorhanden mit Artefakt und 6,9 % nicht vorhanden. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 33.




Abbildung 33: Ergebnisse zur Interpretation von Zahn 37 aller Teilnehmenden.

3.6.2.6 Zahn 35

Der Zahn 35 wurde wie folgt bewertet: 93,1 % vorhanden mit Krone, 5,7 % Zwischenglied und 1,1 % nicht vorhanden. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 34.

Ergebnisse




Abbildung 34: Ergebnisse zur Interpretation von Zahn 35 aller Teilnehmenden.

3.6.2.7 Zahn 44

Der Zahn 44 wurde wie folgt bewertet: 3,5 % vorhanden, 54 % mit Krone, 4,6 % mit Füllung und 37,9 % mit Artefakt. Damit wurde keine Übereinstimmung erreicht. Siehe Abbildung 35.




Abbildung 35: Ergebnisse zur Interpretation von Zahn 44 aller Teilnehmenden.

3.6.2.8 Zahn 47

Der Zahn 47 wurde wie folgt bewertet: 97,7 % vorhanden mit Krone, 1,1 % vorhanden und 1,1 % nicht vorhanden. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 36.




Abbildung 36: Ergebnisse zur Interpretation von Zahn 47 aller Teilnehmenden.

3.6.3 Knochenstruktur und Mineralisation

Die Knochenstruktur und Mineralisierung wurden wie folgt bewertet: 53,5 % physiologisch, 14,0 % sklerotisch, 2,3 % osteoporotisch und 30,2 % heterogen. Damit wurde keine Übereinstimmung erreicht. Siehe Abbildung 37.

Ergebnisse




Abbildung 37: Ergebnisse zur Interpretation der Knochenstruktur und Mineralisierung aller Teilnehmenden.

3.6.4 Extraktionsalveolen

Die Bewertung der Extraktionsalveolen erbrachten einen Mittelwert von $2,24 \pm$ SD $0,77$. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 38.




Abbildung 38: Ergebnisse zur Interpretation der Extraktionsalveolen aller Teilnehmenden. „Wie viele ehemalige Extraktionsalveolen können Sie sehen?“.

3.6.5 Konservierende Füllungen

Die Bewertung der Konservierung erbrachte einen Mittelwert von $4,24 \pm \text{SD } 1,05$. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 39.




Abbildung 39: Ergebnisse zur Interpretation der konservierenden Füllungen aller Teilnehmenden. „Wie viele Zähne mit RÖV i.S. von konservierenden Füllungen können Sie sehen?“.

3.6.6 Apikale Aufhellungen

Die Bewertung der apikalen Aufhellungen erbrachten einen Mittelwert von $1,39 \pm \text{SD } 1,36$. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 40.




Abbildung 40: Ergebnisse zur Interpretation der apikalen Aufhellungen aller Teilnehmenden. „Wie viele apikale Aufhellungen können Sie sehen?“.

3.6.7 Wurzelkanal-gefüllte Zähne

Die Bewertung der Wurzelkanal-gefüllten Zähne erbrachten einen Mittelwert von $0,10 \pm SD 0,30$. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 41.




Abbildung 41: Ergebnisse zur Interpretation der Wurzelkanal-gefüllten Zähne aller Teilnehmenden. „Wie viele RÖV i.S. von wurzelkanal-gefüllten Zähnen können Sie sehen?“.

3.6.8 Nicht-erhaltungswürdige Zähne

Die Bewertung der nicht-erhaltungswürdigen Zähne erbrachten einen Mittelwert von $0,49 \pm SD 0,95$. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 42.




Abbildung 42: Ergebnisse zur Interpretation der nicht-erhaltungswürdigen Zähne aller Teilnehmenden. „Wie viele (radiologisch) nicht-erhaltungswürdige Zähne können Sie erkennen?“.

3.6.9 Alveolarkammresorption (PA)

Die Resorption des Alveolarkamms wurden wie folgt bewertet: 20,7 % physiologisch, 34,5 % im Oberkiefer, 4,6 % im Unterkiefer und 40,2 % in beiden Kiefern. Damit wurde keine Übereinstimmung erreicht. Siehe Abbildung 43.




Abbildung 43: Ergebnisse zur Interpretation der Alveolarkammresorption aller Teilnehmenden.

3.6.10 Processus condylaris rechts und links

Der rechte Kondylus wurde wie folgt bewertet: 10,3 % rund/glatt und 89,7 % abgerundet. Damit wurde eine Übereinstimmung erreicht. Der linke Kondylus wurde wie folgt bewertet: 87,4 % rund/glatt und 12,6 % abgerundet. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 44.

Ergebnisse




Abbildung 44: Ergebnisse zur Interpretation des rechten und linken Kondylus aller Teilnehmenden.

3.6.11 Knochenkontinuität

Die Knochenkontinuität wurden wie folgt bewertet: 87,2 % durchgehend intakt und 12,8 % unterbrochen. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 45.

Ergebnisse




Abbildung 45: Ergebnisse zur Interpretation der Knochenkontinuität aller Teilnehmenden.

3.6.12 Canalis n. alveolaris inferior

Die Kanäle des Nervus alveolaris inferior wurden wie folgt bewertet: 89,7 % auf beiden Seiten sichtbar, 9,2 % nur auf der rechten Seite sichtbar und 1,1 % nicht sichtbar. Damit wurde eine Übereinstimmung erreicht. Siehe Abbildung 46.




Abbildung 46: Ergebnisse zur Interpretation der Kanäle des Nervus alveolaris inferior aller Teilnehmenden.

3.7 Bedeutung von synthetischen, medizinischen Bildern

3.7.1 Im Hinblick auf den Beruf

Die Bedeutung für den Beruf wurde von allen Teilnehmenden insgesamt im Medianwert mit 7 bewertet (Likert-Skala). Siehe Abbildung 47.




Abbildung 47: Ergebnisse der Bewertung der Bedeutung von synthetischen Bildern für den Beruf aller Teilnehmenden (Likert-Skala, 0=unbedeutend; 10=sehr bedeutend).

3.7.2 Im Hinblick auf die Gesellschaft

Die Bedeutung für den Beruf wurde von allen Teilnehmenden insgesamt im Medianwert mit 4 bewertet (Likert-Skala). Siehe Abbildung 48.




Abbildung 48: Ergebnisse der Bewertung der Bedeutung von synthetischen Bildern für die Gesellschaft aller Teilnehmenden (Likert-Skala, 0=unbedeutend; 10=sehr bedeutend).

3.8 Follow up

Aus der ersten (primären) und zweiten (Follow up) Bewertung ergibt die Analyse des Follow up für die vier möglichen Kombinationen folgende Ergebnisse (primäre Bewertung-Follow up Bewertung): echt-echt: 24,4 %, echt-synthetisch: 20,4 %, synthetisch-echt: 17,7 % und synthetisch-synthetisch: 37,5 %

Die Test-Retest-Reliabilität wurde anhand von Cohen's Kappa gemessen und ergab einen Wert von 0,23. Dies ergibt nach der Interpretation von Landis und Koch eine „fair“ Übereinstimmung [59]. Siehe Abbildung 49.

Ergebnisse

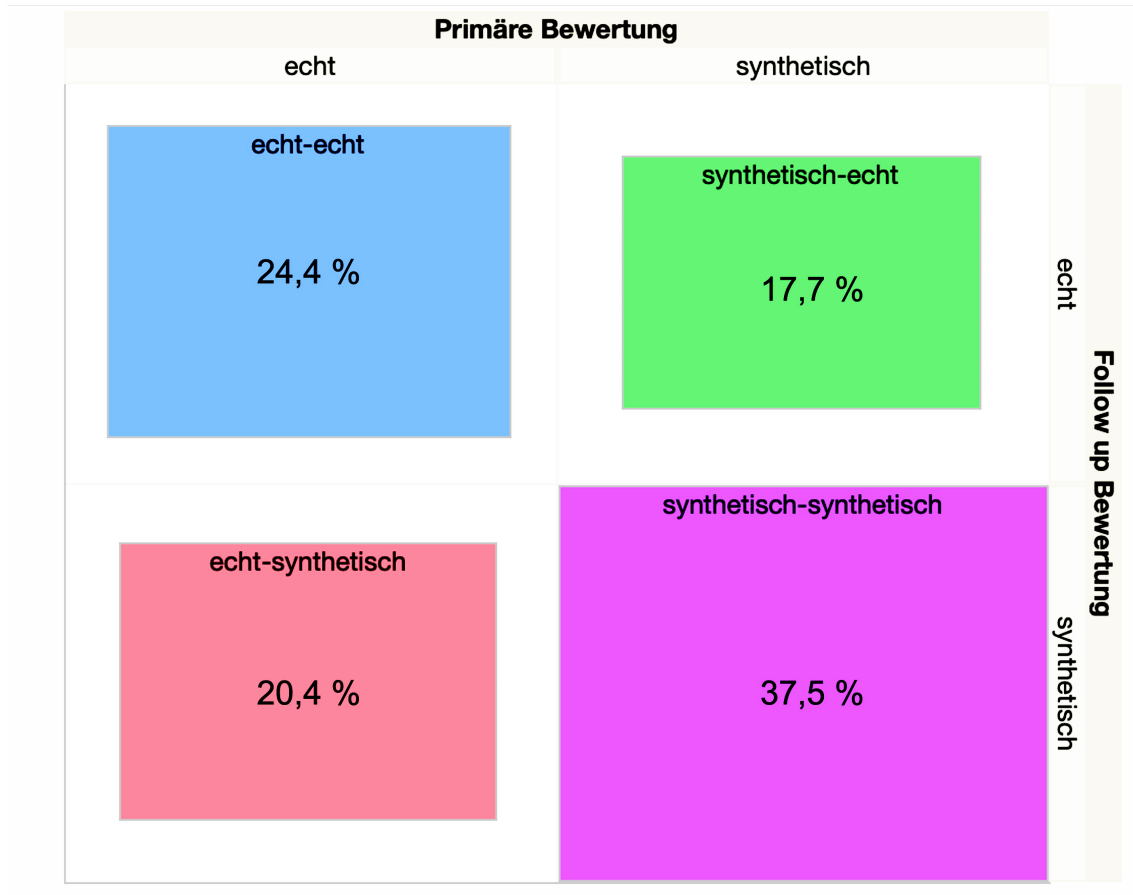


Abbildung 49: Ergebnisse des Follow up nach den vier möglichen Kombinationen (primäre Bewertung-Follow up Bewertung: echt-echt, echt-synthetisch, synthetisch-echt, und synthetisch-synthetisch).

4 Diskussion

Nach dem aktuellen Literaturstand ist diese Studie die Erste, in welcher mittels eines GAN, nach aktuellem Stand der Technik, synthetische OPGs erzeugt und nach ihrer Authentizität evaluiert wurden.

Der gängigen Auffassung nach, dass synthetische, durch GANs erzeugte Abbildungen, frei von personen-bezogenen Daten sind, ist es der Arbeitshypothese folgend gelungen, realistische, synthetische Abbildungen von OPGs zu erzeugen.

4.1 Diskussion von Material und Methode

4.1.1 Allgemeine Problematik

Die korrekte Durchführung und Erstellung eines aussagekräftigen OPG im klinischen Betrieb ist fehleranfällig, selbst unter Zuhilfenahme von technologischen Fortschritten wie Positionierungshilfen und Bildregistrierung. Dies kann auf anatomische oder pathologische Veränderungen oder mangelnde Kooperation zurückzuführen sein. Artefakte und Fehler können in jeder Phase der Erstellung eines OPG auftreten [60].

4.1.2 OPG-GAN

StyleGAN2-ADA© (NVIDIA, USA) ist, zum Zeitpunkt der Erstellung dieser Dissertation, ein GAN auf dem neuesten technischen Stand. Es gibt jedoch weitere, konkurrenzfähige GAN-Architekturen anderer Anbieter. Als bedeutendste Alternative kommt Stable Diffusion© (Stability AI LTD, UK) in Betracht.

Stable Diffusion© nutzt den Ansatz der Diffusion, um schrittweise ein Bild zu erstellen. Diffusion basiert auf der rückwärtsgerichteten Diffusion von Daten, bei

der das Modell versucht, den ursprünglichen Zustand wiederherzustellen, indem es die Daten schrittweise mit Rauschen überlagert. Stable Diffusion© hingegen verwendet denselben Mechanismus, jedoch mit geringerem Rauschen, um eine höhere Stabilität und reproduzierbarere Ergebnisse zu erzielen. Dabei werden Daten Schicht für Schicht hinzugefügt, wodurch ein immer detaillierteres Bild entsteht.

Im Gegensatz dazu generiert StyleGAN2-ADA© zuerst eine Latent-Space-Darstellung und wandelt diese dann in ein Bild um, was zu hochqualitativen und realistisch aussehenden Bildern führt. Die Wahl des geeigneten Modells hängt von den spezifischen Anforderungen und Daten ab. Beide Modelle sind GANs, die mithilfe künstlicher Intelligenz Bilder generieren. Die Unterschiede liegen jedoch in ihrer Trainingsmethode und im Umgang mit Daten.

Stable Diffusion© ist darauf spezialisiert, hochauflösende Bilder zu erzeugen. Es nutzt Diffusionsprozesse, indem es rauschhafte Informationen anwendet, um die Bildqualität zu verbessern. StyleGAN2-ADA© bietet Funktionen zur Kontrolle des Aussehens von Bildern und verwendet eine Methode namens Noise-Modulation, um Details in den generierten Bildern hervorzuheben.

Letztlich hängt die Wahl des GAN von den Anforderungen ab. Stable Diffusion© arbeitet schneller und benötigt weniger Ressourcen als StyleGAN2-ADA©, während StyleGAN2-ADA© eine höhere Bildqualität liefert und spezifische Bildmerkmale kontrolliert [61].

4.1.3 Studie (Stärken und Limitationen)

Eine Stärke der Studie ist ihr Design und der Umfang, in dem die statistische Überprüfung der syOPGs durchgeführt wurde. Dies ermöglicht, die Ergebnisse der Studie mit hoher Genauigkeit zu bekräftigen.

Obwohl in der Studie weitaus mehr Bilder zum Trainieren von StyleGAN2-ADA© als in vergleichbaren Studien (s.u) verwendet wurden, besteht die größte Schwäche der Studie in der Verwendung einer weiterhin eingeschränkten Bildanzahl von 9599 realen Bildern für das Training. Es kann davon ausgegangen werden, dass mehr reale Bilder zu qualitativ besseren

synthetischen Bildern geführt hätten. Auch wenn es in der Medizin den Grundsatz gibt, dass es nichts gibt, was es nicht gibt, sollten logische Fehler wie in den syOPG-Kontrollen immer vermieden werden, wenn das Ziel ist, realistische Bilder zu erzeugen.

4.2 Diskussion der Ergebnisse

4.2.1 Studienpopulation

Die Verteilung von männlichen und weiblichen Teilnehmenden ist als ausgeglichen anzusehen. Die Gruppe der approbierten (Zahn)ÄrztInnen setzen sich hauptsächlich aus ZahnärztInnen zusammen. Dies erklärt sich daraus, da andere Fachweiterbildungen wie Oralchirurgie oder Kieferorthopädie, sowie die approbierte ÄrztInnen in Weiterbildung zur Mund-, Kiefer- und Gesichtschirurgie seltener an Kliniken vertreten sind. Gleichermaßen gilt dies für erfahrener (Zahn)ÄrztInnen, mit über zehn JAE, da diese mit steigender Erfahrung die Kliniken teilweise verlassen und jüngere (Zahn)ÄrztInnen, im Rahmen ihrer Assistenzzeit, noch vermehrt in der Klinik arbeiten.

4.2.2 Sensitivität, Spezifität und Score

Mit insgesamt 54 approbierten (Zahn)ÄrztInnen wurde der Vergleichsmaßstab von mindestens 1000 abgegebenen Bewertungen für je reOPGs und syOPGs erreicht. Damit sind die Ergebnisse als signifikant zu werten. Unter Einbezug der statistischen Planung, die eine Sensitivität von 80% als Referenzwert für eine suffiziente Erkennung von syOPGs voraussetzt, zeigen die Studienergebnisse, dass syOPGs nicht eindeutig von reOPGs unterschieden werden können. Einzig die Gruppe mit über zehn JAE war in der Lage eine ausreichende Sensitivität zu erreichen, jedoch wurde auch hier nicht alle synthetischen Bilder als solche identifiziert. Im Hinblick auf die Zielsetzung kann die Hypothese, dass es möglich ist, durch GANs authentische syOPGs zu erzeugen, angenommen werden.

4.2.3 Selbstbewertung

In der primären Untersuchung ergab sich eine starke Korrelation zwischen der subjektiv empfundenen Selbsteinschätzung und dem erreichten Score. Mit dem Ergebnis der empfundenen Selbsteinschätzung im Median von 6 auf der Likert-Skala kann dies als mittelmäßige subjektive Einschätzung der eigenen Genauigkeit der Erkennung interpretiert werden. In Relation zu der erreichten Sensitivität erklärt dies die starke Korrelation. Dies bekräftigt die eigene Unsicherheit der Teilnehmenden.

4.2.4 Subjektive Unterscheidungsmerkmale

Vornehmlich gaben Studienteilnehmende an, synthetische Bilder aufgrund einer unphysiologischen Anatomie bzw. der Bildqualität erkannt zu haben. Zu beachten ist, dass Studienteilnehmende nie wussten, welche Bilder echt oder synthetisch waren. Im Hinblick darauf, dass synthetische Bilder nicht suffizient erkannt wurden, könnte es sein, dass die Nennung der unphysiologischer Anatomie als Erkennungsmerkmal auf die syOPG-Kontrollen zurückzuführen ist, da diese eindeutig unphysiologische Anatomien aufwiesen. Bezüglich der Bildqualität kann angenommen werden, dass diese Verbesserungspotential bietet.

4.2.5 Einzel OPG-Befundung

Bei der Einzelbildanalyse kann die Bildqualität als mittelmäßig bezeichnet werden. Mit einer erzielten Übereinstimmung bei 15 der 19 untersuchten Punkte wurde eine insgesamt zufriedenstellende Übereinstimmung erreicht. Die Differenzen in der Bewertung der Knochenstruktur und der Mineralisierung kann darauf zurückgeführt werden, dass es sich hierbei um die feinsten Strukturen in einem OPG handelt und die Detailschärfe von syOPGs an diesem gewissen Punkt zum aktuellen Zeitpunkt technisch begrenzt war. Im Fall von Zahn 24 und 44 könnten ebenfalls Mängel in der Bildqualität ursächlich sein. Was die

Einschätzung der Resorption des Alveolarkamms betrifft, ist zu beachten, dass selbst im klinischen Alltag zur PA-Diagnostik die Messung bzw. Schätzung der Alveolarkammresorption radiologisch ungenau ist und stark vom Betrachtenden abhängt [62].

4.2.6 Follow up

Obwohl die Selbsteinschätzung eine hohe Korrelation mit der erzielten Punktzahl aufwies, ergab die Nachuntersuchung nur eine „fair“ Übereinstimmung. Dies deutet darauf hin, dass die Teilnehmenden ihre Einschätzungen zum selben OPG-Bild in der Nachuntersuchung auf einmal änderten. Im Gegensatz zur Selbsteinschätzung ergeben sich damit nun nachweislich Unsicherheiten und Inkonsistenzen in der Bewertung der Bilder. Damit kann die Hypothese, dass syOPGs nicht oder nur schwer von reOPGs unterschieden werden können erhärtet werden.

4.2.7 Einschätzung der Wichtigkeit von synthetischen, medizinischen Bildern für den Beruf und Bedeutung für die Gesellschaft

Die Ergebnisse zu den Einschätzungen der Bedeutung für den eigenen Beruf und die Gesellschaft unterscheiden sich. Während die Bedeutung für den Beruf als „eher Wichtig“ interpretiert werden kann, kann die Bedeutung für die Gesellschaft als eher „weniger Wichtig“ verstanden werden. Hierzu ist anzumerken, dass die Erzeugung von synthetischen Bildern ein verhältnismäßig neues und sehr abstraktes Verfahren ist. Der Mehrwert von synthetischem Bildmaterial ist unter Umständen für die praktische Anwendung nicht sofort ersichtlich oder stößt sogar auf Kritik, da es letztendlich nicht real ist und nur versucht echte Daten nachzuahmen. Andererseits könnte abgeleitet, dass Defizite im Verständnis für das Potential des Verfahrens vorhanden sind. Dies begründet sich darin, dass die Anwendung von GANs zur Verbesserung von radiologischen Bildern, keine abstrakte Vorstellung für die Zukunft ist, sondern diese dazu bereits angewendet werden [63]. Im Hinblick auf die Bedeutung für

die Gesellschaft sollte einbezogen werden, dass die Vorteile für den Beruf, sowie Forschung, Klinik und Lehre letztlich die Versorgung von Patienten verbessern kann und damit einen Nutzen für die Gesellschaft haben kann.

4.3 Einfluss der Studie in die aktuelle Forschung

Vergleichbare Studien, in denen GANs zur Erstellung von medizinischen Bildern eingesetzt und diese Bilder auf Qualität und Authentizität überprüft wurden, sind nur begrenzt vorhanden. In einer Studie von S. Chen et al. wurden aus 6058 realen Funduskopie-Bildern 880 synthetische Fundoskopie-Bilder erstellt. Von diesen wurden allerdings nur 20 von vier Experten bewertet [64]. In einer Studie von M. Tian et al. gelang es, Gesichtsbilder mit Hilfe von StyleGAN2-ADA© zu verändern und dabei zahnähnliche Merkmale zu erhalten. Dies stellt einen bedeutenden Ansatz zur Konstruktion von synthetischen Fällen ohne persönliche Daten dar. In diesem Fall wurden 30 synthetische und reale Bilder zur Bewertung herangezogen und von fünf Experten beurteilt [65]. In einer anderen Studie von S. Yang et al. wurden mit StyleGAN2-ADA©, welches mit 1456 realen Bildern trainiert wurde, 50 synthetische Zahnfilme erzeugt. Diese wurden von zwei Radiologen bewertet. Es wurde unter anderem vom fehlenden Details in den synthetischen Bildern berichtet [66].

Im Kontext dieser Publikationen konnte die Studie dieser Dissertation mit dem Training von StyleGAN2-ADA© mit einem Datensatz von 9599 Bildern sowie der umfangreichen Authentizitätsprüfung von 87 Bewertenden und insgesamt 3915 Bewertungen eine vergleichbare Qualität erreichen. Zudem unterstützten die Ergebnisse ebenfalls die Translation von computer-generierten, synthetischen Bildern von der Machbarkeitsanalyse in medizinische Anwendungen.

Der Einsatz synthetischer Bilder in der medizinischen Bildgebung stellt eine zunehmend bedeutende Entwicklung dar, die auf die wachsende Nachfrage nach hochqualitativen, annotierten Bilddatensätzen für die Entwicklung und Schulung medizinischer KI-Modelle reagiert. Ein zentraler Ansatz hierbei ist die Verwendung von generativen Modellen, insbesondere durch Techniken wie

latente Diffusionsmodelle. Diese Modelle, wie das "RoentGen"-Modell von Stanford, erlauben die Synthese hochgradig detaillierter und realistisch wirkender Brust-Röntgenaufnahmen. Das Besondere an diesen Modellen ist ihre Fähigkeit, spezifische radiologische Merkmale wie Lungenödeme oder Pneumothorax gezielt darzustellen, indem sie auf medizinische Fachsprache abgestimmte Textbeschreibungen als Eingabe verwenden. Diese neue Art der textgesteuerten Bildsynthese schafft flexible Möglichkeiten, Bilddatensätze individuell anzupassen und erweitert so das Potenzial für die klinische Anwendbarkeit [67].

Diese stellt im Hinblick auf diese Arbeit eine mögliche Folgeanwendung dar. Die Nutzung synthetisch generierter Bilder in der Zahnmedizin, insbesondere von OPG, wirft spezifische Fragen auf, die mit der klinischen Präzision und Anwendbarkeit solcher Bilder zusammenhängen. Die genaue und zuverlässige Synthese solcher Aufnahmen stellt daher besondere Anforderungen an die verwendeten Modelle [67].

Allerdings gibt es bei der Nutzung synthetischer Bilder auch Herausforderungen und Einschränkungen. Die Studie von Gao et al. befasst sich umfassend mit den sogenannten „Modell-Halluzinationen“ in generativen Modellen. Diese Arbeit untersucht, wie große Vision-Language-Modelle, die synthetische medizinische Bilder verwenden, dazu neigen, Bildmerkmale zu generieren, die in den Originaldaten nicht vorhanden waren, oft als unrealistische oder klinisch irrelevante Details. Ein zentrales Problem sind „latente Halluzinationen“ – Merkmale, die zwar plausibel erscheinen, jedoch keine tatsächlichen klinischen Informationen repräsentieren und damit potenziell die Diagnosequalität gefährden. Diese Untersuchung zeigt, dass Halluzinationen besonders bei generierten Bildinhalten auftreten, die Eigenschaften enthalten, die den zugrunde liegenden Trainingsdaten fremd sind, oder wenn die Text-Bild-Korrelation nicht exakt stimmt. Solche Phänomene könnten sich negativ auswirken, wenn synthetische Bilder zur Schulung medizinischer KI-Systeme genutzt werden, was den Einsatz generativer Modelle in sicherheitskritischen Anwendungen einschränkt. Die Studie schlägt vor, zusätzliche Validierungsmethoden und

„semantische Filter“ anzuwenden, um die Konsistenz und Authentizität der synthetischen Bilder zu verbessern, bevor diese in klinischen oder diagnostischen Kontexten verwendet werden [68].

Neben den technischen Herausforderungen gibt es ethische Überlegungen, die im Kontext synthetischer medizinischer Bilder aufkommen. Die Frage, ob und wie synthetische Daten in klinische Schulungen und Entscheidungsfindungen integriert werden dürfen, wirft wichtige ethische und rechtliche Fragen auf. Forscher fordern daher Transparenz bei der Kennzeichnung synthetischer Bilder und klare Richtlinien, um sicherzustellen, dass solche Daten nicht missbräuchlich verwendet werden und dass die diagnostische Integrität gewahrt bleibt. Diese ethischen Aspekte werden zunehmend diskutiert, da synthetische Bilder in der medizinischen Forschung und Diagnostik eine immer größere Rolle spielen [69].

Die Anwendung synthetischer Daten reicht weit über die reine Generierung von Röntgenbildern hinaus und umfasst neben andere Bildgebungsverfahren wie MRT und CT auch die Möglichkeit der Veränderung bestehender Bilder (Augmentation). Modelle wie GANs und Variational Autoencoders (VAEs) haben sich besonders in der Datenaugmentation bewährt. Diese synthetisch veränderten Datensätze sind wertvoll für die Schulung von Diagnosealgorithmen, da sie sowohl die Vielfalt als auch die Menge verfügbarer Trainingsbilder erhöhen und somit die Leistung von Klassifizierungsmodellen verbessern. Beispiele hierfür aus Sizikova et al. [69] sind die Studien Lewis et al. [70] oder Pezeshk et al. [71], in den bestehende Lungen CT-Bilddaten mit synthetischen Bilddaten augmentiert wurden.

4.3.1 Personen-bezogene Daten in OPGs

Um zu diskutieren, wie viele personenbezogene Daten in OPGs enthalten sind, sollte vorher abgeschätzt werden, wie einzigartig die individuellen Attribute sein können. Hierzu dient die folgende Veranschaulichung, in der dargestellt wird, wie die Kombination an Attributen eines Zahnes in einem OPG sein könnten und im

Weiteren, wie sie durch eine vereinfachte mathematische Näherung betrachtet werden könnten. Siehe Abbildung 50.

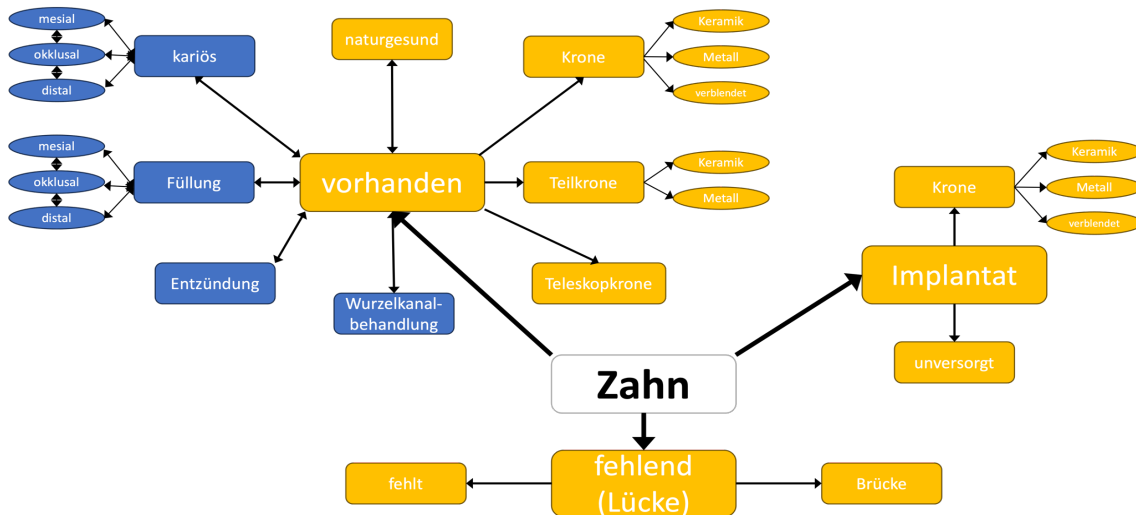


Abbildung 50: Mögliche Kombinationen für sichtbare Zahnattribute in einem OPG für eine vereinfachte mathematische Näherung. Gelbe Kästen = oder-Bedingung, blaue Kästen = und/oder-Bedingungen.

Abbildung 50 setzt die vereinfachte Annahme voraus, dass ein OPG 32 Positionen besitzt, in denen ein Zahn entweder „vorhanden“ oder „fehlend“ oder „Implantat“-versorgt sein kann. Ist der Zahn vorhanden kann er „Naturgesund“ oder mit „Krone“ oder „Teilkrone“ oder „Teleskopkrone“ versorgt sein, oder er ist „karös“ und/oder besitzt „Füllungen“ und/oder ist „entzündet“ und/oder ist „wurzelkanalbehandelt“. „Karös“ und/oder „Füllung“ kann „mesial“ und/oder „okklusal“ und/oder „distal“ vorliegen. Die Krone kann aus „Keramik“ oder „Metall“ oder „verblendet“ gestaltet sein. Die Teilkrone kann aus „Keramik“ oder „Metall“ gestaltet sein. Ist der Zahn fehlend, „fehlt“ er oder ist ersetzt durch eine „Brücke“. Liegt ein Implantat vor, kann dieses „unversorgt“ oder durch eine „Krone“ versorgt sein. Die Krone kann aus „Keramik“ oder „Metall“ oder „verblendet“ gestaltet sein.

Um die Menge der möglichen Zahnattribute zu beschreiben, werden erst Gruppen von Eigenschaften beschrieben, die sich gegenseitig ausschließen und diese werden dann entweder durch Vereinigungen (=Anzahl addiert sich) oder durch Kombinationen (Anzahl multipliziert sich) zusammengefügt.

Kategorie 'Vorhanden'

Erst werden die verschiedenen Möglichkeiten in Untergruppen zerlegt, sodass Werte innerhalb jeder Gruppe sich gegenseitig ausschließen:

$$M_{\text{Zustand}} = \{\text{Gesund, Krone (Keramik), Krone (Metall), Krone (Verblendet), Teilkrone (Keramik), Teilkrone (Metall), Teleskop}\}$$

$$M_{\text{Kariös}} = \{\text{Nein, Mesial, Distal, Okklusal}\}$$

$$M_{\text{Füllung}} = \{\text{Nein, Mesial, Distal, Okklusal}\}$$

$$M_{\text{Entzündung}} = \{\text{Ja, Nein}\}$$

$$M_{\text{Wurzelkanalbehandlung}} = \{\text{Ja, Nein}\}$$

Jeder Zahn aus der Kategorie 'Vorhanden' hat einen Wert pro obiger Menge. Formal kann die Gesamtmenge also mit dem kartesischen Produkt 'x' beschrieben werden als:

$$M_{\text{Vorhanden}} = M_{\text{Zustand}} \times M_{\text{Kariös}} \times M_{\text{Füllung}} \times M_{\text{Entzündung}} \times M_{\text{Wurzelkanalbehandlung}}$$

Die Anzahl der Elemente in einem kartesischen Produkt ist das Produkt der Elemente pro Menge, also:

$$\begin{aligned} |M_{\text{Vorhanden}}| &= |M_{\text{Zustand}}| \cdot |M_{\text{Kariös}}| \cdot |M_{\text{Füllung}}| \cdot |M_{\text{Entzündung}}| \cdot |M_{\text{Wurzelkanalbehandlung}}| \\ &= 7 \cdot 4 \cdot 4 \cdot 2 \cdot 2 \\ &= 448. \end{aligned}$$

Kategorie 'Fehlend'

$$M_{\text{Fehlend}} = \{\text{Fehlt, Brücke (Keramik), Brücke (Metall), Brücke (Verblendet)}\}$$

$$|M_{\text{Fehlend}}| = 4.$$

Kategorie 'Implantat'

$$M_{\text{Implantat}} = \{\text{Unversorgt, Krone (Keramik), Krone (Metall), Krone (Verblendet)}\}$$

$$|M_{\text{Implantat}}| = 4$$

Pro Zahn

Die drei obigen Kategorien schließen sich gegenseitig aus, also ist die Gesamtmenge der Möglichkeiten pro Zahn die (disjunkte) Vereinigung der Mengen:

$$M_{\text{Zahn}} = M_{\text{Vorhanden}} \uplus M_{\text{Fehlend}} \uplus M_{\text{Implantat}}$$

Die Anzahl der Elemente einer disjunkten Vereinigung ist die Summe der Elemente pro Menge, also:

$$\begin{aligned} |M_{\text{Zahn}}| &= |M_{\text{Vorhanden}}| + |M_{\text{Fehlend}}| + |M_{\text{Vorhanden}}| \\ &= 448 + 4 + 4 \\ &= 456 . \end{aligned}$$

Pro Person

Wenn jeder der 32 Zähne unabhängig voneinander ist, ergibt sich wieder das kartesische Produkt:

$$M_{\text{Gesamt}} = \underbrace{M_{\text{Zahn}} \times \cdots \times M_{\text{Zahn}}}_{32 \text{ mal}}$$

und die Anzahl der Elemente ist wieder das Produkt der einzelnen Anzahlen:

$$\begin{aligned} |M_{\text{Gesamt}}| &= \underbrace{|M_{\text{Zahn}}| \cdots |M_{\text{Zahn}}|}_{32 \text{ mal}} \\ &= |M_{\text{Zahn}}|^{32} \\ &= 456^{32} \\ &\approx 10^{85} . \end{aligned}$$

Um die Zahl von 10^{85} theoretisch möglichen Kombinationsmöglichkeiten fassbar zu machen, kann man sie in Relation zu der Zahl der geschätzten Atome im Universum setzen, diese beträgt im Allgemeinen schätzungsweise 10^{78} bis 10^{82} und ist damit kleiner [72].

Die Veranschaulichung bietet nun eine Grundlage dafür, einschätzen zu können, in welchem Maß und auf welche Weise OPGs personenbezogene Daten verschlüsseln. Es lässt sich ableiten, dass die individuelle Verteilung von Attributen in OPGs ein extrem breites Spektrum an unterschiedlichen Zahn-Kombinationen ermöglicht. In diesem Sinne ist zu argumentieren, dass OPGs in der Lage sind, in Bezug auf Individuen, personen-bezogene Daten zu verschlüsseln und die Identifikation von Personen eindeutig zu ermöglichen. Hierzu entgegen steht, dass bestimmte Varianten gehäuft in der Bevölkerung vorkommen, bspw. vollbezahnte, naturgesunde Kiefer oder unbezahnte Kiefer [73]. Hinsichtlich dieser Individuen können aber andere Merkmale herangezogen

werden, wie bspw. der Abstand der Foraminae mentales oder die Kondylenform, auch wenn sich diese dann nicht mehr mit bloßem Auge klinisch differenzieren lassen.

Es sollte auch diskutiert werden, inwieweit sich OPG von anderen Röntgenbildern wie bspw. Röntgenbildern der Hand, dem Knie oder des Sprunggelenks unterscheidet. Auf diesen Bildmodalitäten sind Attribute lange nicht im gleichen Maß codierbar und einfach klinisch erkennbar wie in OPGs. Mögliche Attribute wären makroskopische Anomalien wie bspw. das Fehlen von makroskopischen anatomischen Strukturen (z.B. Finger). Mögliche weitere Ansatzpunkte wären auch die Anlage oder nicht-Anlage von akzessorischen Knochen, Osteosynthesematerial oder diverse anatomische Anomalien. Diese sind jedoch nicht oder nur mithilfe genauer Untersuchung detektierbar. Die Knochenmatrix und Trabekelstruktur sollte nicht herangezogen werden, da sich diese mit der Zeit durch das Knochenremodeling ändert [74].

Die Studie von Ali et al. untersucht Herausforderungen und Entwicklungen bei der Generierung synthetischer medizinischer Bilder mit Diffusionsmodellen, speziell unter Berücksichtigung von Datenschutzrisiken. Sie ist ein Beispiel für die Herausforderungen und das Potenzial, das Diffusionsmodelle in der medizinischen Bildgenerierung bieten, und fördert weitere Forschung, um die Anwendbarkeit und Sicherheit solcher Modelle zu verbessern. Diffusionsmodelle, die für die Erstellung realistischer medizinischer Bilder wie Röntgenbilder und CT-Scans eingesetzt werden, bergen das Risiko, vertrauliche Details aus den Trainingsdaten zu reproduzieren, was bei Patientendaten zu potenziellen Datenschutzproblemen führen kann. Um dies zu verhindern, nutzen neuere Studien optimierte Versionen dieser Modelle, die sicherstellen sollen, dass synthetische Bilder sich ab einer vorgegebenen Schwelle deutlich von Originalbildern unterscheiden, was die Wiedererkennung realer Patientendaten verhindern soll [75].

Auch Gao et al. betont im Beitrag zur 32. ACM International Conference on Multimedia 2024, dass bei generativen Modellen die Gefahr besteht, dass Daten aus dem Training unbeabsichtigt wieder gegeben werden, was potenziell zu

Datenschutzproblemen führt, insbesondere wenn Patientendaten verwendet wurden [68].

Um dem entgegenzutreten werden Ansätze zur Erhöhung der Bildvariabilität erforscht, damit diese synthetischen Daten die diagnostische Generalisierungsfähigkeit auf verschiedene demografische Gruppen erweitern.

Die Studien von Shi et al. und Khader et al. im Jahr 2023 untersuchen sowohl den Datenschutz als auch die Variabilität in synthetischen Datensätzen, um eine bessere Generalisierbarkeit in klinischen Anwendungen zu erreichen [76, 77]:

Shi et al. entwickelt eine Methode, bei der Diffusionsmodelle zur Erzeugung synthetischer medizinischer Bilddaten genutzt werden, ohne dass Patientendaten reproduziert werden. Durch den Einsatz von „Differential Privacy“ und Variabilitätstechniken wird das Modell darauf trainiert, medizinische Bilder zu erzeugen, die den Datenschutz gewährleisten und gleichzeitig die Generalisierbarkeit verbessern [76].

Khader et al. konzentriert sich in einer Studie auf die Anwendung von Diffusionsmodellen zur Generierung dreidimensionaler medizinischer Bilddaten, insbesondere MRT- und CT-Bilder. Das Modell ermöglicht eine variantenreiche Bilderzeugung und zielt darauf ab, diagnostische Algorithmen zu unterstützen, die über verschiedene demografische und klinische Merkmale hinweg anwendbar sind. Diese Arbeit betont die Bedeutung synthetischer Daten zur Erhöhung der Datenvielfalt, ohne reale Patientendaten zu gefährden [77].

Beide Studien zeigen wichtige Fortschritte in der synthetischen Bildgebung und adressieren dabei sowohl Datenschutzfragen als auch die Notwendigkeit einer großen Vielfalt an Trainingsdaten, um KI-Modelle in der Medizin weiter zu verbessern.

4.4 Urheberrecht von synthetischen OPGs

Das Urheberrecht tritt unmittelbar in Kraft, sobald ein Werk geschaffen wird. Dabei ist laut der Rechtsprechung des Europäischen Gerichtshofs entscheidend, dass es sich um eine „eigene geistige Schöpfung“ eines Menschen handelt, die die Persönlichkeit des Urhebers widerspiegelt, indem sie dessen „freie kreative

Entscheidungen“ zum Ausdruck bringt. Geschützt im Sinne des Urheberrechtsgesetzes sind somit ausschließlich persönliche geistige Schöpfungen von Menschen. Inhalte, die ausschließlich auf Basis künstlicher Intelligenz (KI) generiert werden, genießen hingegen keinen urheberrechtlichen Schutz. Dies liegt daran, dass die Arbeitsweise der KI sich der Kontrolle des Nutzers entzieht und der erzeugte Inhalt nur bedingt steuerbar ist. Die daraus resultierenden Texte oder Bilder haben somit keinen Urheber im rechtlichen Sinne. Eine Urheberschaft des Nutzers der KI könnte allenfalls dann in Betracht gezogen werden, wenn die Software lediglich als Hilfsmittel dient und ihr Einsatz im Entstehungsprozess des Werkes von untergeordneter Bedeutung ist. Im Zusammenhang mit KI greift das Urheberrecht also nur dann, wenn die Grundlage für das neu geschaffene Werk ursprünglich von einem Menschen stammt. Es muss daher im Einzelfall genau geprüft werden, ob ausreichender Einfluss auf die konkrete Gestaltung des Werkes durch den Menschen besteht oder nicht. [78]

Mit diesem Hintergrund ist zu argumentieren, dass synthetische OPGs ohne durch Menschen eigens vorgenommene „schöpferische“ Modifikationen keinem urheberrechtlichen Schutz unterliegen. Dieser könnte entsprechend dann vorliegen, wenn die Bilder nachträglich bewusst verändert werden. Eine genaue Abgrenzung in welchem Ausmaß dies erfolgen muss, ist zum aktuellen Zeitpunkt nicht klar definiert.

In praktischer Anwendung ist damit nachteilig, dass synthetische OPGs nicht ohne eigenständigen Aufwand schützbar sind. Andererseits bietet dies auch den Vorteil, dass synthetische OPGs barrierefrei durch andere Nutzende verwendet werden können.

4.5 Zusammenfassendes Anwendungskonzept von synthetischen, radiologischen Bildern in der medizinischen Klinik, Forschung und Lehre

Mit einer Open-Source-Bereitstellung von diagnostisch markierten synthetischen radiologischen Bildern in großen Mengen könnte die Trainings- und Diagnosequalität neuronaler Netze verbessert werden, was eine KI-gestützte Bildanalyse und -berichterstattung ermöglicht. Darüber hinaus könnten datenschutzkonforme Bilder für Forschung, klinische Anwendungen und Ausbildung usw. bereitgestellt werden. Die Nutzenden könnten von einer geplanten, künftig frei zugänglichen Datenbank oder Bildschmiede mit synthetischen radiologischen Bildern profitieren.

Künftige, synthetisch aus GANs generierte Daten sollten jedoch weiterhin kritischen Qualitätskontrollen durch Experten unterzogen werden, um realistische Erkenntnisse durch Lernen zu gewinnen, selbst wenn das Lernen auf künstlichen Daten beruht. Außerdem sollten synthetische Daten sowie Ergebnisse und Erkenntnisse, die unter Verwendung synthetischer Daten gewonnen wurden, eindeutig gekennzeichnet werden, um Transparenz der Informationsquelle und Wissenserzeugung zu gewährleisten.

Zudem könnten zukünftige Studien größere Trainingsätze und weiter verbesserte GANs verwenden, um noch authentischere Bilder zu erzeugen, die eine visuelle Unterscheidung nahezu unmöglich machen. Darüber hinaus könnten Methoden entwickelt werden, um bestimmte gewünschte Bildattribute oder Pathologien auf Befehl in authentische synthetische Bilder umzuwandeln.

Die kontinuierliche Weiterentwicklung synthetischer Bildgenerierungsmodelle deutet darauf hin, dass diese Technologie das Potenzial hat, das Feld der medizinischen Bildgebung grundlegend zu transformieren. Durch ständige Verbesserungen in der Feinabstimmung und Anpassung an die medizinische Domäne wird angestrebt, synthetische Bilder mit einer Präzision zu erzeugen, die der Qualität realer klinischer Aufnahmen immer näherkommt. Dies könnte langfristig dazu führen, dass synthetische Bilddatensätze eine zentrale Rolle in

der medizinischen Ausbildung und in der Weiterentwicklung diagnostischer Algorithmen spielen, was die Qualität und Reichweite der Gesundheitsversorgung positiv beeinflussen könnte.

Abschließend lässt sich zusammenfassen, dass mit der Studie ein umfassender Test durchgeführt wurde, um zu zeigen, dass GANs synthetische radiologische Bilder erzeugen können, die selbst von medizinischem Fachpersonal manchmal nicht von echten radiologischen Bildern unterschieden werden können und somit als authentisch gelten. Dies ermöglicht ihren Einsatz in der Forschung, bei klinischen Anwendungen, in der Ausbildung sowie die Skalierung bestehender Datensätze, wobei die Freiheit von personenbezogenen Informationen gewahrt bleibt, so dass sie barrierefrei genutzt und/oder verändert werden können.

5 Zusammenfassung

Generative Adversarial Networks (GANs) können synthetische, humane Bilder erzeugen, die völlig frei von personenbezogenen Daten sind. In der medizinischen Klinik, Forschung und Lehre ist die Verarbeitung von Gesundheitsdaten in der Regel nur mit wirksamer, informierter Einwilligung zulässig. Da dies mit logistischen Herausforderungen verbunden ist, können synthetische Daten von großem Wert sein. Zahnärztliche Panoramaröntgenbilder, oder auch Orthopantomogramme (OPG) genannt, sind aufgrund ihres hohen Standardisierungsgrades bei gleichzeitig hohem Anteil an individuellen, personenbezogenen Daten ein geeigneter Anwendungsfall zur Erzeugung von synthetischem Daten.

Ziel dieser Studie ist es, eine Datenbank von synthetischen OPGs (syOPGs), welche frei von personenbezogenen Daten sind, zu erstellen und diese auf ihre Authentizität zu überprüfen, indem ermittelt wird, inwieweit diese von realen OPGs (reOPGs) durch medizinisches Fachpersonal unterschieden werden können.

Mit StyleGAN2-ADA[©] (adaptive discriminator augmentation) von NVIDIA[©] (USA) wurden aus 9.599 reOPGs ein OPG-StyleGAN trainiert und aus diesem syOPGs erzeugt. Diese wurde dann in einer Umfrage von 54 approbierten (Zahn)ÄrztInnen und 33 Zahnmedizinierenden beurteilt. 45 radiologische Bilder (20 reOPGs, 20 syOPGs und 5 syOPG-Kontrollen) wurden entweder als real oder synthetisch bewertet. Anschließend interpretierten sie ein syOPG-Einzelbild nach 19 verschiedenen Parametern, wobei eine Übereinstimmung bei einer Antwort von >80% oder einer Standardabweichung < $\pm 1,5$ als Übereinstimmung gewertet wurde, andernfalls wurde es als keine Übereinstimmung gewertet. Zusätzlich bewerteten die Teilnehmenden die Wichtigkeit von synthetischen radiologischen Bildern für den Beruf (Likert-Skala: 0-10) und für die Gesellschaft (Likert-Skala: 0-10). Zur Überprüfung der Test-Retest-Zuverlässigkeit wurde ein Follow-up mit >10 % aller Teilnehmer durchgeführt.

Insgesamt lag die Sensitivität der Erkennung von syOPGs bei 78,2 % und die Spezifität bei 82,5 %. Bei den approbierten (Zahn)ÄrztInnen lag die Sensitivität bei 79,9 % und die Spezifität bei 82,3 %. Bei den Studierenden lag die Sensitivität bei 75,5 % und die Spezifität bei 82,7 %. Bei der Einzel-syOPG-Interpretation wurde bei 15 von 19 Parametern eine Übereinstimmung erreicht. Die Bedeutung für den Beruf wurde im Median mit 7 und die Bedeutung für die Gesellschaft im Median mit 4 bewertet. Die Test-Retest-Reliabilität, gemessen mit Cohen's Kappa, ergab einen Wert von 0,23.

Die Studie stellt eine umfassende Machbarkeitsuntersuchung dar, die zeigt, dass GANs synthetische radiologische Bilder erzeugen können, die teilweise selbst von medizinischem Fachpersonal nicht von echten radiologischen Bildern zu unterscheiden sind und somit als authentisch gelten können. Ein Einsatz in der medizinischen Klinik, Forschung und Lehre ist somit in Zukunft realistisch. Es ermöglicht auch die Skalierung bereits bestehender Datensätze. Während echte OPGs viele personenbezogene Daten enthalten, sind syOPGs frei davon, was ihre barrierefreie Nutzung und/oder Veränderung außerhalb des Datenschutzes ermöglicht.

Synthetische Bilder haben das Potential für die universitäre Lehre, Forschung und Klinik sowie in der Patientenaufklärung verwendet werden zu können, ohne auf patientenbezogene Daten angewiesen zu sein. Sie können auch dazu verwendet werden, bestehende Trainingsdatensätze zu erweitern, um die Genauigkeit von KI-basierten Diagnosesystemen zukünftig zu verbessern. Die Studie unterstützt damit den klinische Informationsumgang sowie die diagnostische und therapeutische Entscheidungsfindung.

6 Literatur- und Abbildungsverzeichnis

Literaturverzeichnis

1. (DPMA), D.P.-u.M. 100. Todestag von Wilhelm Conrad Röntgen. 09.04.2024 Available from: <https://www.dpma.de/dpma/veroeffentlichungen/meilensteine/erfindungen/mitgeschichten/roentgen-strahlen/index.html>.
2. Fuhrmann, A., *1 Geschichte und Entwicklung des zahnärztlichen Röntgens*, in *Zahnärztliche Radiologie*. 2013, Georg Thieme Verlag KG: Stuttgart.
3. parodontitis.com. *Zahnfilm (Einzelzahnrontgen)* Available from: <https://www.parodontitis.com/diagnostik-der-parodontitis/roentgendiagnostik/zahnfilm-einzelzahnroentgen.html>.
4. Dieter Beyer, M.H., Friedhelm Zanella, Klaus Bohndorf, Eberhard Walter, Alfons Hüls, *Röntgendiagnostik von Zahn- und Kiefererkrankungen: Ein klinisch-radiologisches Konzept*. 2013: p. 7–13.
5. ZULAUF, A.F., *PANORANHC X-BAY APPARATUS*. 1920.
6. Numata, H., *Consideration 01' the parabolic radiography 01' dental arch*. J. Shimi zu Studies, 1989. **10**.
7. Scheutzel, P., *En twick lung der zahnärztli chen Panoramaröntgenaufnahmeverfahren*. Zahnärztl. Mitt., 1989. **79**.
8. Paatero, Y.V., *The use of a mobile source of light in radiography*. Acta radiol, 1948. **29**(3): p. 221-7.
9. Paatero, Y.V., *A new tomographical method for radiographing curved outer surfaces*. Acta radiol, 1949. **32**(2-3): p. 177-84, illust.
10. Heckmann, K., *Die Röntgenperspektive und ihre Umwandlung durch eine neue Aufnahmetechnik*. Fortschr. Röntgenstr., 1939. **60**.
11. Düker, J., *1.2 Panoramaschichtverfahren*, in *Röntgendiagnostik mit der PANORAMASCHICHTAUFNAHME*. 2000, Georg Thieme Verlag KG: Stuttgart.
12. Mattilda, K., *Panorama-Röntgenverfahren, Rückblick und Ausblick*. Jung. T. (Hrsg.): *Panorama-Röntgenographie*. Hüthig, Heidelberg, 1984: p. 10.
13. Sklavos, A., et al., *The panoramic dental radiograph for emergency physicians*. Emergency Medicine Journal, 2019. **36**(9): p. 565-571.
14. Paatero, Y.V., *Pantomography in theory and use*. Acta radiol, 1954. **41**(4): p. 321-35.
15. Subbulakshmi, A.C., et al., *Positioning errors in digital panoramic radiographs: A study*. Journal of Orofacial Sciences, 2016. **8**(1): p. 22-26.
16. Asha, V.K.S., M.; Shalma, H.; Sushmini, H., *Positioning errors in digital panoramic radiographs- A retrospective analysis*. Int. J. Adv. Res. Ideas Innov. Technol., 2018: p. 517–521.

17. Boeddinghaus, R. and A. Whyte, *Dental panoramic tomography: an approach for the general radiologist*. Australas Radiol, 2006. **50**(6): p. 526-33.
18. Izzetti, R., et al., *Basic Knowledge and New Advances in Panoramic Radiography Imaging Techniques: A Narrative Review on What Dentists and Radiologists Should Know*. Applied Sciences, 2021. **11**(17): p. 7858.
19. Hughes, T., *Book review: Oral radiology: principles and interpretation, 7th edition*. British Dental Journal, 2014. **217**(2): p. 62-62.
20. Schiff, T., et al., *Common positioning and technical errors in panoramic radiography*. J Am Dent Assoc, 1986. **113**(3): p. 422-6.
21. Akarslan, Z.Z., et al., *Common errors on panoramic radiographs taken in a dental school*. J Contemp Dent Pract, 2003. **4**(2): p. 24-34.
22. Pfeiffer, P., S. Bewersdorf, and P. Schmage, *The effect of changes in head position on enlargement of structures during panoramic radiography*. Int J Oral Maxillofac Implants, 2012. **27**(1): p. 55-63.
23. Rondon, R.H., Y.C. Pereira, and G.C. do Nascimento, *Common positioning errors in panoramic radiography: A review*. Imaging Sci Dent, 2014. **44**(1): p. 1-6.
24. Peretz, B., M. Gotler, and I. Kaffe, *Common errors in digital panoramic radiographs of patients with mixed dentition and patients with permanent dentition*. Int J Dent, 2012. **2012**: p. 584138.
25. White, S.C.a.P., M.J. , *Oral Radiology: Principles and Interpretation*. 2014. **7th Edition**: p. 41-63.
26. Rozylo-Kalinowska, I., *Technical Errors and Artefacts in Dental Radiography*, in *Imaging Techniques in Dental Radiology: Acquisition, Anatomic Analysis and Interpretation of Radiographic Images*. 2020, Springer International Publishing: Cham. p. 79-125.
27. Perschbacher, S., *Interpretation of panoramic radiographs*. Aust Dent J, 2012. **57 Suppl 1**: p. 40-5.
28. Costa, J.F.d., *Orthopantomography*, in *Radiopedia*. 2023.
29. parodontitis.com. OPG: Orthopantomogramm, Panorama-Schichtaufnahme des Kiefers. Available from: <https://www.parodontitis.com/diagnostik-der-parodontitis/roentgendiagnostik/opg-orthopantomogramm-panorama-roentgen.html>.
30. Schneider, M., *Radiologische Bildgebung in der Zahnheilkunde*. Zahnmedizin up2date, 2013. **7**(05): p. 477-501.
31. Rushton, V.E. and K. Horner, *The use of panoramic radiology in dental practice*. J Dent, 1996. **24**(3): p. 185-201.
32. Carcev, K., *KRITISCHE EVALUIERUNG DER ZAHNACHSBESTIMMUNG AM ORTHOPANTOMOGRAMM*. 2009, Medizinischen Universität Wien.
33. Stichaller, M., *FORENSISCHE ZAHNMEDIZIN - IDENTIFIZIERUNG UNBEKANNTER TOTER Eine Recherche und Methodenanalyse*, in *Universitätsklinik für Zahn-, Mund- und Kieferheilkunde, Klinische Abteilung für Zahnersatzkunde*. 2010, Medizinischen Universität Graz. p. 39.

34. Rötzscher, K., *Forensische Zahnmedizin*, ed. A. 1. 2003: BoD – Books on Demand.
35. Manigandan, T., et al., *Forensic radiology in dentistry*. Journal of Pharmacy and Bioallied Sciences, 2015. 7(Suppl 1): p. S260-S264.
36. Münster, F.Z. *Radiologischer Kurs I*. Available from: <https://zahnmedizin.ms.de/studium/6-semester/radiologischer-kurs-i/>.
37. Nicholson, C.V., *A Beginner's Guide to Important Topics in AI, Machine Learning, and Deep Learning.*, in *A.I. Wiki*. 2023: pathmind.
38. IBM. *Was ist ein neuronales Netz?* 2024; Available from: <https://www.ibm.com/de-de/topics/neural-networks>.
39. Oppermann, A. *Aktivierungsfunktionen in neuronalen Netzen: Sigmoid, tanh, ReLU*. Available from: <https://artemoppermann.com/de/aktivierungsfunktionen/>.
40. Han, S.H., et al., *Artificial Neural Network: Understanding the Basic Concepts without Mathematics*. Dement Neurocogn Disord, 2018. 17(3): p. 83-89.
41. Nicholson, C.V., *A Beginner's Guide to Generative AI*, in *A.I. Wiki*. 2023: pathmind.
42. Hansen, C. *Generative adversarial networks explained*. 20 July 2022; Available from: <https://developer.ibm.com/articles/generative-adversarial-networks-explained/>.
43. aws. *Was ist ein GAN?* ; Available from: <https://aws.amazon.com/de/what-is/gan/>.
44. Situ, Z., et al., *Automated Sewer Defects Detection Using Style-Based Generative Adversarial Networks and Fine-Tuned Well-Known CNN Classifier*. IEEE Access, 2021. 9: p. 59498-59507.
45. *DSGVO Personenbezogene Daten*. intersoft consulting; Available from: <https://dsgvo-gesetz.de/themen/personenbezogene-daten/>.
46. Europäisches Parlament, R.d.E.U., *Datenschutz-Grundverordnung*. 27. April 2016: Europäisches Parlament and Rat der Europäischen Union.
47. *Was sind personenbezogene Daten?* Europäische Kommission 2024; Available from: https://commission.europa.eu/law/law-topic/data-protection/reform/what-personal-data_de#:~:text=Personenbezogene%20Daten%20sind%20alle%20Informationen,oder%20identifizierbare%20lebende%20Person%20beziehen.
48. *Art. 1 DSGVO Gegenstand und Ziele*. intersoft consulting; Available from: <https://dsgvo-gesetz.de/art-1-dsgvo/>.
49. ISiCO. *Das neue Patientendaten-Schutz-Gesetz (PDSG): Mehr Datensicherheit für das digitale Gesundheitswesen*. Available from: <https://www.isico-datenschutz.de/blog/patientendaten-schutz-gesetz-gesundheitswesen/>.
50. Unternehmensberatung, H. *Datenmissbrauch - Was kann passieren, wenn Sie gegen den Datenschutz verstoßen?* ; Available from: <https://www.hub24.de/datenschutz/datenmissbrauch/>.
51. Deutschland, B., *Bundesdatenschutzgesetz (BDSG)*. 2017.
52. aws. *Was sind synthetische Daten?* ; Available from: <https://aws.amazon.com/de/what-is/synthetic-data/>.

53. Eckhardt, S., Lüttel, S., *Geistiges Eigentum und KI Welche Herausforderungen stellen sich für das Urheberrecht*. IntellectualProperty, 2023. **4**: p. 3-5.
54. Kaulartz, M., T. Braegelmann, and T. Ammann, *Rechtshandbuch Artificial Intelligence und Machine Learning*. Vol. 1. 2020: C.H. Beck. XXXVII.
55. Gausling, T., *Künstliche Intelligenz und DSGVO*. MIT Technology Review, 2018: p. 59.
56. Normung, D.I.f., *Prozesse in der Radiologie, in Teil 1: Befundung eines bildgebenden oder bildgestützten Verfahrens* 2018, DIN Standards Committee Radiology
57. Normung, D.I.f., *Sicherung der Bildqualität in röntgendiagnostischen Betrieben, in Teil 157: Abnahme- und Konstanzprüfung an Bildwiedergabesystemen in ihrer Umgebung* 2022: DIN-Normenausschusses Radiologie (NAR).
58. Hajian-Tilaki, K., *Sample size estimation in diagnostic test studies of biomedical informatics*. J Biomed Inform, 2014. **48**: p. 193-204.
59. Landis, J.R. and G.G. Koch, *The measurement of observer agreement for categorical data*. Biometrics, 1977. **33**(1): p. 159-74.
60. Różyło-Kalinowska, I., *Panoramic radiography in dentistry*. Clinical Dentistry Reviewed, 2021. **5**(1): p. 26.
61. Arnold, V. *KI Bilder Tools Vergleiche „Erkunde den Unterschied: Stabile Diffusion vs. StyleGAN“*
. 2023; Available from: <https://neuroflash.com/de/blog/erkunde-den-unterschied-stabile-diffusion-vs-stylegan/>.
62. Sairam, V. and G. Puri, *Comparison of measurements of alveolar bone levels by clinical, bitewing and panoramic radiography*. Journal of Indian Academy of Oral Medicine and Radiology, 2011. **23**(4): p. 543-547.
63. Ahmad, W., et al., *A new generative adversarial network for medical images super resolution*. Scientific Reports, 2022. **12**(1): p. 9533.
64. Chen, J.S., et al., *Deepfakes in Ophthalmology: Applications and Realism of Synthetic Retinal Images from Generative Adversarial Networks*. Ophthalmol Sci, 2021. **1**(4): p. 100079.
65. Mingchuan Tian, W.W.L., Kelvin Weng Chiong Foong, Eugene Loh, *Generative Adversarial Networks for Dental Patient Identity Protection in Orthodontic Educational Imaging*. arXiv, 2023. **Computer Science, Computer Vision and Pattern Recognition**.
66. Yang, S., et al., *Evaluating the performance of generative adversarial network-synthesized periapical images in classifying C-shaped root canals*. Sci Rep, 2023. **13**(1): p. 18038.
67. Bluethgen, C., et al., *A vision–language foundation model for the generation of realistic chest X-ray images*. Nature Biomedical Engineering, 2024.
68. Gao, Y., et al., *AIGCs Confuse AI Too: Investigating and Explaining Synthetic Image-induced Hallucinations in Large Vision-Language Models*, in *Proceedings of the 32nd ACM International Conference on Multimedia*. 2024, Association for Computing Machinery: Melbourne VIC, Australia. p. 9010–9018.

69. Sizikova, E., et al., *Synthetic data in radiological imaging: current state and future outlook*. BJR|Artificial Intelligence, 2024. **1**(1).
70. Lewis, A., *Improving Tuberculosis (TB) Prediction using Synthetically Generated Computed Tomography (CT) Images*. 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW), 2021: p. 3258-3266.
71. Pezeshk, A., et al., *Seamless Insertion of Pulmonary Nodules in Chest CT Images*. IEEE Trans Biomed Eng, 2015. **62**(12): p. 2812-2827.
72. Baker, H. *How many atoms are in the observable universe?* 2021; Available from: <https://www.livescience.com/how-many-atoms-in-universe.html>.
73. Tóth, U. and O. Gyulavári, *Distribution of number of teeth in an adult population*. Hum Hered, 1969. **19**(5): p. 581-8.
74. Hadjidakis, D.J. and Androulakis, I., *Bone remodeling*. Ann N Y Acad Sci, 2006. **1092**: p. 385-96.
75. Ali, H., S. Murad, and Z. Shah, *Spot the fake lungs: Generating Synthetic Medical Images using Neural Diffusion Models*. 2022.
76. Yongyi Shi, W.X., Chuang Niu, Christopher Wiedeman, Ge Wang, *Enabling Competitive Performance of Medical Imaging with Diffusion Model-generated Images without Privacy Leakage*. arXiv, 2024. **2301.06604**(physics.med-ph).
77. Khader, F., et al., *Denoising diffusion probabilistic models for 3D medical image generation*. Scientific Reports, 2023. **13**(1): p. 7303.
78. Urheberrecht, K.I.u., *Künstliche Intelligenz und Urheberrecht*, in - *Fragen und Antworten* -. März 2024, Bundesministerium der Justiz. p. 3.

Abbildungsverzeichnis

		Seite
Abbildung 1:	Schematische Ansicht der Beziehungen zwischen der Röntgenquelle, dem Patienten, dem sekundären Kollimator und dem Bildempfänger.	13
Abbildung 2:	Richtungen des Röntgenstrahls in verschiedenen Intervallen	14
Abbildung 3:	Drehzentrums während des Belichtungszyklus	15
Abbildung 4:	Verviewepocs 2D Panorama-Einheit	16
Abbildung 5:	Anordnung der Gesichtsschädelknochen auf einem Panoramabild	19
Abbildung 6:	Identifizierung der anatomischen Strukturen auf einem Panoramaröntgenbildes	19
Abbildung 7:	Neuronen in künstlichen neuronalen Netzen	24
Abbildung 8:	Generator-Netzwerk (G) und das Diskriminator-Netzwerk (D) in einem generativen adversarialen Netzwerks	27
Abbildung 9:	Generator und Diskriminator von StyleGAN2-ADA©	38
Abbildung 10:	Flussdiagramm der Studienplanung	44
Abbildung 11:	Verteilung der Approbierten (Zahn)ÄrztInnen und Studierende der Zahnmedizin im klinischen Abschnitt	45
Abbildung 12:	Verteilung der Geschlechter	46
Abbildung 13:	Verteilung der Altersgruppen aller Studienteilnehmer	46
Abbildung 14:	Verteilung der Altersgruppen nach Approbation	47
Abbildung 15:	Verteilung der Berufsgruppen	47
Abbildung 16:	Verteilung der Jahre der Arbeitserfahrung innerhalb den approbierten (Zahn)ÄrztInnen	48
Abbildung 17:	Verteilung der Jahre der Arbeitserfahrung gemäß	

	innerhalb den approbierten (Zahn)ÄrztInnen	48
Abbildung 18:	Bewertungen der syOPGs, reOPGs und syOPGKontrollen aller Teilnehmenden	49
Abbildung 19:	Bewertungen der syOPGs, reOPGs und syOPGKontrollen nach approbierten (Zahn)ÄrztInnen und Studierenden	50
Abbildung 20:	Bewertungen der syOPGs, reOPGs und syOPGKontrollen nach Jahren der Arbeitserfahrung	50
Abbildung 21:	Score Ergebnisse aller Teilnehmenden	51
Abbildung 22:	Score Ergebnisse nach approbierten (Zahn)ÄrztInnen und Studierenden	51
Abbildung 23:	Score Ergebnisse nach Jahren der Arbeitserfahrung	52
Abbildung 24:	Selbsteinschätzung aller Teilnehmenden (Likert-Skala)	53
Abbildung 25:	Subjektive Erkennungsmerkmale aller Teilnehmenden	53
Abbildung 26:	Beispiele für reOPGs, syOPGs und syOPGKontrollen	54
Abbildung 27:	Einzel OPG-Befundung	55
Abbildung 28:	Bewertung der Bildqualität	56
Abbildung 29:	Interpretation von Zahn 17	56
Abbildung 30:	Interpretation von Zahn 12	57
Abbildung 31:	Interpretation von Zahn 22	58
Abbildung 32:	Interpretation von Zahn 24	58
Abbildung 33:	Interpretation von Zahn 37	59
Abbildung 34:	Interpretation von Zahn 35	60
Abbildung 35:	Interpretation von Zahn 44	60

Abbildung 36:	Interpretation von Zahn 47	61
Abbildung 37:	Interpretation der Knochenstruktur und Mineralisierung	62
Abbildung 38:	Interpretation der Extraktionsalveolen	62
Abbildung 39:	Interpretation der konservierenden Füllungen	63
Abbildung 40:	Interpretation der apikalen Aufhellungen	64
Abbildung 41:	Interpretation der Wurzelkanal-gefüllten Zähne	64
Abbildung 42:	Interpretation der nicht-erhaltungswürdigen Zähne	65
Abbildung 43:	Interpretation der Alveolarkammresorption	66
Abbildung 44:	Interpretation des rechten und linken Kondylus	67
Abbildung 45:	Interpretation der Knochenkontinuität	68
Abbildung 46:	Interpretation der Kanäle des Nervus alveolaris inferior	68
Abbildung 47:	Bewertung der Bedeutung von synthetischen Bildern für den Beruf	69
Abbildung 48:	Bedeutung von synthetischen Bildern für die Gesellschaft	70
Abbildung 49:	Follow up	71
Abbildung 50:	Möglichen Kombinationen für sichtbare Zahnattribute in einem OPG für eine vereinfachte mathematische Näherung	80

7 Erklärung zum Eigenanteil

Die Arbeit wurde in der Klinik für Mund-, Kiefer- und Gesichtschirurgie des Universitätsklinikums Tübingen, unter Betreuung meines Doktorvaters PD Dr. Dr. Sebastian Hoefert (Klinik und Poliklinik für Mund-, Kiefer- und Gesichtschirurgie UKT, Ärztlicher Direktor: Prof. Dr. Dr. Bernd Lethaus) und in Kooperation mit Raoul Schönhof (M.Sc., LL.B.) (Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V., München), durchgeführt. Die Berichterstattung zum Antrag erfolgte durch Prof. Dr. Fabian Springen (Diagnostische und interventionelle Radiologie UKT und BG Unfallklinik Tübingen). Die Konzeption der Studie erfolgte durch mich in Zusammenarbeit mit PD Dr. Dr. Sebastian Hoefert und Raoul Schönhof (M.Sc., LL.B.).

Das Training des Generativen Adversarialen Netzwerks für OPGs erfolgte durch mich in Zusammenarbeit mit Raoul Schönhof (M.Sc., LL.B.).

Die statistische Auswertung erfolgte in Zusammenarbeit mit Dr. Gunnar Blumenstock (Institut für Biometrie klinische Epidemiologie Tübingen UKT).

Die mathematische Beispielrechnung im Absatz „Personen-Bezogene Daten in OPGs“ erfolgte durch mich in Zusammenarbeit mit Luca Rendsburg, PhD (Fraunhofer IIS, Erlangen)

Zur sprachlichen Verbesserung wurden die Programme DeepL und ChatGPT 4.o verwendet.

Ich versichere, das Manuskript selbständig (unter Korrektur von PD Dr. Dr. Sebastian Hoefert) verfasst zu haben und keine weiteren, als die von mir angegebenen Quellen verwendet zu haben.

Tübingen, den 16.08.2024

Rouven Jan Michael Schönhof

8 Liste der Veröffentlichungen

Teile der vorliegenden Dissertationsschrift wurde bereits in den folgenden Publikationen veröffentlicht:

Journal of Dentistry (Impact Factor: 4,4):

R. Schoenhof, R. Schoenhof, G. Blumenstock, B. Lethaus, S. Hoefert, *Synthetic, non-person related panoramic radiographs created by generative adversarial networks in research, clinical, and teaching applications* Journal of Dentistry, Volume 146, July 2024, 105042. <https://doi.org/10.1016/j.jdent.2024.105042>

ZMK - ZAHNHEILKUNDE | MANAGEMENT | KULTUR:

R. Schoenhof, R. Schoenhof, G. Blumenstock, B. Lethaus, S. Hoefert, ZMK - ZAHNHEILKUNDE | MANAGEMENT | KULTUR, Jg. 40, Ausgabe 9/2024, ISSN 1826-0914, E12169, S. 474-476

9 Danksagung

"Menschlicher Körper und Geist setzen sich aus unzähligen Ingredienzien zusammen. All diese Komponenten machen mich zu einem Individuum mit einer eigenen Persönlichkeit. Sicher, mein Gesicht und meine Stimme unterscheiden mich auch von anderen. Aber mein Verstand und meine Erinnerungen gehören nur mir und ich besitze das Bewusstsein meines Schicksals. All dies sind Teilaspekte des Ganzen. Ich nehme Information auf und verarbeite sie auf meine Weise. Aus dem Zusammenwirken all dieser Vorgänge entsteht mein Ich und das Bewusstsein meiner Persönlichkeit." Motoko Kusanagi (GITS: S.A.C.)

Beginnen möchte ich mit meinem Dank bei Dr. Gunnar Blumenstock für die immer sehr freundliche Unterstützung bei der Erarbeitung der statistischen Fallzahlplanung und den kreativen Beiträgen für die Publikation.

Als nächstes möchte ich mich gerne bei Herrn Dr. rer. nat. Luca Rendsburg bedanken, der mit seinem beispiellosen mathematischen Wissen, in der stochastischen Näherung für die Einzigartigkeit eines OPG einen wertvollen Beitrag für diese Arbeit geleistet hat.

Meiner Schwägerin (und Schwester im Herzen) Lisa Schönhof (M.Sc.), meinem Vater Georg Schönhof (Dipl.-Ing), meiner Mutter Maria Schönhof (MTA) und an meiner Doktormutter Dr. Claudia Hoefert für die Liebe, die Unterstützung und das immer da sein - Danke.

Abschließend geht mein größter Dank an meinen Doktorvater und Mentor PD Dr. Dr. Sebastian Hoefert sowie der Person, ohne die diese Arbeit niemals auf diese Weise umsetzbar gewesen wäre - meinem großen Bruder Raoul Schönhof (M.Sc., LL.B.). Ich verdanke euch, dass ihr diese Promotionsarbeit ermöglicht habt und ihr seid ein bedeutender Teil der unzähligen Ingredienzen.

10 Anhang

10.1 OPT – StyleGAN2-ADA© Quellcode – Trainingsprotokoll

```

# Copyright (c) 2020, NVIDIA CORPORATION. All rights reserved.
# NVIDIA CORPORATION and its licensors retain all intellectual
# and proprietary rights in and to this software, related
# documentation
# and any modifications thereto. Any use, reproduction, disclosure
# or distribution of this software and related documentation without an
# express
# license agreement from NVIDIA CORPORATION is strictly prohibited.
"""Train a GAN using the techniques described in the paper
"Training Generative Adversarial Networks with Limited Data"."""
import os
import argparse
import json
import re
import tensorflow as tf
import dnnlib
import dnnlib.tfllib as tfllib

from training import training_loop
from training import dataset
from metrics import metric_defaults

# os.environ["TF_ENABLE_AUTO_MIXED_PRECISION"] = "1"
# os.environ["CUDA_DEVICE_ORDER"]="PCI_BUS_ID" # see issue #152

# -----
class UserError(Exception):
    pass

# -----
def setup_training_options(
    # General options (not included in desc).
    gpus = None, # Number of GPUs: <int>, default = 1 gpu
    snap = None, # Snapshot interval: <int>, default = 50 ticks
    # Training dataset.
    data = None, # Training dataset (required): <path>
    res = None, # Override dataset resolution: <int>, default
    = highest available
    mirror = None, # Augment dataset with x-flips: <bool>,
    default = False
    # Metrics (not included in desc).
    metrics = None, # List of metric names: [], ['fid50k_full']

    if mirror is None:
        mirror = False
    else:
        assert isinstance(mirror, bool)
        if mirror:
            desc += "-mirror"
    args.train_dataset_args.mirror_augment = mirror

    # Metrics: metrics, metricdata
    # -----
    if metrics is None:
        metrics = ['fid50k_full']
    assert isinstance(metrics, list)
    assert all(isinstance(metric, str) for metric in metrics)
    args.metric_arg_list = []
    for metric in metrics:
        if metric not in metric_defaults.metric_defaults:
            raise UserError("\n".join(["--metrics can only contain
the following values:", 'none'] +
list(metric_defaults.metric_defaults.keys())))
    args.metric_arg_list.append(metric_defaults.metric_defaults[metric])

    args.metric_dataset_args =
dnnlib.EasyDict(args.train_dataset_args)
    if metricdata is not None:
        assert isinstance(metricdata, str)
        if not os.path.isdir(metricdata):
            raise UserError("--metricdata must point to a directory
containing *.tfrecords")
        args.metric_dataset_args.path = metricdata

    # -----
    # Base config: cfg, gamma, king
    # -----
    if cfg is None:
        cfg = 'auto'
    assert isinstance(cfg, str)
    desc += f"-{cfg}"

    cfg_specs = {
        'auto': dict(ref_gpus=1, king=25000, mb=512,
mbstd=1, fmaps=1, lrate=1, gamma=1, ema=1, ramp=0.05,
map=8), # populated dynamically based on 'gpus' and 'res'
        'stylegan2': dict(ref_gpus=1, king=25000, mb=16,
mbstd=4, fmaps=1, lrate=0.002, gamma=10, ema=10, ramp=None,
map=8), # uses mixed-precision, unlike original StyleGAN2
        'paper256': dict(ref_gpus=8, king=25000, mb=64,
mbstd=5, fmaps=0.5, lrate=0.0025, gamma=1, ema=20, ramp=None,
map=8),
        'paper512': dict(ref_gpus=8, king=25000, mb=64,
mbstd=8, fmaps=1, lrate=0.0025, gamma=0.5, ema=20, ramp=None,
map=8),
        'paper1024': dict(ref_gpus=8, king=25000, mb=32,
mbstd=4, fmaps=1, lrate=0.002, gamma=2, ema=10, ramp=None,
map=8),
        'cifar': dict(ref_gpus=2, king=100000, mb=64,
mbstd=32, fmaps=0.5, lrate=0.0025, gamma=0.01, ema=500, ramp=0.05,
map=2),
        'cifarbaseline': dict(ref_gpus=2, king=100000, mb=64,
mbstd=32, fmaps=0.5, lrate=0.0025, gamma=0.01, ema=500, ramp=0.05,
map=8),
    }
    assert cfg in cfg_specs
    spec = dnnlib.EasyDict(cfg_specs[cfg])
    if cfg == 'auto':
        desc += f'({gpus:d})'
        spec.ref_gpus = gpus
        spec.mb = max(min(gpus * min(4096 // res, 32), 64), gpus) #
keep gpu memory consumption at bay
        spec.mbstd = min(spec.mb // gpus, 4) # other hyperparams
        behave more predictably if mbstd group size remains fixed
        spec.fmaps = 1 if res >= 512 else 0.5
        spec.lrate = 0.002 if res >= 1024 else 0.0025
        spec.gamma = 0.0002 * (res ** 2) / spec.mb # heuristic
        formula
        spec.ema = spec.mb * 10 / 32
    args.total_king = spec.king
    args.minibatch_size = spec.mb
    args.minibatch_gpu = spec.mb // spec.ref_gpus
    args.D_args.mbstd_group_size = spec.mbstd
    args.G_args.fmap_base = args.D_args.fmap_base = int(spec.fmaps *
16384)
    args.G_args.fmap_max = args.D_args.fmap_max = 256
    args.G_opt_args.learning_rate = args.D_opt_args.learning_rate =
spec.lrate
    args.loss_args.r1_gamma = spec.gamma
    args.G_smoothing_king = spec.ema
    args.G_smoothing_rampup = spec.ramp
    args.G_args.mapping_layers = spec.map
    args.G_args.num_fp16_res = args.D_args.num_fp16_res = 5 # enable
mixed-precision training
    args.G_args.conv_clamp = args.D_args.conv_clamp = 256 # clamp
activations to avoid float16 overflow
    if cfg == 'cifar':
        args.loss_args.pl_weight = 0 # disable path length
        regularization
        args.G_args.style_mixing_prob = None # disable style mixing
        args.D_args.architecture = 'orig' # disable residual skip
connections

```

Anhang

```
if gamma is not None:
    assert isinstance(gamma, float)
    if not gamma >= 0:
        raise UserError('--gamma must be non-negative')
    desc += f'-gamma(gamma:g)'
    args.loss_args.r1_gamma = gamma

if king is not None:
    assert isinstance(king, int)
    if not king >= 1:
        raise UserError('--king must be at least 1')
    desc += f'-king(king:d)'
    args.total_king = king

# -----
# Discriminator augmentation: aug, p, target, augpipe
# -----
if aug is None:
    aug = 'ada'
else:
    assert isinstance(aug, str)
    desc += f'--{aug}'

if aug == 'ada':
    args.augment_args.tune_heuristic = 'rt'
    args.augment_args.tune_target = 0.6

elif aug == 'noaug':
    pass

elif aug == 'fixed':
    if p is None:
        raise UserError(f'--aug={aug} requires specifying --p')
    elif aug == 'adavr':
        if not validation_set_available:
            raise UserError(f'--aug={aug} requires separate
validation set; please see "python dataset_tool.py pack -h"')
        args.augment_args.tune_heuristic = 'rv'
        args.augment_args.tune_target = 0.5
    else:
        raise UserError(f'--aug={aug} not supported')

if p is not None:
    assert isinstance(p, float)
    if aug != 'fixed':
        raise UserError(f'--p can only be specified with --
aug=fixed')
    if not 0 <= p <= 1:
        raise UserError(f'--p must be between 0 and 1')
    desc += f'-p(p:g)'
    args.augment_args.initial_strength = p

assert cmeth is None or isinstance(cmeth, str)
if cmeth is None:
    cmeth = 'nocmeth'
else:
    desc += f'--{cmeth}'

if cmeth == 'nocmeth':
    pass

elif cmeth == 'bcr':
    args.loss_args.func_name = 'training.loss.cmethods'
    args.loss_args.bcr_real_weight = 10
    args.loss_args.bcr_fake_weight = 10
    args.loss_args.bcr_augment =
dnnlib.EasyDict(func_name='training.augment.augment_pipeline',
xint=1, xint_max=1/32)

elif cmeth == 'zcr':
    args.loss_args.func_name = 'training.loss.cmethods'
    args.loss_args.zcr_gen_weight = 0.02
    args.loss_args.zcr_dis_weight = 0.2
    args.G_args.num_fp16_res = args.D_args.num_fp16_res = 0 #
disable mixed-precision training
    args.G_args.conv_clamp = args.D_args.conv_clamp = None

elif cmeth == 'pagan':
    if aug != 'noaug':
        raise UserError(f'--cmeth={cmeth} is not compatible
with discriminator augmentation; please specify --aug=noaug')
    args.D_args.use_pagan = True
    args.augment_args.tune_heuristic = 'rt' # enable ada
heuristic
    args.augment_args.pop('apply_func', None) # disable
discriminator augmentation
    args.augment_args.pop('apply_args', None)
    args.augment_args.tune_target = 0.95

elif cmeth == 'wganp':
    if aug != 'noaug':
        raise UserError(f'--cmeth={cmeth} is not compatible
with discriminator augmentation; please specify --aug=noaug')
    if gamma is not None:
        raise UserError(f'--cmeth={cmeth} is not compatible
with --gamma')
    args.loss_args =
dnnlib.EasyDict(func_name='training.loss.wganp')
    args.G_opt_args.learning_rate =
args.D_opt_args.learning_rate = 0.001
    args.G_args.num_fp16_res = args.D_args.num_fp16_res = 0 #
disable mixed-precision training
    args.G_args.conv_clamp = args.D_args.conv_clamp = None
    args.lazy_regularization = False

elif cmeth == 'auxrot':

if target is not None:
    assert isinstance(target, float)
    if aug not in ['ada', 'adavr']:
        raise UserError('--target can only be specified with --
aug=ada or --aug=adavr')
    if not 0 <= target <= 1:
        raise UserError('--target must be between 0 and 1')
    desc += f'-target(target:g)'
    args.augment_args.tune_target = target

assert augpipe is None or isinstance(augpipe, str)
if augpipe is None:
    augpipe = 'bgc'
else:
    if aug == 'noaug':
        raise UserError('--augpipe cannot be specified with --
aug=noaug')
    desc += f'--{augpipe}'

    augpipe_specs = {
        'blit': dict(xflip=1, rotate90=1, xint=1),
        'geom': dict(scale=1, rotate=1, aniso=1, xfrac=1),
        'color': dict(brightness=1, contrast=1, lumaflip=1,
hue=1, saturation=1),
        'filter': dict(imgfilter=1),
        'noise': dict(noise=1, cutout=1, brightness=1,
contrast=1),
        'bg': dict(xflip=1, rotate90=1, xint=1, scale=1,
rotate=1, aniso=1, xfrac=1, hue=1, saturation=1),
        'bgc': dict(xflip=1, rotate90=1, xint=1, scale=1,
rotate=1, aniso=1, xfrac=1, brightness=1, contrast=1, lumaflip=1,
hue=1, saturation=1),
        'bgcf': dict(xflip=1, rotate90=1, xint=1, scale=1,
rotate=1, aniso=1, xfrac=1, brightness=1, contrast=1, lumaflip=1,
hue=1, saturation=1),
        'bgcfn': dict(xflip=1, rotate90=1, xint=1, scale=1,
rotate=1, aniso=1, xfrac=1, brightness=1, contrast=1, lumaflip=1,
hue=1, saturation=1, imgfilter=1, noise=1),
        'bgcfnf': dict(xflip=1, rotate90=1, xint=1, scale=1,
rotate=1, aniso=1, xfrac=1, brightness=1, contrast=1, lumaflip=1,
hue=1, saturation=1, imgfilter=1, noise=1, cutout=1)
    }

    assert augpipe in augpipe_specs
    if aug != 'noaug':
        args.augment_args.apply_func =
'training.augment.augment_pipeline'
        args.augment_args.apply_args = augpipe_specs[augpipe]

# -----
# Comparison methods: cmeth, dcap
# -----

'ffhq1024': 'https://nvlabs-fi-cdn.nvidia.com/stylegan2-
ada/pretrained/transfer-learning-source-nets/ffhq-res1024-mirror-
stylegan2-noaug.pkl',
'celebahq256': 'https://nvlabs-fi-cdn.nvidia.com/stylegan2-
ada/pretrained/transfer-learning-source-nets/celebahq-res256-mirror-
paper256-king100000-ada-target0.5.pkl',
'lsundog256': 'https://nvlabs-fi-cdn.nvidia.com/stylegan2-
ada/pretrained/transfer-learning-source-nets/lsundog-res256-
paper256-king100000-noaug.pkl',
}

assert resume is None or isinstance(resume, str)
if resume is None:
    resume = 'noresume'
elif resume == 'noresume':
    desc += '--noresume'
elif resume in resume_specs:
    desc += f'--resume(resume)'
else:
    desc += '--resumecustom'
    args.resume_pkl = resume # custom path or url

if resume != 'noresume':
    args.augment_args.tune_king = 100 # make ADA react faster at
the beginning
    args.G_smoothing_rampup = None # disable EMA rampup

if freed is not None:
    assert isinstance(freed, int)
    if not freed >= 0:
        raise UserError('--freed must be non-negative')
    desc += f'--freed(freed:d)'
    args.D_args.freeze_layers = freed

return desc, args

#-----
def run_training(outdir, seed, dry_run, **hyperparam_options):
    # Setup training options.
    tflib.init_tf({'rnd_np_random_seed': seed})
    run_desc, training_options =
setup_training_options(**hyperparam_options)

    # Pick output directory.
    prev_run_dirs = []
    if os.path.isdir(outdir):
        prev_run_dirs = [x for x in os.listdir(outdir) if
os.path.isdir(os.path.join(outdir, x))]
    prev_run_ids = [re.match(r'^(\d+)', x) for x in prev_run_dirs]
    prev_run_ids = [int(x.group()) for x in prev_run_ids if x is not
None]
```

Anhang

```
if args.train_dataset_args.max_label_size > 0:
    raise ValueError(f'--method={cmethd} is not compatible
with label conditioning; please specify a dataset without labels')
args.loss_args.func_name = 'training.loss.cmethods'
args.loss_args.auxrot_alpha = 10
args.loss_args.auxrot_beta = 5
args.D_args.score_max = 5 # prepare D to output 5 scalars
per image instead of just 1

elif cmethd == 'spectralnorm':
    args.D_args.use_spectral_norm = True

elif cmethd == 'shallowmap':
    if args.G_args.mapping_layers == 2:
        raise ValueError(f'--method={cmethd} is a no-op for --
cfg={cfg}')
    args.G_args.mapping_layers = 2

elif cmethd == 'adropout':
    if aug != 'noaug':
        raise ValueError(f'--method={cmethd} is not compatible
with discriminator augmentation; please specify --aug=noaug')
    args.D_args.adaptive_dropout = 1
    args.augment_args.tune_heuristic = 'rt' # enable ada
heuristic
    args.augment_args.pop('apply_func', None) # disable
discriminator augmentation
    args.augment_args.pop('apply_args', None)
    args.augment_args.tune_target = 0.6

else:
    raise ValueError(f'--method={cmethd} not supported')

if dcap is not None:
    assert isinstance(dcap, float)
    if not dcap > 0:
        raise ValueError('--dcap must be positive')
    desc += f'-dcap{dcap:g}'
    args.D_args.fmap_base = max(int(args.D_args.fmap_base *
dcap), 1)
    args.D_args.fmap_max = max(int(args.D_args.fmap_max * dcap),
1)

# -----
# Transfer learning: resume, freedze
# -----
resume_specs = {
    'ffhq256': 'https://nvlabs-fi-cdn.nvidia.com/stylegan2-
ada/pretrained/transfer-learning-source-nets/ffhq-res256-mirror-
paper256-noaug.pk1',
    'ffhq512': 'https://nvlabs-fi-cdn.nvidia.com/stylegan2-
ada/pretrained/transfer-learning-source-nets/ffhq-res512-mirror-
stylegan2-noaug.pk1',

    'ffhq256': 'https://nvlabs-fi-cdn.nvidia.com/stylegan2-
ada/pretrained/transfer-learning-source-nets/ffhq-res256-mirror-
paper256-noaug.pk1',
    'ffhq512': 'https://nvlabs-fi-cdn.nvidia.com/stylegan2-
ada/pretrained/transfer-learning-source-nets/ffhq-res512-mirror-
stylegan2-noaug.pk1',

}

_formatter_class=argparse.RawDescriptionHelpFormatter

group = parser.add_argument_group('general options')
group.add_argument('--outdir', help='Where to save the results
(required)', required=True, metavar='DIR')
group.add_argument('--gpus', help='Number of GPUs to use
(default: 1 gpu)', type=int, metavar='INT')
group.add_argument('--snap', help='Snapshot interval (default:
50 ticks)', type=int, metavar='INT')
group.add_argument('--seed', help='Random seed (default: %
(default)s)', type=int, default=1000, metavar='INT')
group.add_argument('-n', '--dry-run', help='Print training
options and exit', action='store_true', default=False)

group = parser.add_argument_group('training dataset')
group.add_argument('--data', help='Training dataset path
(required)', metavar='PATH', required=True)
group.add_argument('--res', help='Dataset resolution
(default: highest available)', type=int, metavar='INT')
group.add_argument('--mirror', help='Augment dataset with x-
flips (default: false)', type=str_to_bool, metavar='BOOL')

group = parser.add_argument_group('metrics')
group.add_argument('--metrics', help='Comma-separated list or
"none" (default: fid50k_full)', type=parse_comma_sep,
metavar='LIST')
group.add_argument('--metricdata', help='Dataset to evaluate
metrics against (optional)', metavar='PATH')

group = parser.add_argument_group('base config')
group.add_argument('--cfg', help='Base config (default:
auto)', choices=['auto', 'stylegan2', 'paper256', 'paper512',
'paper1024', 'cifar', 'cifarbaseline'])
group.add_argument('--gamma', help='Override R1 gamma',
type=float, metavar='FLOAT')
group.add_argument('--king', help='Override training duration',
type=int, metavar='INT')

group = parser.add_argument_group('discriminator augmentation')
group.add_argument('--aug', help='Augmentation mode (default:
ada)', choices=['noaug', 'ada', 'fixed', 'adar'])
group.add_argument('-p', help='Specify augmentation
probability for --aug=fixed', type=float, metavar='FLOAT')
group.add_argument('--target', help='Override ADA target for --
aug=ada and --aug=adar', type=float)
group.add_argument('--augpipe', help='Augmentation pipeline
(default: bgc), choices=['blit', 'geom', 'color', 'filter',
'noise', 'cutout', 'bg', 'bgc', 'bgcf', 'bgcfn', 'bgcfncl'])

group = parser.add_argument_group('comparison methods')
group.add_argument('--method', help='Comparison method
(default: nocmethod), choices=['nocmethod', 'bcr', 'zcr', 'pagan',
'wgangp', 'auxrot', 'spectralnorm', 'shallowmap', 'adropout'])

def main():
    parser = argparse.ArgumentParser(
        description='Train a GAN using the techniques described in
the paper "Training Generative Adversarial Networks with Limited
Data"',
        epilog=__docline_help_epilog,
    )

    _cmdline_help_epilog = '''examples:

# Train custom dataset using 1 GPU.
python %(prog)s --outdir~/training-runs --gpus=1 --data~/
datasets/custom

# Train class-conditional CIFAR-10 using 2 GPUs.
python %(prog)s --outdir~/training-runs --gpus=2 --data~/
datasets/cifar10c \\\
--cfg=cifar

# Transfer learn MetFaces from FFHQ using 4 GPUs.
python %(prog)s --outdir~/training-runs --gpus=4 --data~/
datasets/metfaces \\\
--cfg=paper1024 --mirror=1 --resume=ffhq1024 --snap=10

# Reproduce original StyleGAN2 config F.
python %(prog)s --outdir~/training-runs --gpus=8 --data~/
datasets/ffhq \\\
--cfg=stylegan2 --res=1024 --mirror=1 --aug=noaug

available base configs (--cfg):
auto Automatically select reasonable defaults based on
resolution and GPU count. Good starting point for new
datasets.
stylegan2 Reproduce results for StyleGAN2 config F at
1024x1024.
paper256 Reproduce results for FFHQ and LSUN Cat at 256x256.
paper512 Reproduce results for BreCAHAD and AFHQ at 512x512.
paper1024 Reproduce results for MetFaces at 1024x1024.
cifar Reproduce results for CIFAR-10 (tuned
configuration).
cifarbaseline Reproduce results for CIFAR-10 (baseline
configuration).

transfer learning source networks (--resume):
ffhq256 FFHQ trained at 256x256 resolution.
ffhq512 FFHQ trained at 512x512 resolution.
ffhq1024 FFHQ trained at 1024x1024 resolution.
celebahq256 CelebA-HQ trained at 256x256 resolution.
lsun0g256 LSUN Dog trained at 256x256 resolution.
<path or URL> Custom network pickle.

'''
```

Anhang

```
_cmdline_help_epilog = '''examples:

# Train custom dataset using 1 GPU.
python %(prog)s --outdir~/training-runs --gpus=1 --data~/
datasets/custom

# Train class-conditional CIFAR-10 using 2 GPUs.
python %(prog)s --outdir~/training-runs --gpus=2 --data~/
datasets/cifar10c \
--cfg=cifar

# Transfer learn MetFaces from FFHQ using 4 GPUs.
python %(prog)s --outdir~/training-runs --gpus=4 --data~/
datasets/metfaces \
--cfg=paper1024 --mirror=1 --resume=ffhq1024 --snap=10

# Reproduce original StyleGAN2 config F.
python %(prog)s --outdir~/training-runs --gpus=8 --data~/
datasets/ffhq \
--cfg=stylegan2 --res=1024 --mirror=1 --aug=noaug

available base configs (--cfg):
auto Automatically select reasonable defaults based on
resolution and GPU count. Good starting point for new
datasets.
stylegan2 Reproduce results for StyleGAN2 config F at
1024x1024.
paper256 Reproduce results for FFHQ and LSUN Cat at 256x256.
paper512 Reproduce results for BreCAGHD and AFHQ at 512x512.
paper1024 Reproduce results for MetFaces at 1024x1024.
cifar Reproduce results for CIFAR-10 (tuned
configuration).
cifarbaseline Reproduce results for CIFAR-10 (baseline
configuration).

transfer learning source networks (--resume):
ffhq256 FFHQ trained at 256x256 resolution.
ffhq512 FFHQ trained at 512x512 resolution.
ffhq1024 FFHQ trained at 1024x1024 resolution.
celebahq256 CelebA-HQ trained at 256x256 resolution.
lsundog256 LSUN Dog trained at 256x256 resolution.
,,<path or URL> Custom network pickle.

-----

def main():
    parser = argparse.ArgumentParser(
        description='Train a GAN using the techniques described in
the paper "Training Generative Adversarial Networks with Limited
Data".',
        epilog=_cmdline_help_epilog,

        group.add_argument('--dcap', help='Multiplier for
discriminator capacity', type=float, metavar='FLOAT')

        group = parser.add_argument_group('transfer learning')
        group.add_argument('--resume', help='Resume from network pickle
(default: noresume)')
        group.add_argument('--frozen', help='Freeze-D (default: 0
discriminator layers)', type=int, metavar='INT')

        args = parser.parse_args()
        try:
            run_training(**vars(args))
        except UserError as err:
            print(f'Error: {err}')
            exit(1)

    -----

if __name__ == "__main__":
    main()

    -----'''
```

10.2 Studienaufklärung



**Universitätsklinikum
Tübingen**

Klinik und Poliklinik für Mund-, Kiefer- und
Gesichtschirurgie, *

**Klinik und Poliklinik für Mund-,
Kiefer- und Gesichtschirurgie**
Plastisch-ästhetische Operationen

Zentrum für Kopf-Hals-Tumoren im CCC

Zentrum für Lippen-Kiefer-Gaumenspalten/
Kraniofaziale Fehlbildungen

Ärztlicher Direktor (komm.)
Prof. Dr. Dr. Michael Krimmel

Tel. +49 7071 29-86174
Fax +49 7071 29-3481

Osianderstraße 2-8
72076 Tübingen

mkg@med.uni-tuebingen.de

Prüfärzte:

1. PD Dr. Dr. Sebastian Hoefert
Oberarzt

sebastian.hoefert@med.uni-tuebingen.com

2. Dr. Rouven Schönhof

Arzt in Weiterbildung
rouven.schoenhof@med.uni-tuebingen.com

Aufklärung für die Studie:

„Erstellung einer Datenbank für synthetische, nicht-personenbezogenen Orthopantomogramme (OPTs) durch Generative Adversarial Networks (GANs), Analyse ihrer Authentizität und Machbarkeitsanalyse für die Bereitstellung für Forschung, klinische Anwendung und Lehre.“

Sehr geehrte ÄrztInnen, ZahnärztInnen und Studierende der Zahnmedizin im klinischen Studienabschnitt,

vielen Dank für Ihr Interesse an unserer Fragebogenstudie. Diese Umfrage richtet sich an ÄrztInnen in Weiterbildung zur MKG-Chirurgie und FachärztInnen der MKG-Chirurgie, ÄrztInnen in Weiterbildung zur Radiologie und FachärztInnen der Radiologie, Approbierte ZahnärztInnen und Studierende der Zahnmedizin im klinischen Abschnitt nach Erhalt des Röntgen-Scheins. Im Folgenden werden wir Sie über Ziele und Hintergrund dieser Untersuchung informieren. Bitte lesen Sie sich diese Informationen sorgfältig durch.

Hintergrund

In dieser Studie soll geprüft werden, ob KlinikerInnen mit radiologisch Expertise in der Befundung von Orthopantomogrammen (OPTs) echte OPTs von computergenerierten, durch künstliche Intelligenzen (KIs/GANs) erzeugte, synthetischen OPTs unterscheiden können. Es ist geplant, voraussichtlich bis Dezember 2023 ca. 20 ÄrztInnen und 20 ZahnärztInnen sowie ca. 20-40 Studierende der Zahnmedizin im Rahmen dieser Studie zu befragen. In der Umfrage sehen Sie insgesamt 45 Abbildungen von OPTs und Sie sollen entscheiden, ob diese echt oder synthetisch/computergeneriert sind. Zudem soll ein synthetisches OPT auf eventuelle artifizielle Pathologien analysiert werden. Die Umfrage erfolgt unter adäquaten, Befundungs-realistischen Untersuchungsbedingungen und dauert ca. 30 Minuten. Zudem ist die Umfrage zweizeitig und nach diesem ersten Fragebogen erfolgt eine weitere Befragung in 4-6 Wochen.

Universitätsklinikum Tübingen

Anstalt des öffentlichen Rechts, Sitz Tübingen
Steuer-Nr. 86156/09402
USt.-ID: DE 146 889 674
Geissweg 3
72076 Tübingen
Tel. +49 7071 29-0
www.medin.uni-tuebingen.de

Aufsichtsrat

Dr. Hans J. Reiter (Vorsitzender)
Vorstand
Prof. Dr. Michael Bamberg (Vorsitzender)
Gabriele Sonntag (Stellv. Vorsitzende)
Prof. Dr. Karl Ulrich Bartz-Schmidt
Prof. Dr. Bernd Pichler
Klaus Tischler

Banken

Baden-Württembergische Bank Stuttgart:
(BLZ 600 501 01) Konto-Nr. 7477 5037 93
IBAN: DE 41 6005 0101 7477 5037 93
BIC (SWIFT-Code): SOLADEST600
Kreissparkasse Tübingen:
(BLZ 641 500 20) Konto-Nr. 14 144
IBAN: DE 79 6415 0020 0000 0141 44
BIC (SWIFT-Code): SOLADES1TUB



Informationen zum Datenschutz

Im Rahmen der Studie werden Ihre personenbezogenen Daten erhoben und verarbeitet. Die Dokumentation Ihrer Daten und deren Archivierung erfolgt pseudonymisiert in einer geschützten elektronischen Datenbank, zu der nur befugte Mitarbeiterinnen und Mitarbeiter einschließlich auf das Berufs- und Datengeheimnis verpflichtete Doktorandinnen und Doktoranden Zutritt haben. Alle beteiligten Mitarbeiter unterliegen der Schweigepflicht.

Rechtsgrundlage für die Verarbeitung sind Art. 6 Abs. 1 lit. a und Art. 9 Abs. 2 lit. a Datenschutz-Grundverordnung (DSGVO) in Verbindung mit Ihrer Einwilligung.

Für die Erhebung, Speicherung, Nutzung und Weitergabe Ihrer Daten ist Ihre ausdrückliche Zustimmung durch Unterzeichnung der Einwilligungserklärung zum Datenschutz erforderlich.

Die Forschungsergebnisse aus der Studie werden in anonymisierter Form in Fachzeitschriften oder in wissenschaftlichen Datenbanken veröffentlicht. Die Verarbeitung der pseudonymisierten Daten erfolgt auf Erhebungsbögen und elektronischen Datenträgern.

Die Daten werden 10 Jahre nach Beendigung oder Abbruch der Studie aufbewahrt. Sie sind gegen unbefugten Zugriff geschützt und werden gelöscht, sobald sie für den Zweck der Datenverarbeitung im Rahmen der Studie nicht mehr benötigt werden, spätestens nach 10 Jahren.

Die im Verlauf dieser Studie gewonnenen Informationen werden ausschließlich in der EU, dem Europäischen Wirtschaftsraum oder Ländern mit vergleichbarem Datenschutzniveau verarbeitet.

Sie können Ihre Einwilligung jederzeit ohne Angabe von Gründen schriftlich oder mündlich widerrufen, ohne dass Ihnen daraus ein Nachteil entsteht. Wenn Sie Ihre Einwilligung widerrufen, werden keine weiteren Daten mehr erhoben. Die bis zum Widerruf erfolgte Datenverarbeitung bleibt jedoch rechtmäßig.

Sie können auch jederzeit Auskunft über Ihre gespeicherten Daten anfordern sowie die Überlassung einer kostenlosen Kopie verlangen und haben das Recht, fehlerhafte Daten berichtigen zu lassen.

Sie können auch jederzeit verlangen, dass Ihre Daten gelöscht oder anonymisiert werden, so dass ein Bezug zu Ihrer Person nicht mehr hergestellt werden kann.

Diese Rechte sind nach § 13 des Landesdatenschutzgesetzes (LDSG) bzw. § 27 des Bundesdatenschutzgesetzes (BDSG) insoweit beschränkt, als diese Rechte voraussichtlich die Verwirklichung der jeweiligen Forschungszwecke unmöglich machen oder ernsthaft beeinträchtigen und die Beschränkung für die Erfüllung der jeweiligen Forschungszwecke notwendig ist. Das Recht auf Auskunft besteht darüber hinaus nicht, wenn die Daten für Zwecke der wissenschaftlichen Forschung erforderlich sind und die Auskunftserteilung einen unverhältnismäßigen Aufwand erfordern würde.

Verantwortlicher für die Datenverarbeitung gem. Art. 4 Abs. 7 DSGVO ist das Universitätsklinikum Tübingen, rechtsfähige Anstalt des öffentlichen Rechts der Universität Tübingen, Geissweg 3, 72076 Tübingen, Tel.: 07071 29-0, service@med.uni-tuebingen.de. Verantwortliche für die

Datenverarbeitung in dieser Studie sind die Studienleiter PD Dr. Dr. Sebastian Hoefert und Dr. Rouven Schönhof. Bei Fragen zur Nutzung oder Verarbeitung Ihrer Daten wenden Sie sich bitten an sie.

Sollten Sie Bedenken oder Beschwerden im Hinblick auf den Datenschutz haben oder Ihre Rechte gemäß Art. 15ff. DSGVO wahrnehmen wollen, können Sie sich an folgenden Kontakt wenden: Universitätsklinikum Tübingen, Datenschutzbeauftragter, Geissweg 3, 72076 Tübingen, Tel.: 07071 29-87667, E-Mail: Datenschutz@med.uni-tuebingen.de. Sie haben außerdem das Recht sich bei der zuständigen Aufsichtsbehörde für den Datenschutz zu beschweren (Landesbeauftragter für den Datenschutz und die Informationsfreiheit in Baden-Württemberg, Postfach 10 29 32, 70025 Stuttgart, Tel.: 0711 / 61 55 41 - 716, Mail: Poststelle@lfdi.bwl.de).

Bitte nehmen Sie nur an der Untersuchung teil, wenn sie bereit sind, ihre persönliche Meinung offen und ehrlich bei der Bearbeitung der Fragebögen zu äußern. Sie können zu jedem Zeitpunkt die Bearbeitung der Umfrage abbrechen. Ihre Teilnahme an unserer Studie ist freiwillig. Lehnen Sie die Teilnahme ab oder widerrufen oder beschränken Sie Ihre Einwilligung, entstehen Ihnen hieraus keine Nachteile.

Kontakt

Haben Sie vor Beginn der Befragung noch offene Fragen oder Wünschen sie nach Abschluss der Befragung noch weitere Informationen, können Sie die Studienmitarbeiter gerne über E-Mail an rouven.schoenhof@med.uni-tuebingen.com kontaktieren.

Freundliche Grüße

Dr. Rouven Schönhof
Arzt in Weiterbildung
Klinik und Poliklinik für Mund-, Kiefer- und Gesichtschirurgie des Universitätsklinikums
Tübingen

10.3 Studieneinverständnis

Klinik und Poliklinik für Mund-, Kiefer- und Gesichtschirurgie, *
Osianderstr. 2-8 • 72076 Tübingen



**Universitätsklinikum
Tübingen**

Laufende Nummer: XYZ

Einverständniserklärung für die Studie:

„Erstellung einer Datenbank für synthetische, nicht-personenbezogenen Orthopantomogramme (OPTs) durch Generative Adversarial Networks (GANs), Analyse ihrer Authentizität und Machbarkeitsanalyse für die Bereitstellung für Forschung, klinische Anwendung und Lehre.“

Über Forschungsziele, Datennutzung und Datenschutz wurde ich in den vorherigen Abschnitten informiert. Diese Abschnitte habe ich gelesen und verstanden. Ich erkläre hiermit, dass ich vor den Datenerhebungen die Möglichkeit hatte, an die Verantwortlichen Fragen zu stellen. Eventuelle Fragen wurden vollständig beantwortet.

Mir ist bewusst, dass meine Teilnahme an der Studie vollkommen freiwillig ist und ich weder bei einer Nicht-Teilnahme keinerlei Nachteile erleide noch bei Teilnahme Vorteile erhalte. Die individuelle Performance hat keinen Einfluss auf die weitere berufliche Entwicklung. Meine Einwilligung kann ich jederzeit mit Wirkung für die Zukunft widerrufen, ohne dass dies einer Begründung bedarf und ohne, dass mir daraus irgendwelche Nachteile entstehen. Im Fall eines Widerrufs werden meine personenbezogenen Daten anonymisiert oder gelöscht.

Ich versichere, dass ich die Untersuchung unter adäquaten, Befundungs-realistischen Untersuchungsbedingungen durchführe.

Eine Kopie der Informationsschrift und dieser Einwilligungserklärung habe ich erhalten. Das Original verbleibt bei in der Klinik für MKG-Chirurgie UKT.

**Klinik und Poliklinik für Mund-,
Kiefer- und Gesichtschirurgie**

Plastisch-ästhetische Operationen

Zentrum für Kopf-Hals-Tumoren im CCC

Zentrum für Lippen-Kiefer-Gaumenspalten/
Kraniofaziale Fehlbildungen

Ärztlicher Direktor (komm.)
Prof. Dr. Dr. Michael Krimmel

Tel. +49 7071 29-86174
Fax +49 7071 29-3481

Osianderstraße 2-8
72076 Tübingen

mkg@med.uni-tuebingen.de

Prüfärzte:

1. PD Dr. Dr. Sebastian Hoefert

Oberarzt

sebastian.hoefert@med.uni-tuebingen.com

2. Dr. Rouven Schönhof

Arzt in Weiterbildung

rouven.schoenhof@med.uni-tuebingen.com

Vor- und Nachname (Teilnehmende)

Ort, Datum, Unterschrift (Teilnehmende)

Vor- und Nachname (Prüfarzt)

Ort, Datum, Unterschrift (Prüfarzt)

Universitätsklinikum Tübingen
Anstalt des öffentlichen Rechts, Sitz Tübingen
Steuer-Nr. 86156/09402
USt.-ID: DE 146 889 674
Geissweg 3
72076 Tübingen
Tel. +49 7071 29-0
www.medizin.uni-tuebingen.de

Aufsichtsrat
Dr. Hans J. Reiter (Vorsitzender)*
Vorstand
Prof. Dr. Michael Bamberg (Vorsitzender)
Gabriele Sonntag (Stellv. Vorsitzende)
Prof. Dr. Karl Ulrich Bartz-Schmidt
Prof. Dr. Bernd Pichler
Klaus Tischler

Banken
Baden-Württembergische Bank Stuttgart:
(BLZ 600 501 01) Konto-Nr. 7477 5037 93
IBAN: DE 41 6005 0101 7477 5037 93
BIC (SWIFT-Code): SOLADEST600
Kreissparkasse Tübingen:
(BLZ 641 500 20) Konto-Nr. 14 144
IBAN: DE 79 6415 0020 0000 0141 44
BIC (SWIFT-Code): SOLADES1TUB



Klinik und Poliklinik für Mund-, Kiefer- und Gesichtschirurgie, *
Osianderstr. 2-8 • 72076 Tübingen



**Universitätsklinikum
Tübingen**

Laufende Nummer: XYZ

**Klinik und Poliklinik für Mund-,
Kiefer- und Gesichtschirurgie**
Plastisch-ästhetische Operationen

Zentrum für Kopf-Hals-Tumoren im CCC

Zentrum für Lippen-Kiefer-Gaumenspalten/
Kraniofaziale Fehlbildungen

Ärztlicher Direktor (komm.)
Prof. Dr. Dr. Michael Krimmel

Tel. +49 7071 29-86174
Fax +49 7071 29-3481

Osianderstraße 2-8
72076 Tübingen

mkg@med.uni-tuebingen.de

Prüfärzte:

1. PD Dr. Dr. Sebastian Hoefert

Oberarzt

sebastian.hoefert@med.uni-tuebingen.com

2. Dr. Rouven Schönhof

Arzt in Weiterbildung

rouven.schoenhof@med.uni-tuebingen.com

Einwilligungserklärung zum Umgang mit den in einer Studie erhobenen Daten für die Studie:

„Erstellung einer Datenbank für synthetische, nicht-personenbezogenen Orthopantomogramme (OPTs) durch Generative Adversarial Networks (GANs), Analyse ihrer Authentizität und Machbarkeitsanalyse für die Bereitstellung für Forschung, klinische Anwendung und Lehre.“

Ich erkläre, dass ich mit der im Rahmen der Studie erfolgenden Erhebung und Verarbeitung von Daten und ihrer verschlüsselten (pseudonymisierten) Weitergabe einverstanden bin.

Ich stimme zu, dass bevollmächtigte Personen zum Zwecke der Überprüfung der Daten Einblick in meine persönliche Krankenakte nehmen dürfen und entbinde den behandelnden Arzt insoweit von seiner ärztlichen Schweigepflicht.

Mir ist bewusst, dass die Ergebnisse dieser Studie in medizinischen Fachzeitschriften veröffentlicht werden, allerdings in anonymisierter Form, so dass ein direkter Bezug zu meiner Person nicht hergestellt werden kann.

Ich wurde darüber informiert, dass ich jederzeit Auskunft über meine gespeicherten Daten und die Berichtigung von fehlerhaften Daten verlangen kann. Ich wurde in Kenntnis gesetzt, dass die erhobenen Daten 10 Jahre nach Beendigung oder Abbruch der Studie aufbewahrt werden.

Ich weiß, dass ich jederzeit, beispielsweise beim Widerruf der Studienteilnahme, verlangen kann, dass meine bis dahin erhobenen Daten gelöscht oder unverzüglich anonymisiert werden.

Ich erkläre, dass ich über die Erhebung und Verarbeitung meiner in dieser Studie erhobenen Daten und meine Rechte angemessen informiert wurde.

Ich stimme der Verwendung der im Rahmen dieser Studie erhobenen Daten in der oben beschriebenen Form zu. Für die Einsichtnahme bevollmächtigter Personen befreie ich im erforderlichen Umfang meine behandelnden Ärzte und das Studienteam von der Schweigepflicht.

Ich bin ausdrücklich damit einverstanden, dass das Studienteam auch nach Studienende zu mir Kontakt aufnehmen darf, um zu fragen, ob ich einverstanden bin, dass die im Rahmen der Studie erhobenen Daten auch für konkrete künftige Forschungsvorhaben der Klinik bzw. des Instituts genutzt und weiterverarbeitet werden können.

Ja Nein

Vor- und Nachname (Teilnehmende)

Ort, Datum, Unterschrift (Teilnehmende)

Vor- und Nachname (Prüfarzt)

Ort, Datum, Unterschrift (Prüfarzt)

Universitätsklinikum Tübingen
Anstalt des öffentlichen Rechts, Sitz Tübingen
Steuer-Nr. 86156/09402
USt.-ID: DE 146 889 674
Geißweg 3
72076 Tübingen
Tel. +49 7071 29-0
www.medizin.uni-tuebingen.de

Aufsichtsrat
Dr. Hans J. Reiter (Vorsitzender)“
Vorstand
Prof. Dr. Michael Bamberg (Vorsitzender)
Gabriele Sonntag (Stellv. Vorsitzende)
Prof. Dr. Karl Ulrich Bartz-Schmidt
Prof. Dr. Bernd Pichler
Klaus Tischler

Banken
Baden-Württembergische Bank Stuttgart:
(BLZ 600 501 01) Konto-Nr. 7477 5037 93
IBAN: DE 41 6005 0101 7477 5037 93
BIC (SWIFT-Code): SOLADEST600
Kreissparkasse Tübingen:
(BLZ 641 500 20) Konto-Nr. 14 144
IBAN: DE 79 6415 0020 0000 0141 44
BIC (SWIFT-Code): SOLADES1TUB

