

**Diplomarbeit**

**Maschinelles Lernen in der Zahnmedizin**  
**Eine systematische Literaturrecherche**

eingereicht von

**Lisa Anna Marie Bauer**

zur Erlangung des akademischen Grades

**Doktorin der Zahnheilkunde**  
**(Dr.<sup>in</sup> med. dent.)**

an der

**Medizinischen Universität Graz**

ausgeführt an der

**Universitätsklinik für Zahnmedizin und Mundgesundheit**  
Klinischen Abteilung für Orale Chirurgie und Kieferorthopädie

unter der Anleitung von

Univ.-ZÄ Dr.<sup>in</sup> med.dent.Dr.<sup>in</sup> scient.med. Barbara Kirnbauer

Assoz. Prof. Priv.-Doz. Dr.med.univ. Dr.med.dent.et scient.med. Michael Payer

Graz, 08.11.2022

*Eidesstattliche Erklärung*

*Ich erkläre ehrenwörtlich, dass ich die vorliegende Arbeit selbstständig und ohne fremde Hilfe verfasst habe, andere als die angegebenen Quellen nicht verwendet habe und die den benutzten Quellen wörtlich oder inhaltlich entnommenen Stellen als solche kenntlich gemacht habe.*

*Graz, 08.11.2022.*

*Bauer Lisa Anna Marie eh.*

*Für meinen Bruder Daniel*

## Danksagung

An dieser Stelle möchte ich mich bei all jenen bedanken, die an der Entstehung dieser Diplomarbeit beteiligt waren und mich im Laufe meines Studiums unterstützt haben.

Ich würde mich gerne bei meiner Betreuerin Frau Univ.-ZÄ Dr.<sup>in</sup> med.dent.Dr.<sup>in</sup> scient.med. Barbara Kirnbauer bedanken. Danke für die Themenbereitstellung, die Hilfestellung und die immense Geduld die Sie mir während der Erarbeitung dieser Diplomarbeit entgegengebracht haben. Bei Assoz. Prof. Priv.-Doz. Dr.med.univ. Dr.med.dent.et scient.med. Michael Payer möchte ich mich ebenfalls herzlich bedanken. Sie beide haben mich nicht nur beim Verfassen dieser Arbeit unterstützt, sondern mich auch durch das chirurgische Praktikum geführt und mir bei meiner zahnmedizinischen Entwicklung geholfen.

Der größte Dank gilt meiner Familie! Ihr habt mich zu jeder Tages- und Nachtzeit unterstützt. Trotz der vielen dunklen Tage in den letzten Jahren, haben wir immer alles gemeinsam bewältigt und ich bin mir sicher, dass das auch weiterhin so sein wird. Komme was wolle, wir meistern jede noch so große Hürde mit Bravour! Meine Studienzeit war wunderschön und ohne euch wäre das nicht möglich gewesen. Auch meinem Luki möchte ich Danke sagen. Du bist mein Ruhepol und motivierst mich auch an den Tagen, an denen das sonst keiner schafft.

Zuletzt möchte ich mich noch bei meinen vielen Freunden und Freundinnen bedanken. Ich bin unendlich dankbar, dass ich im Rahmen meines Studiums nicht nur wahnsinnig viel lernen durfte, sondern auch Freund\*innen fürs Leben gefunden habe! Ihr habt mir immer ein offenes Ohr für meine kleinen oder großen Probleme gehabt und wir hatten unvergessliche Momente, sowohl auf der Klinik als auch außerhalb. Ich freu mich auf viele großartige gemeinsame Abende die noch folgen. Ich bin aus tiefstem Herzen stolz und dankbar, dass ich euch meine Freunde und Freundinnen nennen darf!

# Inhaltsverzeichnis

<b>DANKSAGUNG</b> .....	<b>I</b>
<b>ABKÜRZUNGEN UND DEREN ERKLÄRUNG</b> .....	<b>IV</b>
<b>TABELLENVERZEICHNIS</b> .....	<b>VI</b>
<b>ABBILDUNGSVERZEICHNIS</b> .....	<b>VII</b>
<b>ZUSAMMENFASSUNG</b> .....	<b>IX</b>
<b>ABSTRACT</b> .....	<b>X</b>
<b>1 EINLEITUNG</b> .....	<b>11</b>
<b>1.1 ARTIFIZIELLE INTELLIGENZ</b> .....	<b>13</b>
1.1.1 MASCHINELLES LERNEN.....	15
1.1.2 CONVOLUTIONAL NEURAL NETWORK .....	16
1.1.3 CNN-ARCHITEKTUREN .....	17
<b>1.2 MASCHINELLES LERNEN IN DER MEDIZIN UND ZAHNMEDIZIN</b> .....	<b>19</b>
1.2.1 ANWENDUNGSGEBIETE IN DER ZAHNMEDIZIN .....	20
<b>1.3 BILDGEBENDE VERFAHREN</b> .....	<b>32</b>
1.3.1 ORTHOPANTOMOGRAMM .....	32
1.3.2 INTRAORALES KLEINBILDRÖNTGEN .....	33
1.3.3 BISSFLÜGELRÖNTGEN.....	34
1.3.4 DIGITALE VOLUMENTOMOGRAPHIE .....	34
<b>1.4 METRIKEN</b> .....	<b>35</b>
<b>1.5 ZIEL DER LITERATURERECHERCH</b> .....	<b>36</b>
<b>2 MATERIAL UND METHODEN</b> .....	<b>37</b>
<b>2.1 SUCHSTRATEGIE UND DURCHSUCHUNG DER DATENBANKEN</b> .....	<b>37</b>
<b>2.2 DATENERHEBUNG UND ANALYSE</b> .....	<b>38</b>
2.2.1 AUSWAHLKRITERIEN FÜR DIE ARBEITEN .....	39
2.2.2 EXTRAKTION DER DATEN .....	39
2.2.3 AUSWERTUNG DER RELEVANTEN ARBEITEN.....	39
<b>3 ERGEBNISSE</b> .....	<b>40</b>
<b>3.1 SUCHE UND AUSWAHL DER LITERATUR</b> .....	<b>40</b>
3.1.1 INKLUDIERTER ARTIKEL .....	44
<b>3.2 ANWENDUNGSBEREICHE DER INKLUDIERTEN ARTIKEL</b> .....	<b>45</b>
<b>3.3 DATENSÄTZE UND ART DER BILDGEBUNG</b> .....	<b>47</b>
<b>3.4 FESTLEGUNG DES GOLDSTANDARDS</b> .....	<b>49</b>
<b>3.5 CNN-ARCHITEKTUREN</b> .....	<b>50</b>

3.5.1	VERWENDETE CNN-ARCHITEKTUREN .....	50
3.5.2	CNN-ARCHITEKTUREN UND METRIKEN.....	50
<b>4</b>	<b><u>DISKUSSION.....</u></b>	<b>52</b>
<b>4.1</b>	<b>VERGLEICH DER ARBEITEN BEZOGEN AUF DIE UNTERSCHIEDLICHEN ANWENDUNGSBEREICHE MIT RÜCKSICHT AUF DIE VERWENDETEN BILDGEBUNGSARTEN .....</b>	<b>52</b>
4.1.1	ANATOMISCHE STRUKTURERKENNUNG AUF DER GRUNDLAGE VON ORTHOPANTOMOGRAMMEN .....	53
4.1.2	KARIESDETEKTION AUF DER GRUNDLAGE VON ORTHOPANTOMOGRAMMEN .....	57
4.1.3	RADIOLOGISCHE PARODONTALANALYSE AUF DER GRUNDLAGE VON ORTHOPANTOMOGRAMMEN .....	57
4.1.4	ERKENNUNG PERIAPIKALER LÄSIONEN AUF DER GRUNDLAGE VON ORTHOPANTOMOGRAMMEN .....	59
4.1.5	KLASSIFIKATION ZYSTISCHER LÄSIONEN AUF DER GRUNDLAGE VON ORTHOPANTOMOGRAMMEN .....	60
4.1.6	ANATOMISCHE STRUKTURERKENNUNG AUF DER GRUNDLAGE VON DVT-DATEN .....	63
4.1.7	ERKENNUNG PERIAPIKALER LÄSIONEN AUF DER GRUNDLAGE VON DVT-DATEN.....	64
4.1.8	BELEUCHTUNG MEHRERE ANWENDUNGSBEREICHE AUF DER GRUNDLAGE VON DVT-DATEN .....	67
4.1.9	KARIESDETEKTION AUF DER GRUNDLAGE VON INTRAORALEN KLEINBILDAUFNAHMEN .....	68
4.1.10	IMPLANTATANALYSE AUF DER GRUNDLAGE VON INTRAORALEN KLEINBILDAUFNAHMEN .....	69
4.1.11	IMPLANTATANALYSE AUF DER GRUNDLAGE VON ORTHOPANTOMOGRAMMEN UND INTRAORALEN KLEINBILDAUFNAHMEN .....	71
4.1.12	KARIESDETEKTION AUF DER GRUNDLAGE VON BISSFLÜGEL RÖNTGENAUFNAHMEN .....	73
<b>5</b>	<b><u>KONKLUSION.....</u></b>	<b>76</b>
	<b><u>LITERATURVERZEICHNIS .....</u></b>	<b>78</b>

## Abkürzungen und deren Erklärung

Abb.: Abbildung

Tab.: Tabelle

CNN: Convolutional Neural Network; Faltungsneurales Netzwerk

AI: Künstliche Intelligenz

KI: Künstliche Intelligenz

ML: Machine learning; maschinelles Lernen

NN: Neuronal networks; Neuronale Netze

DL: deep learning

KDD: Knowledge Discovery in Databases

ResNet: Residual Network

YOLO: You Only Look Once

VGG Net: Visual Geometry Group

z.B.: zum Beispiel

i.e. : id est

e.g. : exempli gratia

OK: Oberkiefer

UK: Unterkiefer

UTN: Universal tooth numbering

FDI: Fédération Dentaire Internationale FDI

NILT: Nah-Infrarot-Transillumination

PSI: Parodontal-Screening-Index

PBI: Periodontal Bone Loss

PL: periapikale Läsion

CBCTPAI: Cone Beam Computed Tomography Periapical Index Score

AB: Ameloblastom

OKZ: Odontogene Keratozyste

DZ: dentinogene Zyste

PZ: periapikale Zyste

SBC: Staphne Knochenzyste

Sci. Rep.: Scientific Reports

IJCARS: International Journal of Computer Assisted Radiology and Surgery

Dmfr: Dentomaxillofacial Radiology  
Isdent: Imaging Science in Dentistry  
Clin. Med: Journal of Clinical Medicine  
Ann. Transl. Med.: Annals of Translational Medicine  
Endod. J.: International Endodontic Journal  
JOE: Journal of Endodontics  
OPG: Orthopantomogramm  
KB: Intraorales Kleinbildröntgen  
BF: Bissflügelröntgen  
DVT: Digitale Volumentomographie  
CAD: computergestützte Diagnose  
MW: Mittelwert  
SD: Standardabweichung  
AUC: Area under the Curve  
PPV: positive predictive value  
NPV: negative predictive value  
TPR: true positive rate  
Mean DSC: Mean Dice similarity coefficient  
OMS: oral and maxillofacial surgery specialists  
GP: general practitioners  
Indiv. CNN: individuell entworfene CNN-Architektur  
AOI: Area of Interest

## **Tabellenverzeichnis**

Tabelle 1 Suchergebnisse die in die Literaturübersicht integriert wurden .....	42
Tabelle 2 CNN-Modelle und Metriken.....	51

## Abbildungsverzeichnis

Abbildung 1 (a) Mögliche Beschriftungsstrategien für verschiedene zahnmedizinische Bildmodalitäten wie (von links nach rechts) NILT, BF oder Segmente, die aus OPGs extrahiert wurden. (b) Training eines neuronalen Netzes, demonstriert an dem BF zur Karieserkennung aus (a) - nach Schwendicke et al. [100].....	12
Abbildung 2 Künstliche Intelligenz und ihre Untergruppen (eigene Abbildung).....	14
Abbildung 3 Ergebnis der Faltung eines Bildes mit einem bestimmten Filter, der gut geeignet ist, um Kanten in einem Bild zu finden – nach Albawi et al. [30].....	17
Abbildung 4 Kanonische Form eines residualen neuronalen Netzes. Eine Schicht $\ell - 1$ wird über die Aktivierung von $\ell - 2$ übersprungen. – nach Targ et al. [50].....	18
Abbildung 5 Arbeitsablauf und Gesamtarchitektur des digitalen Workflows – nach Tuzoff et al. [8].....	21
Abbildung 6 Universal tooth numbering (UTN) System und Fédération Dentaire Internationale (FDI) system – nach Mahdi et al. [89].....	22
Abbildung 7 Erfolgreiche Nummerierung der gesamten Dentition nach - Mahdi et al. [89].....	22
Abbildung 8 (a) Darstellung einer beginnenden Kariesläsion, (b) Intraorale Kleinbildaufnahme mit hervorgehobener beginnender Läsion, (c) Darstellung einer fortgeschrittenen Kariesläsion, (d) Intraorale Kleinbildaufnahme mit hervorgehobener fortgeschrittener Läsion – nach Moran et al. [97].....	23
Abbildung 9 Beispiel für Bildvorverarbeitungsschritte: (a) Originalbild, (b) adaptive Histogramm-Entzerrung, (c) Otsu-Schwellenwert, (d) Erosion, (e) Schließen, (f) Dilatation und Definition der Zahnregion, (g) erhaltene Zahnbilder – nach Moran et al. [97].....	24
Abbildung 10 Panoramaröntgenbild Beispiele und kommentierte PBL-Läsionen nach Kim et al. [38] (Oben) Patient*innen Fälle ohne kommentierten parodontalen Knochenverlust, (Unten) Patient*innen Fälle mit kommentierten Läsionsmasken. Die Gutachter*innen gaben auch die entsprechenden Zahnnummern der PBL-Läsionen an. – nach Kim et al. [38] .....	26
Abbildung 11 Schematische Darstellung von Molaren nach der Einteilung von Estrela et al. [118].....	27
Abbildung 12 CBCTPAI (Cone Beam Computed Tomography Periapical Index Score) – nach Estrela et al. [118] .....	27
Abbildung 13 Beispiel für Klassifizierung von Zysten unterstützt durch CNN: Läsionen von Radiolog*innen kommentierte (durchgezogene Linie), Läsionen kommentiert durch ein CNN-Modell (gepunktete Linie) korrekt klassifiziert als odontogene Zyste (a), periapikale Zyste (b), odontogene Keratozyste (c) und Ameloblastom (d) ohne Datensatzerweiterung. Korrekt klassifiziert: (durchgezogene Linie) odontogene Zyste (e), periapikale Zyste (f), odontogene Keratozyste (g) und Ameloblastom (h) mit Datensatzerweiterung, falsch klassifiziert:	

(gepunktete Linie) odontogene Keratozyste (e), keine (f), odontogene Zyste (g) und follikuläre Zyste (h) ohne Datensatzerweiterung. – nach Kwon et al. [39].....	29
Abbildung 14 Periapikale Röntgenbilder vier unterschiedlicher Implantattypen. (a) Brånemark Mk TiUnite, (b) Dentium Implantium, (c) Straumann Bone Level und (d) Straumann Tissue Level Implantate. – Kim et al. [58] .....	31
Abbildung 15 Beispiele zweier intraoralen Bissflügelröntgenbilder – nach Pasler et al. [171] .....	34
Abbildung 16 PRISMA-Flow Chart zur Literatursuche (eigene Darstellung) .....	43
Abbildung 17 Anzahl der Publikationen im jeweiligen Jahr (eigene Darstellung) ..	44
Abbildung 18 Anzahl der Publikationen in den Jahren 2019 bis 2021 (eigene Darstellung) .....	44
Abbildung 19 Publikationsländer aller inkludierten Arbeiten (eigene Darstellung)	45
Abbildung 20 Anwendungsbereiche die von den Publikationen abgedeckt werden (eigene Darstellung) .....	46
Abbildung 21 Anzahl der Gutachter*innen der jeweiligen Publikationen (eigene Darstellung) .....	49
Abbildung 22 Arithmetisches Mittel der Spezifität und Sensitivität nach CNN- Architekturen (eigene Darstellung) .....	51

# Zusammenfassung

## **Einleitung:**

Maschinelles Lernen wird zunehmend für die medizinische Bilddiagnostik und in der Zahnmedizin eingesetzt. Diese Arbeit schafft einen Überblick über die zahlreichen Anwendungsgebiete in der modernen Zahnmedizin.

## **Material und Methoden:**

Die Datenbanken PubMed, Mendeley und Web of Science wurden systematisch durchsucht. Die Themenfelder „Artifizielle Intelligenz“, „Maschinelles Lernen“ und „Deep learning“, wurden mit Synonymen für die Recherche verwendet. Nach Definition der Ein- und Ausschlusskriterien (Jahr, Sprache, Fachgebiet, Art des Artikels) wurden die verbliebenen Arbeiten gesichtet.

## **Ergebnisse:**

Anfangs konnten 1632 Artikel extrahiert werden, wovon 1544 Einträge nach Anwendung spezifischer Filter und der Kontrolle auf Duplikate ausgeschlossen wurden. Schlussendlich konnten 24 Artikel inkludiert werden. Die diskutierten Themen wurden in sechs unterschiedliche Anwendungsgebiete unterteilt. Anatomische Strukturerkennung (n=8), Kariesdetektion (n=5), Radiologische Parodontalanalyse (n=4), Erkennung periapikaler Läsionen (n=4), Klassifikation zystischer Läsionen (n=4) und Implantatanalyse. Vier Bildgebungsarten (OPG, KB, BF, DVT) wurden herangezogen, das OPG wurde am häufigsten genutzt (n=16). Acht CNN-Architekturen wurden eingesetzt: Individuell entworfenes CNN (n=4), Inception (n=4), MobileNet (n=2), ResNet (n=6), SqueezeNet (n=2), U-Net (n=3), VGG (n=2) YOLO (n=3).

## **Konklusion:**

Die analysierten Studien haben gezeigt, dass die KI in einigen Fachbereichen der Zahnmedizin weit verbreitet ist. Sie ist auf gutem Weg, ein wertvolles Hilfsmittel für das Fachpersonal zu werden. Obwohl weitere Forschungsarbeiten erforderlich sind, zeigen sich erste vielversprechende Schritte zur Realisierung eines ML-basierten Hilfsmittels. Vor allem für unerfahrenere Zahnärzt\*innen könnte das hilfreich sein, da sie eine exakte Diagnosestellung erleichtern. Durch die unterstützenden Algorithmen könnte eine Zeitersparnis erreicht werden, was im oft stressigen klinischen Alltag vorteilhaft sein kann.

# Abstract

## Introduction:

Machine learning is increasingly used for medical image diagnosis and in dentistry. This paper provides an overview of the numerous applications in modern dentistry.

## Material and Methods:

PubMed, Mendeley, and Web of Science databases were systematically searched. The subject areas "artificial intelligence", "machine learning" and "deep learning", were used with synonyms for the search. After defining the inclusion and exclusion criteria (year, language, subject area, type of article), the remaining papers were screened.

## Results:

Initially, 1632 articles could be extracted, of which 1544 entries were excluded after applying specific filters and checking for duplicates. Finally, 24 articles could be included. The discussed topics were divided into six different application areas. Anatomical structure detection (n=8), caries detection (n=5), radiographic periodontal analysis (n=4), periapical lesion detection (n=4), cystic lesion classification (n=4), and implant analysis. Four imaging modalities (OPG, KB, BF, DVT) were used, and OPG was the most frequently used (n=16). Eight CNN architectures were used: Individually designed CNN (n=4), Inception (n=4), MobileNet (n=2), ResNet (n=6), SqueezeNet (n=2), U-Net (n=3), VGG (n=2) YOLO (n=3).

## Conclusion:

The studies analyzed showed that AI is widely used in some dental specialties. It is well on its way to becoming a valuable tool for professionals. Although further research is needed, the first promising steps toward realizing an ML-based aid are emerging. This could be especially helpful for more inexperienced dentists by facilitating accurate diagnosis. The supporting algorithms could save time, which can be beneficial in the often stressful clinical routine.

# 1 Einleitung

In der Medizin hat sich ein Großteil der jüngsten Forschung auf die Entwicklung von diagnostischen und therapeutischen Werkzeugen der künstlichen Intelligenz (KI) zur Unterstützung von klinischen Entscheidungsprozessen konzentriert [1-4].

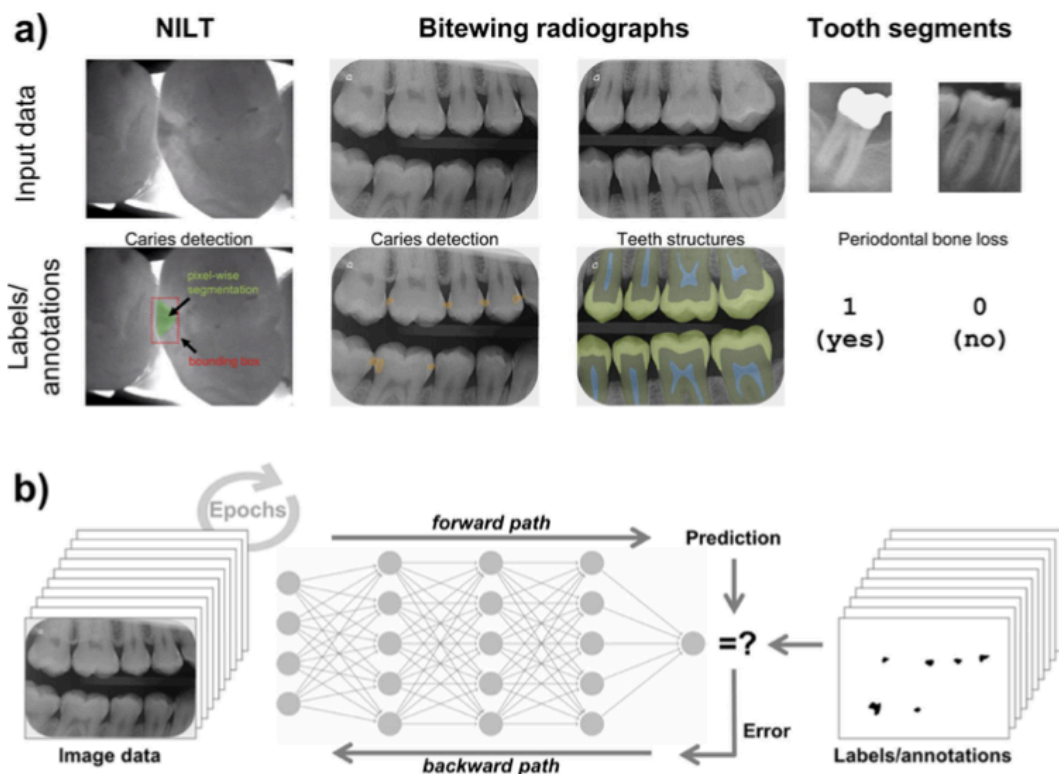
Immer häufiger werden Techniken aus dem Bereich der künstlichen Intelligenz eingesetzt. Deep Learning unter der Verwendung von Faltungsneuronalen Netzen (CNN) hat sich als bemerkenswertes Potenzial erwiesen, um Ärzt\*innen in Bereichen wie der Dermatologie (zur Erkennung von Hautkrebs), der Augenheilkunde (zur Erkennung und Unterscheidung verschiedener Arten von Retinopathie) und der Radiologie (z. B. zur Erkennung von Anomalien in Röntgenaufnahmen der Brust) zu unterstützen [5-7]. Obwohl CNNs das Potenzial haben Pathologien und anatomische Strukturen auf medizinischen Bildern mit ähnlicher oder sogar höherer Genauigkeit zu erkennen als medizinisches Fachpersonal, gibt es jedoch auch Hinweise auf potenzielle Verzerrungen in den Algorithmen [8].

Die Interpretation von Röntgenbildern ist ein wesentlicher Bestandteil der Diagnose, der Kontrolle und der etwaigen Behandlungsplanung im Bereich der Zahnmedizin. Obwohl CAD-Systeme bereits seit Jahrzehnten im klinischen Umfeld eingesetzt werden, zielen sie in den meisten Fällen nicht darauf ab die medizinischen Expert\*innen zu ersetzen, sondern sie zu unterstützen [9, 10]. Automatisierte Lösungen könnten Zahnärzt\*innen bei klinischen Entscheidungsfindungen unterstützen, Zeit sparen und negativen Auswirkungen von Stress und Ermüdung in der täglichen Praxis verringern [9].

CNNs erfüllen Aufgaben wie (1) die Erkennung von Strukturen (Entscheidung, ob anatomisch relevante Struktur (e.g., ein Zahn, ein Organ) oder Pathologien (z. B. Knoten in der Lunge, Kariesläsionen an Zähnen) auf einem Bild (2) der Segmentierung dieser Strukturen (e.g., Identifizierung der genauen Form eines Organs, eines Zahns oder der Pathologie auf einem Bild) und (3) der Klassifizierung dieser Strukturen (e.g., die Fähigkeit, die linke von der rechten Niere zu trennen

oder jeden Zahn in einem Gebiss zu kennzeichnen, erworbene und entwicklungsbedingte Schmelzläsionen voneinander zu unterscheiden).

Zu diesem Zweck werden CNNs mit Hilfe von Bilddatenpaaren (i.e., Bild mit einem entsprechenden Ergebnis) trainiert. Je nach Aufgabe kann dieses Ergebnis eine eindeutige Kennzeichnung sein, wie "betroffen" oder "nicht betroffen" oder eine Liste von Kennzeichnungen mit zugehörigen Bereichen auf dem Bild, welche die entsprechende Struktur oder pathologische Region abbilden (e.g., Bezeichnung eines Zahnes oder Pathologien). Durch die Wiederholung der Daten wird die interne Struktur des CNN optimiert, um dann die jeweilige Struktur der Eingangsdaten und ihre Zuordnung darzustellen [11]. Der Trainingsprozess wird so lange wiederholt, bis die Vorhersagekraft des Modells die Zuordnung eines Eingangsbildes zu einem bestimmten Label ermöglicht (**Abbildung 1**).



**Abbildung 1** (a) Mögliche Beschriftungsstrategien für verschiedene zahnmedizinische Bildmodalitäten wie (von links nach rechts) NILT, BF oder Segmente, die aus OPGs extrahiert wurden. (b) Training eines neuronalen Netzes, demonstriert an dem BF zur Karieserkennung aus (a) - nach Schwendicke et al. [100]

## **1.1 Künstliche Intelligenz**


Das exponentielle Wachstum von Wissenschaft und Technologie hat unterschiedliche Anwendungen hervorgebracht, die wir täglich in unserem Leben benutzen (e.g., die weltweit verwendeten Anwendungen Siri oder Alexa). Derartige Anwendungen sind die bekanntesten Beispiele für die künstliche Intelligenz (KI) und ihre Untergruppen. Der Begriff künstliche Intelligenz (AI) wird meist mit der Robotik in Verbindung gebracht. AI beschreibt, wie unterschiedliche Technologien eingesetzt werden, um eine Software oder eine Maschine so zu programmieren oder entwickeln, dass sie die menschliche Intelligenz nachahmen kann und bestimmte Funktionen ausführt [12].

John McCarthy prägte bereits im Jahre 1955 den Begriff „artificial intelligence“ und gilt somit als Vater der künstlichen Intelligenz. Er wählte diesen Begriff um zu beschreiben, dass Maschinen Aufgaben ausführen können die in den Bereich der „intelligenten“ Aktivitäten fallen [13].

Die berühmte Dartmouth Konferenz im Jahr 1956 befasste sich erstmals offiziell mit dem Forschungsprojekt der künstlichen Intelligenz – es war die Geburtsstunde dieses Wissenschaftsbereichs. Diese Konferenz leitete die entscheidende Periode zwischen den 1950er und 1970er Jahren ein, in der umfangreiche Forschungen im Bereich der KI durchgeführt wurden [14, 15].

1978 definierte Richard Bellman AI als die Automatisierung von Tätigkeiten, die mit menschlicher Denkfähigkeit verbunden sind, wie zum Beispiel Lernen, Entscheidungsfindung oder Problemlösung [16].

In der heutigen, modernen Welt bezieht sich die KI auf jede Maschine und Technologie, die in der Lage ist menschliche kognitive Fähigkeiten zu imitieren [17-20]. Um die künstliche Intelligenz verstehen zu können, ist es wichtig folgende Schlüsselaspekte zu kennen (**Abbildung 2**).



- Artificial intelligence wird als Fähigkeit von Maschinen bezeichnet, die eine Form von Intelligenz aufweisen. Ziel ist es, Maschinen zu entwickeln, die durch Daten lernen können und somit Probleme lösen können.
- Machine learning ist ein Teil der artifiziellen Intelligenz, die sich auf Algorithmen stützt, um Ergebnisse auf der Grundlage eines Datensatzes vorherzusagen. Ziel ist es, Maschinen das Lernen aus Daten zu erleichtern, damit sie Probleme ohne menschliche Hilfe lösen können.
- Neuronal Networks sind eine Reihe von Algorithmen, die Signale über künstliche Neuronen berechnen. Ziel ist es, neuronale Netze zu schaffen, die wie das menschliche Gehirn funktionieren.
- Deep Learning ist eine Komponente des maschinellen Lernens, die das Netzwerk mit verschiedenen Berechnungsschichten in einem tiefen neuronalen Netzwerk nutzt, um die Eingabedaten zu analysieren. Ziel ist es, ein neuronales Netz zu konstruieren, das automatisch Muster erkennt, um die Merkmalerkennung zu verbessern [21].

### 1.1.1 Maschinelles Lernen

Die Filterung von Spam-Nachrichten, automatisierte Diagnoseverfahren, Erkennung von Objekten auf Bildern, Spracherkennung sind nur wenige Beispiele, welche auf der Technologie des maschinellen Lernens beruhen. All jene Tätigkeiten, die eine regelmäßige Datenverarbeitung erfordern, lassen sich durch maschinelle Lernverfahren gezielt unterstützen [22, 23].

Ganz allgemein ist das maschinelle Lernen der Informatik zuzuordnen. Genauer handelt es sich um einen Teilbereich der künstlichen Intelligenz, welcher sich mit der computergestützten Problemlösung befasst [12, 24].

Dabei werden mit Hilfe von Computern, Systeme entwickelt, die in der Lage sind aus Daten zu lernen, ohne sie explizit programmieren zu müssen. Diese Systeme lernen und verbessern sich mit zunehmender Erfahrung und entwickeln mit der Zeit ein Modell, das zur Vorhersage, auf der Grundlage des vorherigen Lernens, verwendet werden kann [24, 25].

Die Basis des maschinellen Lernens bildet ein künstliches System, welches in der Lage ist, aus Erfahrungswerten Wissen zu generieren und aus Beispielen zu lernen. Nach vollendeter Lernphase werden die daraus gewonnenen Daten verallgemeinert und darauf aufbauend Algorithmen angewandt. Dadurch wird anhand von Trainingsdaten ein Algorithmus entwickelt, welcher gegen Testdaten getestet wird. Dies geschieht durch das Erkennen von Mustern und Gesetzmäßigkeiten in den Lerndaten, dadurch kann das System auch unbekannte Daten beurteilen [22, 26].

Mittlerweile wird maschinelles Lernen in zahlreichen Anwendungsgebieten der Medizin aber auch in vielen anderen Bereichen verwendet. Beispielsweise in Bereichen wie der Dermatologie (zur Erkennung von Hautkrebs), der Augenheilkunde (zur Erkennung und Unterscheidung verschiedener Arten von Retinopathie) und der Radiologie (z. B. zur Erkennung von Anomalien in Röntgenaufnahmen der Brust) [5-7]. Tan et al. [27] beschreiben in ihrer Arbeit zum Beispiel die Anwendung von ML im Bezug auf die Vorhersage von Studienabbrüchen eines E-Learning Programms. In diesen werden aus Daten

Erkenntnisse zur Lösung praktischer Probleme abgeleitet. Das maschinelle Lernen hat sich zu einem eigenständigen Bereich entwickelt, in dem Probleme gelöst werden, die über die klassischen Probleme der künstlichen Intelligenz hinausgehen [24, 28].


### **1.1.2 Convolutional Neural Network**

Ein Convolutional Neural Network (CNN) ist eine spezielle Art eines künstlichen neuronalen Netzes, das eine mathematische Operation (Faltung) verwendet. CNNs sind leistungsfähige Algorithmen aus dem Gebiet des maschinellen Lernens, wobei die Inspiration des Konzepts von biologischen Prozessen stammt. Diese biologisch inspirierten Computermodelle sind in der Lage, die Leistung früherer Formen künstlicher Intelligenz bei gängigen maschinellen Lernaufgaben weit zu übertreffen [29, 30].

Anwendung finden CNNs hauptsächlich im Bereich der Bilderkennung und -verarbeitung, Bildklassifizierung und der medizinischen Bildanalyse, da sie speziell für die maschinelle Verarbeitung von Pixeldaten konzipiert sind. CNNs werden in erster Linie zur Lösung schwieriger bildgesteuerter Mustererkennungsaufgaben eingesetzt, sie bieten eine präzise und dennoch einfache Architektur. Das neuronale Netz ist speziell für die Arbeit mit Daten mit räumlichen Eigenschaften konzipiert. Seit dem Einsatz von Grafikprozessor-Programmierung können CNNs erstmals effizient trainiert werden. Sie gelten als State-of-the-Art-Methode für zahlreiche Anwendungen im Bereich der Klassifizierung. Häufig erreichen sie eine Fehlerquote von nur 0,23 % auf eine der am häufigsten genutzten Bilddatenbanken, was einer sehr geringen Fehlerquote vieler getesteter Algorithmen entspricht. Auch im Bereich der Gesichtserkennung konnten bahnbrechende Resultate erzielt werden [29-31].

Die Struktur eines klassischen CNNs besteht grundsätzlich aus drei verschiedenen Schichten. Es handelt sich um die Faltungsschicht, die Pooling-Schicht und die vollständig verknüpfte Schicht. Legt man diese Schichten übereinander, entsteht ein tiefes neuronales Faltungsnetz, welches man als CNN-Architektur bezeichnet. Die Faltungsschicht spielt bei der Funktionsweise von CNNs eine entscheidende Rolle, da sie die Eingaben filtert, um nützliche Merkmale innerhalb dieser Eingaben zu

finden (**Abbildung 3**). Dieser Filterungsvorgang wird als Faltung bezeichnet. Darum wird es Faltungsneurales Netz genannt [31, 32].



**Abbildung 3** Ergebnis der Faltung eines Bildes mit einem bestimmten Filter, der gut geeignet ist, um Kanten in einem Bild zu finden – nach Albawi et al. [30]

Die Faltungsoperation ist eine lineare Operation, die zwei Signale zusammenführt.

Zweidimensionale Faltungen werden in der Bildverarbeitung verwendet, um Bildfilter zu implementieren, beispielsweise um einen bestimmten Fleck oder ein bestimmtes Merkmal, eine bestimmte Struktur in einem Bild zu finden [29, 32, 33].


Verglichen mit anderen Algorithmen zur Bildklassifizierung benötigen CNNs relativ wenig Vorverarbeitung. Das bedeutet, dass das Netzwerk lernt, die Filter durch automatisches Lernen zu optimieren. Während diese Filter bei herkömmlichen Algorithmen vom Menschen entwickelt werden müssen. Diese Unabhängigkeit von Vorkenntnissen und menschlichen Eingriffen ist ein großer Vorteil [32-34].

### 1.1.3 CNN-Architekturen

In den Arbeiten, die dieser Literatursuche zugrunde liegen, wurden unterschiedliche CNN- Architekturen angewendet [35-48].

- ResNet
- U-Net
- Inception
- MobileNet
- YOLO
- SHN
- VGG
- SqueezeNet

ResNet (ResidualNetwork) ist eine sehr häufig verwendete CNN-Architektur [49, 50]. Das Modell wurde 2015 erstmals vorgestellt. Es handelt sich um eines der ersten funktionierenden Modelle, welches sehr tief ist und hunderte Faltungsschichten nutzt. Die Kernidee von ResNet ist die Einführung einer sogenannten "Identitätskurzschlussverbindung", die eine oder mehrere Schichten überspringt (**Abbildung 4**) [50, 51].



**Abbildung 4** Kanonische Form eines residualen neuronalen Netzes. Eine Schicht  $l - 1$  wird über die Aktivierung von  $l - 2$  übersprungen. – nach Targ et al. [50]

U-Net wurde speziell für die Bildsegmentierung im biomedizinischen Bereich auf der Universität Freiburg entwickelt [52]. Dieses Modell wurde so modifiziert und erweitert, dass es mit Hilfe einer geringen Datenmenge gut trainierbar ist und präzise Ergebnisse liefern kann. Die Hauptidee besteht darin, ein gewöhnliches kontrahierendes Netz durch aufeinanderfolgende Schichten zu ergänzen, in denen Pooling-Operationen durch Upsampling-Operatoren ersetzt werden. Diese Schichten erhöhen somit die Auflösung der Ausgabe. Eine nachfolgende Faltungsschicht kann dann lernen, auf der Grundlage dieser Informationen eine präzise Ausgabe zusammenzustellen [53]. Außerdem ist es im Stande, Bilddaten in wenigen Sekunden zu segmentieren [52, 54].

Ein besonderer Vorteil des Netzwerks YOLO (You Only Look Once) ist, dass das Modell in der Lage ist verallgemeinerte Objektdarstellungen zu verstehen. Das ermöglicht die Anwendung auf realen Bildern [55, 56].

VGG Net (Visual Geometry Group) ist der Name eines vortrainierten neuronalen Faltungsnetzwerks, es handelt sich um eine vortrainierte, tiefe CNN-Architektur mit mehreren Schichten. VGG-16 oder VGG-19 aus 16 und 19 Faltungsschichten besteht [51, 57].

Häufig wird in der Literatur eine Kombination der unterschiedlichen CNN-Modelle beschrieben, um die gewünschten Ergebnisse zu erzielen [42, 57, 58].

## ***1.2 Maschinelles Lernen in der Medizin und Zahnmedizin***

Die ersten Berichte über die Anwendbarkeit von maschinellem Lernen in der Medizin erschienen Anfang der 1970er Jahre mit dem Aufkommen einiger experimenteller Computersysteme und der neuen chirurgischen Forschung von Gunn, der die Möglichkeit untersuchte akute Unterleibsschmerzen mit Hilfe von Computerdatenanalysen zu diagnostizieren [59-61].

Die größten Fortschritte beim Einsatz von KI-Techniken in der Medizin beschränken sich auf die Prognose und Diagnose von Krankheiten und ermöglichen so klinische Entscheidungen durch die Anwendung von Algorithmen des maschinellen Lernens (ML) zu unterstützen [62]. Einige durchgeführte Arbeiten belegen die vielversprechenden Erwartungen, welche durch die Anwendung dieser Technologien möglich wurden [5, 63-68]. Morgan et al. [68] nutzen KI-Modelle um die Vorhersage von Krankenhauswiederaufnahmen vorherzusagen. Im Bereich der Augenheilkunde entwickelten Gulshan et al. [5] einen DL-Algorithmus, der die Erkennung von diabetischer Retinopathie in Netzhautfundusfotografien ermöglicht. Auch im Fachbereich der Onkologie werden computerunterstützte Systeme eingesetzt, Sultan et al. [69] beschreiben die Anwendung in der onkologischen Histopathologie.

Die Anwendung von ML wurde auch auf andere Bereiche des Gesundheitswesens, einschließlich der Zahnmedizin, ausgeweitet. Der wissenschaftlichen Literatur zufolge begannen die Berichte über die positiven Ergebnisse durch Anwendung der ML-Techniken in den unterschiedlichen klinischen Disziplinen der Zahnmedizin in den frühen 1990er Jahren. Die Kieferorthopädie wird als eines der Fachgebiete hervorgehoben, in denen schon früh der Einsatz von ML spürbare Vorteile gebracht hat; insbesondere durch die Extraktion von Merkmalen aus Fernröntgenbildern oder OPGs [70-76]. Viele Studien in denen Data Mining eingesetzt wurde, haben zuverlässige Ergebnisse für die Differentialdiagnose eines breiten Spektrums von oralen Erkrankungen erbracht [77, 78]. Eine hohe Diagnosegenauigkeit kann zu einer Standardisierung der Verfahren führen und dadurch eine Zeitoptimierung bei der Analyse großer Datenbanken ermöglichen. Darüber hinaus berichten frühere Studien über Fortschritte in der Kariologie – sowohl bei der Erstellung von prädiktiven Risikomodellen als auch bei der Schätzung nützlicher Muster bei der Diagnose [79-86]. Die jüngsten Anwendungen von ML in diesen Bereichen können daher in Zukunft zu Verbesserungen der Diagnose und der Prognose verschiedener Erkrankungen der Zähne beitragen [60]. Arijj et al. [77] untersuchten beispielsweise ob Röntgendurchlässige Läsionen des Unterkiefers mit Hilfe von Deep Learning erkannt werden können und konnten Ergebnisse mit einer Sensitivität 88% erreichen.

### **1.2.1 Anwendungsgebiete in der Zahnmedizin**

In den meisten publizierten Arbeiten zum Thema des maschinellen Lernens in der Zahnmedizin wurden sechs unterschiedliche Anwendungsbereiche behandelt [35-38, 42-45, 48]:

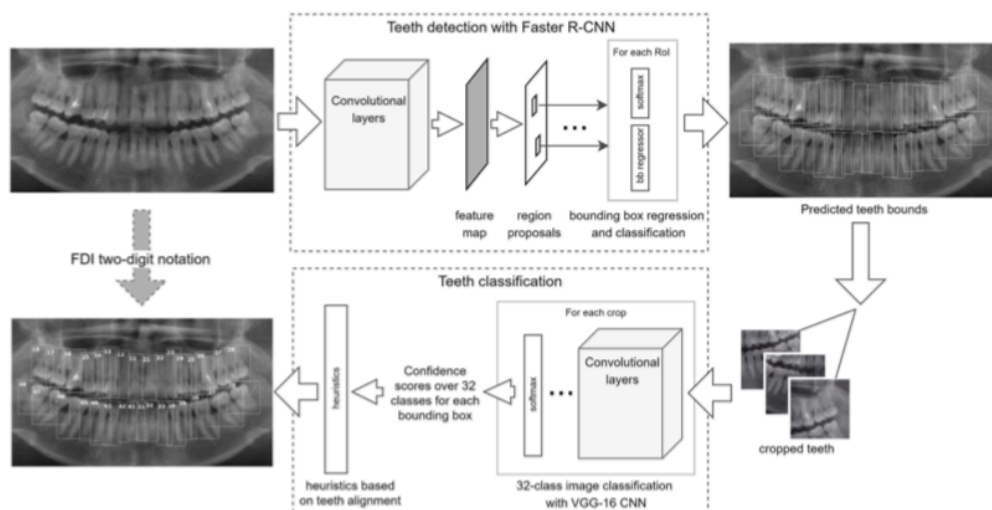
- Anatomische Strukturerkennung
- Kariesdetektion
- Radiologische Parodontalanalyse
- Erkennung periapikaler Läsionen
- Klassifikation zystischer Läsionen
- Implantatanalyse

### 1.2.1.1 Anatomische Strukturerkennung


In einigen Publikationen wurde das Problem der Zahnerkennung und -nummerierung in zahnärztlichen Röntgenbildern gemäß der zweistelligen FDI-Notation untersucht [87-89].

Eine algorithmische Lösung kann verwendet werden, um digitale Patient\*innendatensätze für die zahnärztliche Anamnese und Behandlungsplanung automatisch auszufüllen. Sie kann auch als Vorverarbeitungsschritt für die weitere Pathologieerkennung dienen.


Als Eingabe für das hier vorgestellte System werden Panoramaröntgenbilder verwendet. Das Zahnerkennungsmodul verarbeitet das Röntgenbild, um die Grenzen der einzelnen Zähne zu definieren. Anschließend schneidet das System das Panoramaröntgenbild auf der Grundlage der vorhergesagten Bounding Boxes zu (**Abbildung 5**). Das Modul zur Nummerierung der Zähne klassifiziert jeden beschnittenen Bereich gemäß der FDI-Notation, kombiniert alle Zähne und wendet die Heuristik an, um die endgültigen Zahnnummern zu ermitteln (**Abbildung 6**) [87]. Das System gibt die Koordinaten der Begrenzungsrahmen und die entsprechenden Zahnnummern für alle erkannten Zähne auf dem Bild aus. Die Gesamtarchitektur und der Arbeitsablauf sind in den **Abbildung 5** dargestellt.



**Abbildung 5** Arbeitsablauf und Gesamtarchitektur des digitalen Workflows – nach Tuzoff et al. [8]



**Abbildung 6** Universal tooth numbering (UTN) System und Fédération Dentaire Internationale (FDI) system – nach Mahdi et al. [89]

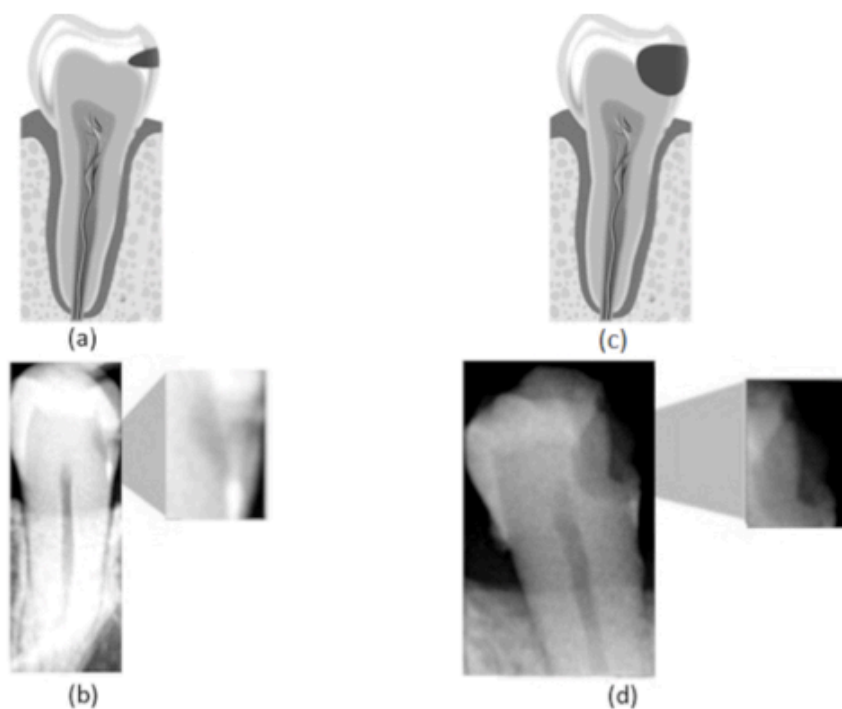


**Abbildung 7** Erfolgreiche Nummerierung der gesamten Dentition nach - Mahdi et al. [89]

### 1.2.1.2 Kariesdetektion

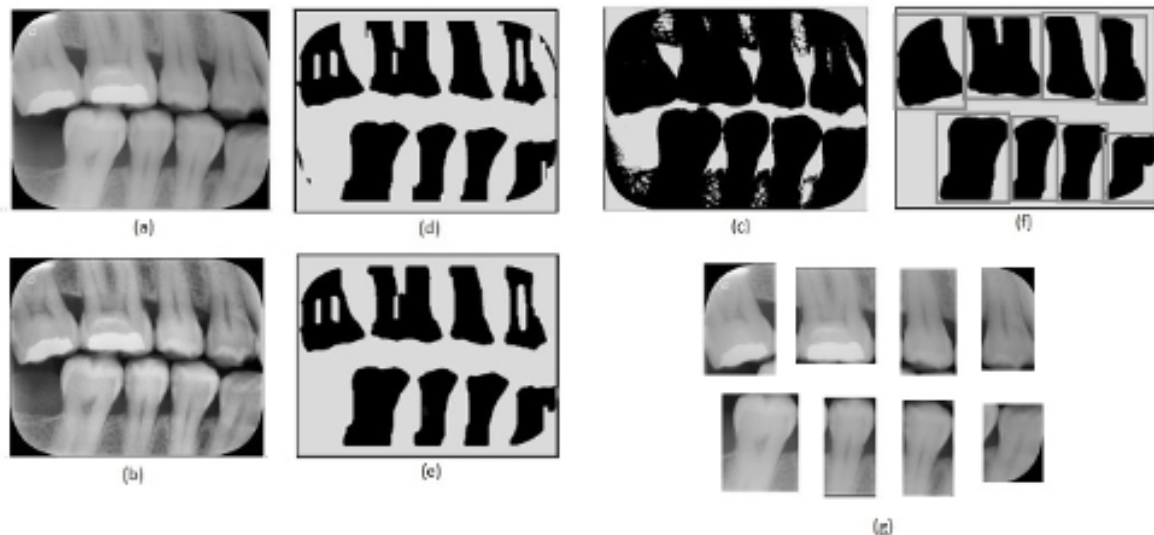
Dentale Karies ist eine häufige chronische orale Infektionskrankheit, von der Kinder, Jugendliche und Erwachsene weltweit betroffen sind. Jährlich wird eine Vielzahl an neuen Infektionen dokumentiert [90-92]. Die Kariesprävalenz nimmt vom Säuglings- bis zum Jugendalter rasch zu. Sie weist eine epidemiologische Charakteristik auf, die nach der Adoleszenz leicht beibehalten wird [93]. Daher sollte Karies bereits im Kindesalter behandelt werden, da unbehandelte Karies im Milchgebiss in weiterer Folge zu Karies an den bleibenden Zähnen und zu oralen Erkrankungen führen kann [94, 95].

Aufgrund mangelnder Früherkennung werden Kariesläsionen jedoch häufig in fortgeschrittenen Stadien entdeckt, in denen eine Restauration die einzige wirksame Behandlung darstellt (**Abbildung 8**) [96]. Neben der Frühdiagnose ist die korrekte Definition des Stadiums der Läsion für eine aussagekräftige Behandlungsplanung unerlässlich.



**Abbildung 8** (a) Darstellung einer beginnenden Kariesläsion, (b) Intraorale Kleinbildaufnahme mit hervorgehobener beginnender Läsion, (c) Darstellung einer fortgeschrittenen Kariesläsion, (d) Intraorale Kleinbildaufnahme mit hervorgehobener fortgeschrittener Läsion – nach Moran et al. [97]

Die Diagnose kariöser Läsionen umfasst in der Regel nicht nur die klinische Untersuchung, sondern auch die Interpretation von Röntgenaufnahmen. Die Diagnose von Approximalraumkaries erfolgt insbesondere durch Bissflügelröntgenaufnahmen, da die Lokalisation solcher Läsionen eine suffiziente klinische Identifizierung verhindert (**Abbildung 9**) [97].



**Abbildung 9** Beispiel für Bildvorverarbeitungsschritte: (a) Originalbild, (b) adaptive Histogrammentzerrung, (c) Otsu-Schwellenwert, (d) Erosion, (e) Schließen, (f) Dilatation und Definition der Zahnregion, (g) erhaltene Zahnbilder – nach Moran et al. [97]

Die visuelle Darstellung von Zahnkaries in Bissflügelaufnahmen besteht aus einem dunklen Bereich aufgrund ihrer geringen Röntgenabsorption [98]. Ein breites Spektrum verschiedener Phänomene kann Bissflügelaufnahmen beeinträchtigen, wie z. B. das zervikale Burnout, welches schwer zu erkennen sein kann [99]. Aus diesem Grund kann der Einsatz von ergänzenden Werkzeugen auf der Grundlage von Computertechniken helfen, exaktere Befunde zu erzielen. Wenn man die Analyse von Röntgenbildern als ergänzendes Diagnoseinstrument betrachtet, hat der Einsatz von Convolutional Neural Networks (CNNs) zur Unterstützung der Identifizierung verschiedener Läsionen vielversprechende Ergebnisse gezeigt [46, 97, 100]. Gute Ergebnisse können beispielsweise in der Publikation von Zheng et al. [46] aus dem Jahr 2021 gezeigt werden. Es wurde eine Genauigkeit von 95% erzielt [46].


### 1.2.1.3 Radiologische Parodontalanalyse

Parodontitis gehört zu den am weitesten verbreiteten Krankheiten der Menschheit. Sie belastet eine Vielzahl von Menschen und führt unbehandelt zu Zahnmobilität und Zahnverlust. Um die Parodontitis suffizient behandeln zu können sind die Früherkennung und Parodontaltherapie erforderlich. Klinisch basiert die Erkennung und Diagnose von Parodontalerkrankungen auf der Beurteilung von Sondierungstaschen und Gingivarezessionen. Diese Messungen führen weiters zur Erhebung des Attachmentverlusts. Diese klinische Bewertung ist jedoch nur begrenzt zuverlässig und ein Screening auf Parodontalerkrankungen (e.g., mit dem Parodontal-Screening-Index, PSI) ist sowohl ein diagnostischer Aufwand und birgt gleichzeitig die Möglichkeit, lokalisierte parodontale Gewebeverluste zu übersehen [101].

Zur Erkennung und Bewertung des durch Parodontalerkrankungen bedingten Knochenverlusts ist die Röntgenaufnahme eine häufig zusätzliche angewandte Methode (**Abbildung 10**) [102]. Während Bissflügelröntgen oder das intraorale Kleinbild häufig als Standard für die Beurteilung von parodontalem Knochenverlust (PBL) angesehen werden, stützt sich die röntgenologische Erkennung von PBL auch auf Panoramaschichtaufnahmen. Es wurde festgestellt, dass intraorale mit Panorama Röntgenaufnahmen bezüglich der PBL weitgehend übereinstimmen und OPGs eine enge Korrelation mit dem PSI aufweisen [103, 104]. Panoramaröntgenbilder können die klinische Beurteilung von PBL ergänzen und unterstützen.

Die Erfassung der PBL auf Röntgenbildern ist jedoch durch mangelnde Genauigkeit und Zuverlässigkeit unter verschiedenen Untersucher\*innen eingeschränkt. Dies wurde in einer Vielzahl von Studien und im Vergleich zu verschiedenen Referenztests nachgewiesen [105, 106]. Daher wurde der Ruf nach automatisierten Assistenzsystemen für die Analyse von Röntgenbilddaten laut [107]. Solche automatisierten Systeme könnten eine zuverlässigere und genauere Bewertung von PBL auf Panoramaröntgenbildern ermöglichen. Für solche Panoramabilder scheinen automatisierte Assistenzsysteme besonders nützlich zu sein, da für eine

systematische, umfassende und zuverlässige Beurteilung hohe menschliche Ressourcen erforderlich sind.



**Abbildung 10** Panoramarröntgenbild Beispiele und kommentierte PBL-Läsionen nach Kim et al. [38] (Oben) Patient\*innen Fälle ohne kommentierten parodontalen Knochenverlust, (Unten) Patient\*innen Fälle mit kommentierten Läsionsmasken. Die Gutachter\*innen gaben auch die entsprechenden Zahnnummern der PBL-Läsionen an. – nach Kim et al. [38]


#### 1.2.1.4 Erkennung periapikaler Läsionen

Die Erkennung von periapikalen Aufhellungen in einem Panoramarröntgenbild ist eine häufige und wichtige Aufgabe für Zahnmediziner\*innen [108]. Meist handelt es sich um entzündliche Läsionen, von denen über 90 % als apikale Granulome, apikale Zysten oder Abszesse klassifiziert werden können [109]. Die Prävalenz periapikaler Aufhellungen in Röntgenbildern, die in zahnärztlichen Ambulanzen/Praxen aufgenommen werden, wird durchschnittlich mit etwa 9-10 % angegeben [108, 110]. Die apikale Parodontitis ist durch ein Immunzellinfiltrat und Knochenzerstörung gekennzeichnet und tritt bei 34 % bis 61 % der Individuen und 3 % bis 4 % der Zähne auf [111-113].

Die Inzidenz von Zysten und Granulomen reicht von 6 bis 55 % bzw. von 46 % bis 94 % [114, 115]. Die apikale Parodontitis ist röntgenologisch als periapikale Radioluzenz zu erkennen. Untersuchungen haben gezeigt, dass eine Zyste von

periapikalen Granulomen unterschieden werden kann, da sie einen deutlichen Dichteunterschied zwischen dem Inhalt des Zystenraums und dem granulomatösen Gewebe aufweist [116, 117]. Häufig handelt es sich um einen Zufallsbefund, der auf periapikalen Röntgenbildern, Panoramaröntgenaufnahmen und CBCT-Scans (Cone-Beam-Computertomographie) entdeckt wird [114].

Estrela et al. [118] klassifizieren in ihrer Arbeit von 2008 einen Index, der eine genaue Einteilung von Größe und Schweregrad periapikaler Läsionen auf DVT Bildern ermöglicht. Dafür werden die Läsionen vermessen und anschließend eingeteilt, wie in den **Abbildung 11** **Abbildung 12** veranschaulicht. Trotz Klassifikation der Läsionen ist es schwer einheitliche Aussagen über die Größe und den Schweregrad der Läsionen zu treffen. Da in den meisten Fällen mehrere Gutachter\*innen mit der Begutachtung der Läsionen beauftragt werden. In diesem Fall spricht man von dem Problem der inter- und intraobserver Accuracy. Die Interobserver Accuracy ist die Genauigkeit der Übereinstimmungen bei der Befundung zwischen unterschiedlichen Gutachter\*innen und von der Intraobserver Accuracy spricht man bei den Übereinstimmungen einer einzelnen Person [119]. Dutra et al. [120] machen in ihrer Studie von 2016 auf dieses Problem aufmerksam. Eine verspätete Diagnose dieser röntgendurchlässigen periapikalen Veränderungen kann zu einer Ausbreitung der Krankheit auf das umliegende Gewebe und in weiterer Folge bis hin zu lebensbedrohlichen Komplikationen führen [121].



**Abbildung 11** Schematische Darstellung von Molaren nach der Einteilung von Estrela et al. [118]

Score	Quantitative Bone Alterations in Mineral Structures
0	Intact periapical bone structures
1	Diameter of periapical radiolucency > 0.5–1 mm
2	Diameter of periapical radiolucency > 1–2 mm
3	Diameter of periapical radiolucency > 2–4 mm
4	Diameter of periapical radiolucency > 4–8 mm
5	Diameter of periapical radiolucency > 8 mm
Score (n) + E*	Expansion of periapical cortical bone
Score (n) + D*	Destruction of periapical cortical bone

\*The variables E (expansion of cortical bone) and D (destruction of cortical bone) were added to each

**Abbildung 12** CBCTPAI (Cone Beam Computed Tomography Periapical Index Score) – nach Estrela et al. [118]

### 1.2.1.5 Klassifikation zystischer Läsionen

Zysten und Tumore des Kieferknochens sind in den meisten Fällen schmerzlos und symptomlos, es sei denn, sie werden so groß, dass sie durch Verdrängung Symptome verursachen oder den Knochen so schwächen, dass es zu pathologischen Frakturen kommt [122, 123]. Die fehlende Symptomatik solcher Läsionen im Anfangsstadium führt zur verzögerten Diagnose und anschließend zu invasiveren Behandlungen [124]. Eine frühzeitige Diagnose ist daher essentiell und hilft zahngesunde Lebensjahre zu gewährleisten [125, 126].


Die meisten dieser Läsionen werden durch routinemäßige Röntgenuntersuchungen in einem früheren Stadium erkannt [127]. Tatsächlich werden zystische Läsionen oft als Zufallsbefund auf Panoramaröntgenbildern identifiziert, ohne erkennbare Symptome, unabhängig von den Hauptbeschwerden des Patient\*innen (**Abbildung 13**) [125].

Die genaue Interpretation erfordert jedoch eine Schulung und kann selbst für erfahrene Zahnmediziner\*innen eine Herausforderung darstellen [128, 129].

Differenzialdiagnosen sind durchaus schwierig, da die meisten Zysten und Tumore in der Röntgenaufnahme einen röntgendurchlässigen Bereich mit kortikalen Rändern zeigen, so dass die endgültige Diagnose nur über die histopathologische Untersuchung gestellt werden kann [130].

Radiologisch zeigen sich die Zysten und Tumore unterschiedlich. Raumforderungen, die mit einem nicht durchgebrochenen Zahn in direkter Beziehung stehen, deuten auf eine folliculäre Zyste hin. Diese sind in der Regel einkammrig [131, 132]. Uni- oder polyzystisch abgrenzbar könne sich Keratozysten im Röntgen präsentieren, häufig zeigen sie sich multilokulär. Es zeigt sich eine scharfe Begrenzung und oft lässt sich die Verdrängung benachbarter Zähne erkennen. Durch die Verhornung des Innenraums der Zyste ist die Strahlentransparenz oft geringer als beispielsweise bei folliculären Zysten.[132, 133]

Ameloblastome präsentieren sich als scharf begrenzte Aufhellungen in der Kortikalis, die mono- oder polyzystisch sein können. Ein wichtiges Merkmal, das vor allem beim monozystischen Ameloblastom gesehen werden kann, ist die Wurzelresorption benachbarter Zähne [132-134].



**Abbildung 13** Beispiel für Klassifizierung von Zysten unterstützt durch CNN: Läsionen von Radiolog\*innen kommentierte (durchgezogene Linie), Läsionen kommentiert durch ein CNN-Modell (gepunktete Linie) korrekt klassifiziert als odontogene Zyste (a), periapikale Zyste (b), odontogene Keratozyste (c) und Ameloblastom (d) ohne Datensatzerweiterung. Korrekt klassifiziert: (durchgezogene Linie) odontogene Zyste (e), periapikale Zyste (f), odontogene Keratozyste (g) und Ameloblastom (h) mit Datensatzerweiterung, falsch klassifiziert: (gepunktete Linie) odontogene Keratozyste (e), keine (f), odontogene Zyste (g) und folliculäre Zyste (h) ohne Datensatzerweiterung. – nach Kwon et al. [39]

Eine genaue präoperative Diagnose dieser Tumore und Zysten des Kiefers könnte jedoch den Behandler\*innen helfen, eine adäquate Therapie im Voraus zu planen und im Anschluss umzusetzen [135].


Unter der Vielzahl an zystischen Läsionen zählen zu den häufigsten gutartigen odontogenen Läsionen das Ameloblastom (AB) und die odontogene Keratozyste (OK) [136]. Sie können in jedem Teil des Kiefers auftreten, wobei die höchste Prävalenzen im Ramus ascendens mandibulae und im Corpus mandibulae zu verzeichnen sind. Aufgrund der signifikanten Unterschiede im biologischen Verhalten haben die Läsionen unterschiedliche Behandlungsstrategien. Daher ist es von entscheidender Bedeutung die beiden Krankheiten vor einem chirurgischen Eingriff zu diagnostizieren und voneinander zu unterscheiden. Obwohl ihre bildgebenden Eigenschaften in Lehrbüchern und in der Literatur vielfach diskutiert werden, ist es oft schwierig, sie in der bildgebenden Diagnostik zu erkennen [137].

Eine weitere häufige zystische Läsion ist die Staphne Knochenzyste (SBC). Auch diese erscheint als röntgendurchlässiger Bereich mit kortikalen Rändern [138]. Die SBC zeigt sich auf Röntgenbildern als gut abgegrenzte kortikale Radioluzenz und kann schwer von Zysten oder Tumoren zu unterscheiden sein. Die Abgrenzung der SBC von Zysten und Tumoren ist wichtig, da die SBC in der Regel keine chirurgische Intervention bedarf, während bei Zysten und Tumoren eine Exzision unumgänglich ist [130, 138].

### **1.2.1.6 Implantatanalyse**

Implantate werden immer häufiger verwendet, um fehlende Zähne zu ersetzen [139-141]. Die kontinuierlichen Entwicklungen in diesem Bereich haben dazu geführt, dass in den letzten Jahren eine Vielzahl von Implantatsystemen auf dem Markt verfügbar ist [142-144]. Hunderte von Firmen produzieren weltweit mehr als 4000 verschiedene Arten von Implantatsystemen [145, 146]. Die Implantatsysteme werden nach den Vorlieben und der Vertrautheit der Kliniker\*innen sowie nach der Kaukraft, der Knochenqualität, dem Knochenvolumen und dem verfügbaren Platz für die Restauration im zahnlosen Bereich des Kiefers ausgewählt und inseriert [144, 147-149]. Eine Vielzahl von Implantatstrukturen (gerade, konisch, konisch,

eiförmig, trapezförmig, intern und extern) werden kontinuierlich entwickelt und finden klinisch Verwendung (**Abbildung 14**) [142, 150, 151].



**Abbildung 14** Periapikale Röntgenbilder vier unterschiedlicher Implantattypen. (a) Brånemark Mk TiUnite, (b) Dentium Implantium, (c) Straumann Bone Level und (d) Straumann Tissue Level Implantate. – Kim et al. [58]

Im Laufe der Entwicklung wurde die Produktion einige ältere Implantatsysteme eingestellt, während zeitgleich viele neue Implantattypen, die sich erheblich von ihren Vorläufern unterscheiden, etabliert wurden. Das Wissen für diese Entwicklungen ist essenziell und muss für die für die heutige Generation von Kliniker\*innen vor allem in Bezug auf ausgeschiedene Implantatsysteme und die Kompatibilität mit anderen Systemen bewahrt werden. Dies ist entscheidend um den Patient\*innen auch Jahre nach der Implantation eine neue Versorgungsmöglichkeit auf bestehende Implantate anbieten zu können [152, 153].

Auf Grund der großen Anzahl an unterschiedlichen Systemen ist es der Untersucher\*in unmöglich jedes einzelne System radiologisch erkennen zu können. Möglicherweise fehlt es an Erfahrung mit Implantatsystemen, die vor 20 bis 30 Jahren verwendet wurden. Daher kann es schwierig sein neue Systeme allein durch die Betrachtung von Röntgenbildern zu erkennen. Beim Auftreten von häufigen Komplikationen wie Schraubenbrüchen oder -lockerung kann es dann schwierig sein den am besten geeigneten Ersatz für eine Schraube zu finden. Kann das verwendete Implantatsystem beim Auftreten mechanischer und biologischer Komplikationen nicht identifiziert werden, steigt die Wahrscheinlichkeit invasiver Behandlungsmethoden zur Reparatur obwohl keine Probleme hinsichtlich der Osseointegration des Implantats und des umgebenden Alveolarknochens bestehen [154, 155].

### **1.3 Bildgebende Verfahren**

Die radiologische Untersuchung ist ein wesentlicher Bestandteil des Patient\*innenmanagements in der Zahnmedizin. Sie wird häufig zur Ergänzung und Unterstützung der klinischen Diagnose von Pathologien im Zusammenhang mit Zähnen und angrenzenden Strukturen eingesetzt [156, 157]. Obwohl die Beurteilung von Panoramaröntgenbildern unter bestimmten Umständen an Radiolog\*innen übertragen werden kann, werden in den meisten klinischen Praxen die Panoramaröntgenbilder selbstständig beurteilt. Frühere Untersuchungen haben gezeigt, dass die Ausbildung der Ärzt\*in eine wesentliche Rolle in der korrekten Interpretation medizinischer Bildgebung spielt [158]. Speziell in der Zahnmedizin scheint die Übereinstimmungsrate (ein Indikator für die diagnostische Leistung) bei der Beurteilung von Röntgenbildern durch zahnärztliches Fachpersonal zum Teil aufgrund von individuellen Kenntnissen, Fähigkeiten und Vorurteilen zu variieren [159, 160]. Die unterschiedlichen Fähigkeiten des zahnärztlichen Personals beim Analysieren von Panoramaröntgenbildern öffnen die Tür für Fehldiagnosen oder Fehlbehandlungen [161, 162]. Jüngste Untersuchungen haben beispielsweise gezeigt, dass die Rate an Fehldiagnosen von Zahnärzt\*innen bei der Bestimmung der Kariestiefe in einem konventionellen Röntgenbild bei bis zu 40% lag, und in 20% der Fälle die Zähne anhand der rein radiologischen Diagnostik fälschlicherweise als pathologisch diagnostiziert wurden [163, 164].

#### **1.3.1 Orthopantomogramm**

Die zahnärztliche Panoramaröntgenaufnahme ist eine der am weitesten verbreiteten und am häufigsten durchgeführten zahnärztlichen Untersuchungen, die den gesamten Mund in einem einzigen 2D-Bild erfasst. Sie wird im Allgemeinen zur Erstbeurteilung des Zustands der Knochenstruktur und des Weichgewebes im Kieferbereich eingesetzt [38, 165, 166].

Das OPG ermöglicht die Abbildung aller Zähne, die angrenzenden Kieferbereiche, beider Kiefergelenke, beide Kieferhöhlen und zahlreiche andere angrenzende anatomische Strukturen, auf einem einzigen Bild. Es wäre sogar möglich,

Arterienverkalkungen der Halsschlagadern zu erkennen. Zur Erzeugung des Bildes fährt die Aufnahmeeinheit mit einer digitalen Zeilenkamera von links kommend halbkreisförmig um das Gesicht der Patient\*in. Parallel dazu fährt die Röntgenröhre um den Hinterkopf. Das geschieht in wenigen Sekunden. Das ist ein großer Vorteil, da in kurzer Zeit das gesamte Gebiet abgeleuchtet werden kann und eine gute Befundung ermöglicht [167-169].

Da die Aufnahmeeinheit außerhalb des Patient\*innenmundes ist, zählt das Panoramaröntgen zu den extraoralen bildgebenden Verfahren [168].

### **1.3.2 Intraorales Kleinbildröntgen**


Intraorale Röntgenaufnahmen sind nach wie vor eines der wichtigsten bildgebenden Verfahren in der Zahnheilkunde, das dem Zahnarzt\*in zur Verfügung steht. Die Technik bietet eine hohe räumliche Auflösung bei der Darstellung von Zähnen und potenziellen Zahn- und Kieferknochenerkrankungen [170, 171].

Durch das intraorale Kleinbild lassen sich einzelne Zähne radiologisch genau darstellen. Abhängig von der Ausrichtung der Röntgenröhre lassen sich unterschiedliche Bereiche im Detail abbilden. Zusätzlich zu den mesio-distalen (horizontalen) und krestal-apikalen (vertikalen) Messungen liefern sie nützliche Informationen über die Knochenstruktur und -dichte. Je nach Ausrichtung des Hauptstrahls und des angesetzten Winkels lassen sich verschiedene Bereiche des Zahnes im Detail abbilden [172].

Die Aufnahmetechniken können in die Rechtwinkeltechnik und die Halbwinkeltechnik eingeteilt werden. Bei der Rechtwinkeltechnik werden der Zahn und der Sensor auf einer parallelen Ebene gehalten. Diese Technik sorgt für weniger Bildverzerrungen und reduziert die übermäßige Strahlung für den Patient\*innen [170, 172].

### 1.3.3 Bissflügelröntgen

Bissflügelaufnahmen gehören zu den intraoralen radiologischen Aufnahmen und werden hauptsächlich zur Erkennung von kariösen Läsionen verwendet, da die Approximalfächen der Zähne im Seitenzahnbereich optimal dargestellt werden. In dieser radiologischen Bildgebung kann sogar der initiale Verlust von Hartschmelze als Radioluzenz im Zahnschmelz festgestellt werden. Außerdem können Bissflügelaufnahmen noch zur Inlaykontrolle und zur parodontalen Befunderhebung gut verwendet werden, da die Kronen und die kronennahen Anteile der Wurzel gut dargestellt werden können (**Abbildung 15**) [173].



**Abbildung 15** Beispiele zweier intraoralen Bissflügelröntgenbilder – nach Pasler et al. [171]

### 1.3.4 Digitale Volumentomographie

Die digitale volumetrische Tomographie (DVT) ist eine in der dentalen Bildgebung häufig verwendete Methode, um eine dreidimensionale Darstellung der Hartgewebe zu erhalten [174]. Die 3-D-Diagnostik stellt eine Ergänzung zu zweidimensionalen Röntgenverfahren dar, und kann in allen Teilgebieten der Zahnheilkunde eingesetzt werden [175].

Das DVT stellt eine Röntgentechnik dar, bei der in einem Umlauf mit einem kegelförmigen Strahlenbündel („cone beam“) ein dreidimensionales Volumen erfasst wird [175]. Das Strahlenbündel trifft auf einen zweidimensionalen

Bildrezeptor und es entstehen Sekundärschichten. Mit Hilfe dieser Sekundärschichten wird die entsprechende 3D-Rekonstruktionen auf der Basis des volumetrischen Datensatzes erzeugt [169, 176].

Diese Untersuchung wird im klinischen Alltag zur Verbesserung der Diagnose und dem Behandlungsplan eingesetzt. Die DVT-Technologie findet vor allem in der Planung von Zahnimplantaten, Lokalisierung von anatomischen Strukturen (e.g. Mandibularkanal), Erhebung der Größe und Form des Kieferkamms inklusive Knochenqualität vor chirurgischen Zahnextraktionen oder für die Beurteilung von Anomalien im Kopf-Hals-Bereich (e.g. Frakturen, Zysten) häufig Anwendung [176, 177].

#### **1.4 Metriken**

Um die Ergebnisse von Studien deutlich zu machen, gibt es eine Vielzahl an unterschiedlichen Metriken [178, 179]. Die in den Artikeln dieses Reviews am häufigsten verwendeten Metriken sind:

- Sensitivität
- Spezifität
- Accuracy

Die Sensitivität gibt die Zuverlässigkeit eines Diagnoseverfahrens an. Sie wird als der Quotient aus richtig positiven und der Summe richtig positiven und falsch negativen Testergebnissen definiert [178, 179].

Der Begriff Spezifität gibt die Wahrscheinlichkeit an, mit. Der Gesunde, welche nicht an der geprüften Krankheit leiden, erkannt werden. Ein Test weist also eine hohe Spezifität auf, wenn er bei der Suche nach einer bestimmten Krankheit die gesunden Menschen auch tatsächlich als gesund erkennt. Definiert wird die Spezifität als der Quotient der richtig negativen Testergebnisse und der Summe aus falsch positiven und richtig negativen Testergebnissen [179, 180].

Die Accuracy (Genauigkeit) sagt aus, wie oft Vorhersagen mit Bezeichnungen übereinstimmen [178, 181, 182].

## **1.5 Ziel der Literaturrecherche**

Die vorliegende Arbeit beschäftigt sich mit dem Thema des maschinellen Lernens in der Zahnmedizin. Besonderes Augenmerk wurde auf den Schnittpunkt der bildgebenden Verfahren mit dem maschinellen Lernen gelegt. Es handelt sich um eine Übersichtsarbeit, die anhand rezenter Literatur den aktuellen Stand und das Potential in der Zukunft beleuchten soll.

In der Zahn- und Mundheilkunde wird jedes Jahr eine große Anzahl von Bildern aufgenommen. In den meisten europäischen Ländern macht die zahnärztliche Röntgenaufnahme (einschließlich Panorama-, Bissflügel-, periapikale und zephalometrische Röntgenaufnahmen) den Großteil aller Röntgenaufnahmen aus. Wobei im Jahr 2010 schätzungsweise 250-300 zahnärztliche Aufnahmen pro 1000 Personen gemacht wurden [183]. Da zum radiologischen Bereich auch noch weitere diagnostische oder dokumentative bildgebende Verfahren wie Fotografien, 3-D-Oberflächenscans oder Fluoreszenzbilder hinzukommen, scheint es ein großes Potenzial für CNN-Anwendungen zu geben. Einige Autor\*innen untersuchten bereits in systematischen Übersichtsarbeiten, in welchen Bereichen CNNs eingesetzt werden und welche Anwendungen im Fokus stehen [100, 184]. Es ist allerdings nicht klar, welche Methoden (Bildtypen, Referenztests, CNN-Architekturen, Ergebnismetriken) üblich sind und wie die CNNs derzeit im Vergleich zu menschlichen Expert\*innen abschneiden. Die durchgeführte Literaturrecherche hat das Ziel derartige Informationen zu erheben und dadurch behilflich zu sein, zukünftige Forschung zu KI-Techniken in der Zahnmedizin einordnen zu können. Ziel wäre die möglichst aktuelle Darstellung des Standes auf Grund der sich schnell verändernden Literaturlandschaft.

## 2 Material und Methoden

### 2.1 Suchstrategie und Durchsichtung der Datenbanken

Diese Arbeit stellt eine Literaturübersicht mit vorangegangener systematischer Recherche, welche in drei bekannten online Datenbanken durchgeführt wurde, dar. Eine Übersichtsarbeit, zielt darauf ab, die Literatur zu einem bestimmten Thema oder Anwendungsbereich zu erfassen und eine Gelegenheit zu bieten, Schlüsselkonzepte, Forschungslücken sowie Arten und Quellen von Nachweisen zu identifizieren, um die Praxis und zukünftige Recherchen zu unterstützen.

Die Durchführung folgt dem Rahmenwerk von Arksey und O'Malley, modifiziert durch Levac [185]. Die Berichterstattung folgt der PRISMA-Erklärung [186].

Die Review-Fragen lauteten:

- (1) Für welche Anwendungen wurden CNNs in der Zahnmedizin eingesetzt?
- (2) Welche CNN-Modelle wurden genutzt?
- (3) Zu welchen Ergebnissen kamen die Studien beim Vergleich der CNN-Leistung?

Um die geeignete Literatur für diese Arbeit zu generieren, wurde zu Beginn eine Suchstrategie erarbeitet, die einen breiten Überblick über das bereits vorhandene Schriftgut ermöglicht. Drei Datenbanken wurden systematisch durchsucht, nämlich PubMed, Mendeley und Web of Science.

Um umfassende Ergebnisse zu erzielen, wurden verschiedene Begriffe und Synonyme zu den Themenfeldern „Artifizielle Intelligenz“, „Maschinelles Lernen“ und „Deep learning“ einbezogen und die jeweiligen Komponenten entsprechend miteinander verknüpft. Um die Schlagwortsuche zu erleichtern, wurden die folgenden Schlüsselwörter in verschiedenen Kombinationen benutzt: AI, CNN, deep learning, artificial intelligence system, data mining, diagnostics, KDD, artificial neuronal networks, oral health, radiology, X-Ray. Zusätzlich wird für die Literatursuche der Filter „dentistry“ angewandt, um ausschließlich das Themengebiet der Zahnmedizin zu erfassen.

Mit dieser Suchstrategie wurden anschließend die medizinischen Datenbanken PubMed, Mendeley und Web of Science auf ihre Ergebnisse durchsucht. Im Anschluss wurden die Ergebnisse mit einem für die jeweilige Datenbank spezifischen Filter eingegrenzt.

Folgende Suchprofile wurden erarbeitet, um in den oben genannten Datenbanken Ergebnisse zu erlangen:

(artificial intelligence\*OR AI OR artificial intelligence system OR KDD) AND (machine learning\* OR artificial neuronal networks OR deep convolutional neural networks OR data mining OR CNN) AND (dentistry\*)

Die erste Suche wurde am 18.11.2021 durchgeführt.

Vor der Erarbeitung der Ergebnisse wurde am 03.05.2022 eine erneute Erhebung der Daten durchgeführt.

## **2.2 Datenerhebung und Analyse**

Alle Ergebnisse, die durch die oben genannte Suchstrategie in den medizinischen Datenbanken gefunden wurden, wurden mit Hilfe einer Excel Tabelle verwaltet. Die Manuskripte der primären Resultate wurden auf ihre inhaltliche Relevanz anhand des Abstracts überprüft.

Die thematisch passenden Artikel wurden dann in die weitere Auswahl eingeschlossen und die zugehörigen Volltexte beschafft, um die Arbeiten nach spezifischen Auswahlkriterien überprüfen zu können. Nicht passende Artikel wurden in diesem Arbeitsschritt aus der Literaturrecherche ausgeschlossen.

Die selektierten Ergebnisse wurden dann zum Vergleich des Datenmaterials verwendet. Der Auswahlvorgang wurde entsprechend den PRISMA-Empfehlungen von 2011 in einem Flussdiagramm dargestellt und dokumentiert (**Abbildung 16**).

### **2.2.1 Auswahlkriterien für die Arbeiten**

Es wurden alle Artikel in die vergleichende Arbeit zum Thema „Maschinelles Lernen in der Zahnmedizin“ eingeschlossen, die den folgenden Ein- und Ausschlusskriterien unterlegen sind.

Die publizierten Artikel mussten aus den Jahren 2019 bis 2021 stammen. Studien, die in anderen Sprachen als englisch publiziert wurden, wurden ausgeschlossen.

Arbeiten, die nicht vertrauenswürdig erschienen, mangelnde Information / zu wenig Inhalt übermittelten oder deren Abstract oder Titel vom Thema abwichen, wurden ausgeschlossen. Ebenfalls ausgeschlossen wurden alle Studien, bei denen der Originaltext im Internet nicht kostenfrei verfügbar war.

Vorhandene Metaanalysen und systematische Reviews wurden genutzt, um eventuelle zusätzlich existierende Arbeiten aufzufinden.

### **2.2.2 Extraktion der Daten**

Folgende Daten sollten aus den verwendeten Studien extrahiert werden:

(1) Allgemeine Studiendetails (Titel, Hauptautor\*in, Zeitschrift oder Konferenz, Datum der Veröffentlichung)

(2) Studienmerkmale (Bereich und Anwendung, Bildgebendes Verfahren, Anzahl der Bilder, Index- und Referenztest, falls vorhanden zusätzliche Vergleichstests)

(3) Ergebnisse und Ergebnis Metriken.

### **2.2.3 Auswertung der relevanten Arbeiten**

Die Extraktion der Daten erfolgt durch zwei unabhängige Reviewer. Mögliche Konflikte wurden durch Diskussion und gegebenenfalls durch Hinzunahme eines dritten Reviewers (2:1-Entscheidungsprozedur) gelöst.

## 3 Ergebnisse

### 3.1 Suche und Auswahl der Literatur

Zu Beginn der Suche wurden 1632 Artikel aus den Datenbanken PubMed, Web of Science und Mendeley ausgewählt deren Titel auf die oben genannten Kriterien gepasst haben. Die Suche in PubMed lieferte 513 Ergebnisse, Web of Science 975 und Mendeley 144.

Nach der Anwendung spezifischer Filter in den jeweiligen Datenbanken (Jahr, Sprache, Fachgebiet, Art des Artikels) und der Kontrolle auf Duplikate, konnten 1544 Einträge ausgeschlossen werden. Inkludiert wurden lediglich Originalartikel, die frei zugänglich waren. Reviews wurden ausgeschlossen.

Die Abstracts der restlichen 88 Artikel wurden gelesen. Nach der Durchsicht der Abstracts konnten weitere 48 Artikel ausgeschlossen werden.

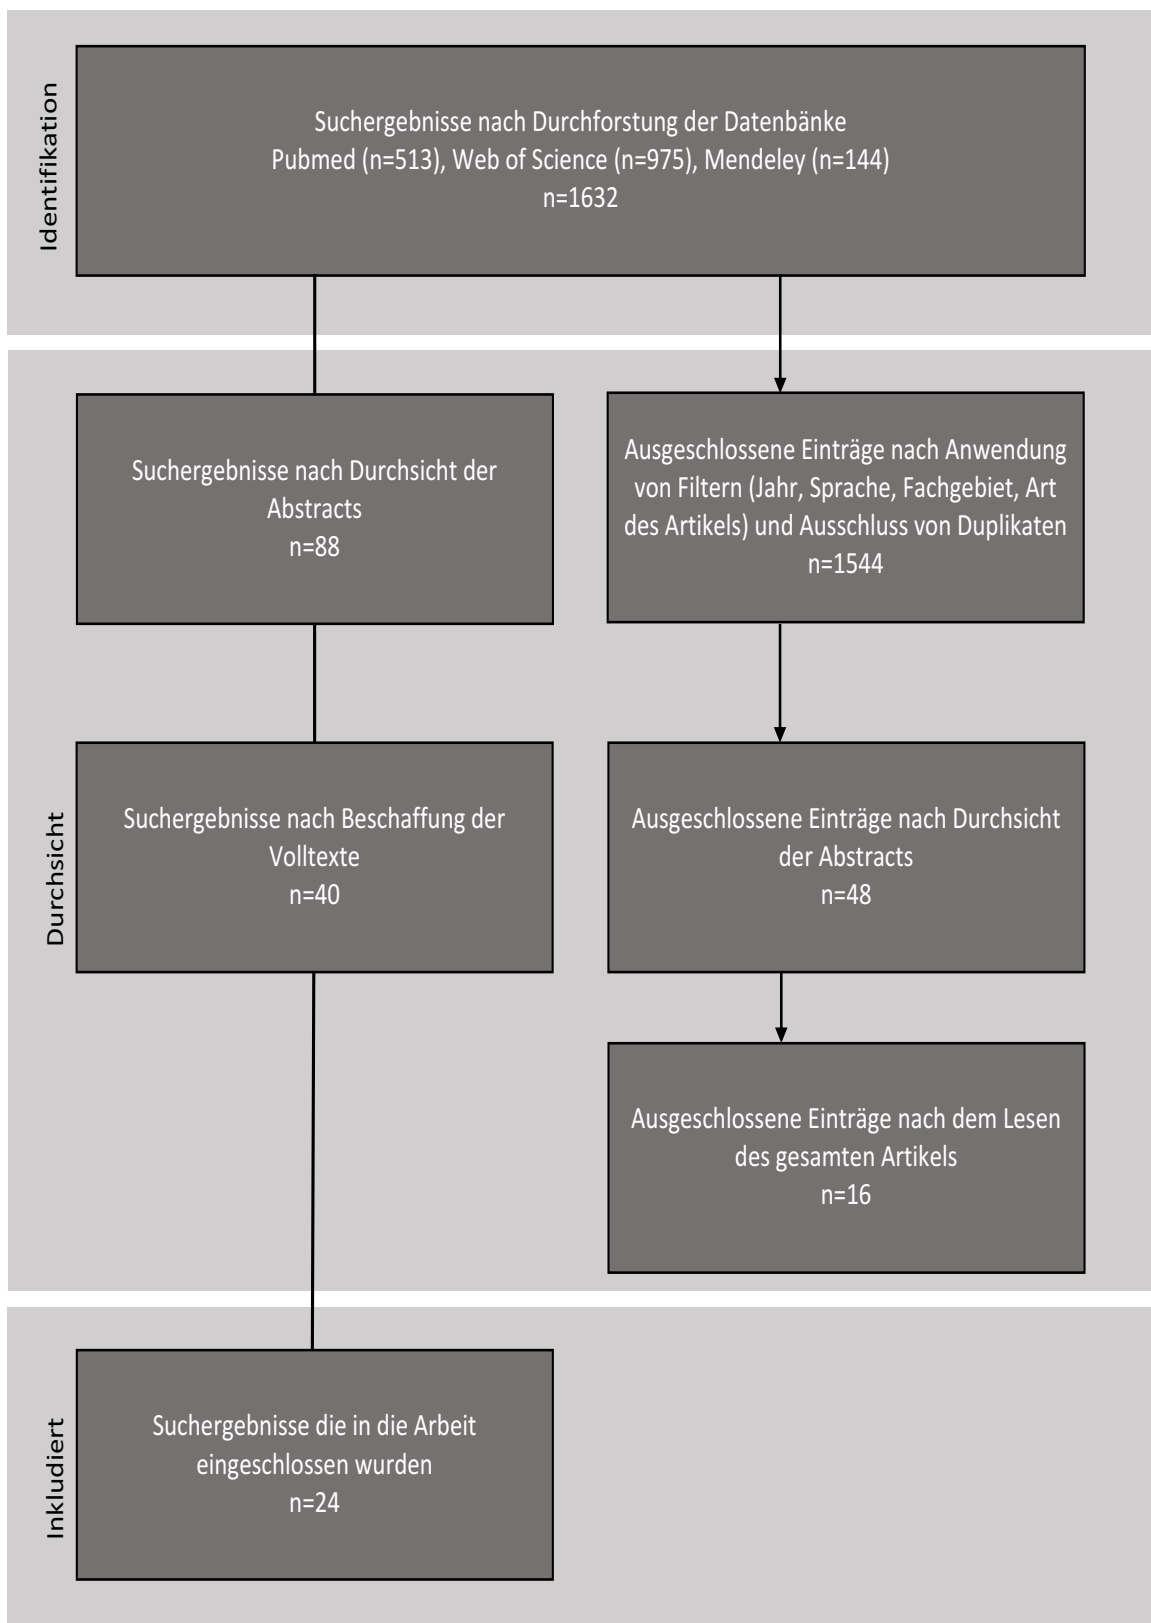
Die Originaltexte der übrigen 40 Artikel wurden beschafft und gelesen. Nach dem Lesen der Volltexte wurden erneut 16 Artikel ausgeschlossen.

24 Artikel wurden in die Arbeit eingeschlossen (**Abbildung 16, Tabelle 1**).

Autor*innen	Jahr	Journal	Anwendungsbereich	Bildgebung	CNN-Architektur
Ezhov [37]	2021	Sci Rep	Anat. Strukturerkennung, Kariesdetektion, rad. Parodontalanalyse, CAP Erkennung	DVT	Diagnocat
Krois [187]	2019	Sci Rep	Rad. Praodontalanalyse	OPG	Individuell entworfene Architektur
Liu [137]	2021	Int J Comput Assist Radiol Surg	Erkennen zyst. Läsionen	OPG	Individuell entworfene Architektur
Lee [42]	2020	Medicine, Balt.	Implantatanalyse	OPG, KB	Inception
Tuzoff [88]	2019	DMFR	Anat. Strukturerkennung	OPG	VGG
Vila-Blanco [188]	2021	Int J Comput Assist Radiol Surg	Anat. Strukturerkennung	OPG	SHN
Ha [45]	2021	Sci Rep	Anat. Strukturerkennung	OPG	YOLO
Vinayahalingam [189]	2021	Sci Rep	Kariesdetektion	OPG	MobileNet
Thanathornwong [190]	2020	ISD	rad. Parodontalanalyse	OPG	ResNet
Kim [38]	2019	Sci Rep	rad. Parodontalanalyse	OPG	DeNTNet
Lee [41]	2021	PLoS One	Erkennen zyst. Läsionen	OPG	DenseNet
Kwon [39]	2020	DMFR	Erkennen zyst. Läsionen	OPG	YOLO
Mahdi [89]	2020	Sci Rep	Anat. Strukturerkennung	OPG	ResNet

Autor*innen	Jahr	Journal	Anwendungsbereich	Bildgebung	CNN-Architektur
Ahn [44]	2021	Diagnostics (Basel)	Anat. Strukturerkennung	OPG	ResNet, SqueezeNet, Inception-ResNet
Endres [191]	2020	Diagnostics (Basel)	CAP Erkennung	OPG	Individuell entworfene Architektur
Minnema [48]	2019	Med Phys	Anat. Strukturerkennung	DVT	Individuell entworfene Architektur
Kim [58]	2020	JCM	Implantatanalyse	KB	Inception, ResNet, MobileNet, SqueezeNet
Zheng [46]	2021	ATM	Kariesdetektion	KB	Inception, VGG, ResNet
Lee [192]	2020	Diagnostics (Basel)	Implantatanalyse	OPG, KB	Neuro-T
Lee [43]	2021	Sci Rep	Kariesdetektion	BF	U-Net
Moran [97]	2021	Sensors (Basel)	Kariesdetektion	BF	Inception, ResNet
Yang [47]	2020	JCM	Erkennen zyst. Läsionen	OPG	YOLO
Orhan [36]	2020	INT ENDOD J	CAP Erkennung	DVT	U-Net
Setzer [35]	2020	J Endod	CAP Erkennung	DVT	U-Net


**Tabelle 1** Suchergebnisse die in die Literaturübersicht integriert wurden



**Abbildung 16** PRISMA-Flow Chart zur Literatursuche (eigene Darstellung)

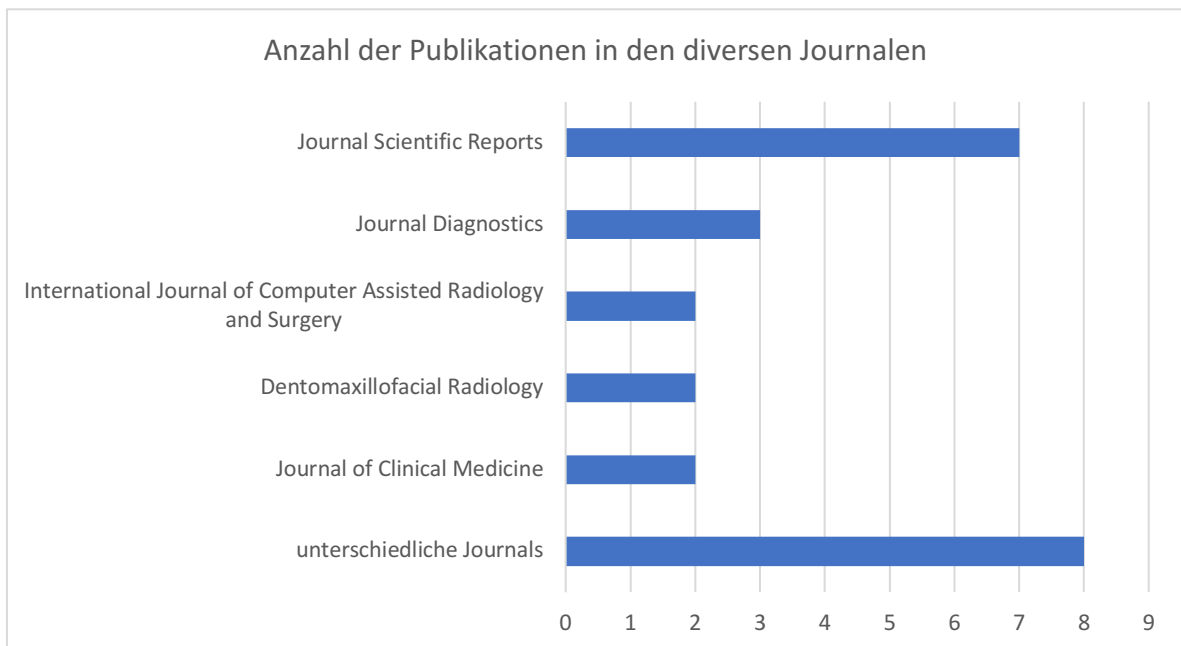
### 3.1.1 Inkludierte Artikel

Die inkludierten Artikel der vorliegenden Arbeit (**Tabelle 1**) wurden in den Jahren 2019 bis 2021 veröffentlicht. Vier dieser Publikationen stammen aus dem Jahr 2019, zehn aus dem Jahr 2020 und weitere zehn aus dem Jahr 2021 (**Abbildung 17**).



**Abbildung 17** Anzahl der Publikationen im jeweiligen Jahr (eigene Darstellung)


Die ausgewählten Publikationen wurden in 13 unterschiedlichen Journals veröffentlicht (**Abbildung 18**). Sieben der 24 Artikel wurden in dem Journal Scientific Reports publiziert, drei im Journal Diagnostics, jeweils zwei Artikel stammten aus den Journals International Journal of Computer Assisted Radiology



**Abbildung 18** Anzahl der Publikationen in den Jahren 2019 bis 2021 (eigene Darstellung)

and Surgery, Dentomaxillofacial Radiology und Journal of Clinical Medicine. Die übrigen acht Publikationen stammten aus unterschiedlichen Journalen.

Neun der inkludierten Publikationen stammen aus Südkorea, jeweils drei wurden in Amerika und China veröffentlicht. Aus den Niederlanden sind zwei Publikationen und aus Deutschland, Russland, Spanien, Thailand, Japan, Brasilien und Belgien, jeweils eine (**Abbildung 19**).



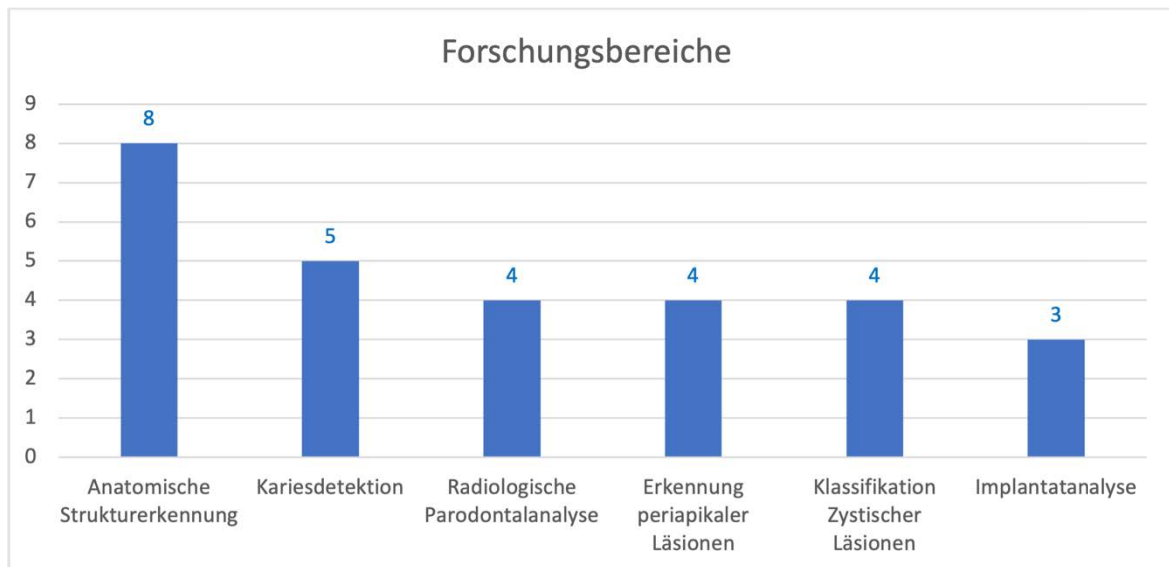
**Abbildung 19** Publikationsländer aller inkludierten Arbeiten (eigene Darstellung)

### **3.2 Anwendungsbereiche der inkludierten Artikel**

Sechs unterschiedliche Anwendungsbereiche der Zahnheilkunde wurden definiert, um die Artikel kategorisieren zu können.

- Anatomische Strukturerkennung
- Kariesdetektion
- Radiologische Parodontalanalyse
- Erkennung periapikaler Läsionen
- Klassifikation zystischer Läsionen
- Implantatanalyse

Acht der Artikel befassten sich mit dem Thema der Strukturerkennung, die übrigen Arbeiten deckten die anderen Anwendungsbereiche ab. Kariesdetektion (n=5), Radiologischer Parodontalanalyse (n=4), Erkennung periapikaler Läsionen (n=4), Erkennung zystischer Läsionen (n=4) und Implantatanalyse (n=3) (**Abbildung 20**). Das am häufigsten behandelte Gebiet war das der Anatomischen Strukturerkennung.



**Abbildung 20** Anwendungsbereiche die von den Publikationen abgedeckt werden (eigene Darstellung)

Die Publikation von Ezhov et al. [37] beschäftigt sich mit mehr als einem Anwendungsbereich. Ezhov et al. [37] greifen die Bereiche anatomische Strukturerkennung, Kariesdetektion, Radiologische Parodontalanalyse und Erkennung periapikaler Läsionen auf. Dafür wurden DVT-Bilder verwendet.

### **3.3 Datensätze und Art der Bildgebung**

Vier unterschiedliche, in der Zahnmedizin häufig angewandte radiologische Methoden der Bildgebung wurden in den Publikationen zum Erlangen der Ergebnisse verwendet.

- Orthopantomogramm
- Intraorales Kleinbildröntgen
- Bissflügelröntgen
- Digitale Volumentomographie

Das am häufigsten verwendete Verfahren war die Orthopantomographie. Sie war 16-mal Teil der Fragestellung. Fünf Studien konzentrierten sich auf die Auswertung von Kleinbildröntgen und weitere fünf Autor\*innen arbeiteten mit Bildern der Digitalen Volumentomographie. Am wenigsten oft wurden Bissflügelröntgen mit nur zwei Untersuchungen genutzt. Lee et al. [42], Vila-Blanco et al. [188] und Lee et al. [43] verwendeten sowohl Kleinbildröntgen als auch Orthopantomogramme in ihrer Untersuchung der Ergebnisse.

In den ausgewerteten Studien wurden zwischen 20 und 11189 Bilder der unterschiedlichen Bildtypen verwendet.

Ezhov et al. [37] (n=1346), Ha et al. [45] (n=612), Minnema et al. [48] (n=20), Setzer et al. [35] (n=2800), und Orhan et al. [36] (n=20) nutzen unterschiedlich viele DVT-Daten.

OPG Datensätze wurden von 16 Autor\*innen genutzt: Krois et al. [187] (n=85), Liu et al. [137] (n=420), Tuzoff et al. [88] (n=1575), Vinayahalingam et al. [189] (n=253), Thanathornwong et al. [190] (n=100), Kim et al. [38] (n=11189), Lee et al. [41] (n=458), Kwon et al. [39] (n=1282), Mahdi et al. [89] (n= 1000), Ahn et al. [44] (n=1100), Endres et al. [191] (n=3240) und Yang et al. [47] (n=1602).

Kim et al. [58] verwendete 801 intraorale KB-Aufnahmen um zu den Studienergebnissen zu gelangen [58].

In den Publikationen von Lee et al. [192], Vila-Blanco et al. [188] und Lee et al. [43] kamen sowohl OPGs als auch KB-Datensätze zum Einsatz. Lee et al. [192] verwendete 5390 OPGs und 5380 KB-Daten, Vila-Blanco [188] nutze jeweils 1195

OPGs und KB Datensätze und Lee et al. [42] hatte mehr OPGs als KB zur Verfügung (OPG = 7146, KB = 4834).

BF-Aufnahmen wurden ausschließlich von Moran et al. [97] und Lee et al. [43] genutzt. Moran et al. [97] (n=112) hatten eine geringere Datensatzanzahl zur Verfügung als Lee et al. [43] (n=354).

In den meisten Arbeiten wird beschrieben, dass die Daten in drei unterschiedliche Datensätze aufgeteilt wurden. Einen Datensatz zum Training, einen zur Validierung und einen zum Testen der jeweiligen CNN-Architektur.


Der größte Teil der vorhandenen Daten ist in der Regel der Trainingsdatensatz. Ein Paper gab keine Angaben über die verwendeten Datensätze. Neun Autor\*innen beschrieben die Größe aller drei Datensätze. Aus vier Artikel ließ sich die Größe der Trainings und Validierungsdatensätze extrahieren und neun Artikel beschrieben die Trainings und Testdatensätze.

### 3.4 Festlegung des Goldstandards

Um die Fähigkeit der CNN-Architekturen bewerten zu können, wird in den meisten Untersuchungen ein oder mehrere Untersucher\*innen beschrieben, die einerseits den Goldstandard definieren und andererseits als Vergleichswert dienen.

In 17 von 24 Artikeln (70,8%) wurden sowohl die Anzahl als auch die Berufsgruppe der Gutachter\*innen angegeben. Der Großteil der Gutachter\*innen waren Zahnärzt\*innen (n = 11) (**Abbildung 21**). Außerdem führten fünf Radiolog\*innen mit dem Spezialgebiet Zahnmedizin (n = 5), Mund-, Kiefer-, Gesichtschirurg\*innen (n = 2), Medizintechniker\*innen (n = 1), Student\*innen (n = 1), und Allgemeinmediziner\*innen (n = 1) die Gutachter\*innenfunktion in den Untersuchungen aus.

Die größte Anzahl an Gutachter\*innen hatte Lee et al. [41] mit 25, wobei alle 25 Expert\*innen Fachärzte\*innen der Zahn-, Mund- und Kieferheilkunde waren [41]. Zwei Studien wurden von mehreren Untersuchern\*innen beurteilt. In der Publikation von Yang et al. [47] wurden die Bilder von fünf Spezialist\*innen begutachtet, drei Mund-, Kiefer-, Gesichtschirurgen\*innen und zwei Allgemeinmediziner\*innen [47]. Setzer et al. [35] hatte jeweils einen Untersucher/eine Untersucherin aus drei unterschiedlichen Spaten, Student\*in, Radiolog\*in und Zahnärzt\*in [35].



**Abbildung 21** Anzahl der Gutachter\*innen zweifelligen Publikationen (eigene Darstellung)

## 3.5 CNN-Architekturen

### 3.5.1 Verwendete CNN-Architekturen

In den 24 Studien wurden acht unterschiedliche CNN-Architekturen verwendet. In Vier (16,6%) Artikeln entwarf die Studiengruppe ein individuelles Netzwerk, das genau auf die Anliegen der jeweiligen Publikationen abgestimmt war. Die übrigen Studien verwendeten gängige CNN-Architekturen, U-Net (n = 3), Diagnocat (n= 1), Inception (n = 4), MobileNet (n = 2), YOLO (n = 3), Neuro-T (n = 1), SHN (n = 1), VGG (n = 2), DeNTNet (n = 1), DenseNet (n = 1), SqueezeNet (n = 2), Inception-ResNet (n = 1). Am häufigsten wurde ResNet verwendet (n = 6).

Ahn et al. [44], Kim et al. [58], Zheng et al. [46] und Moran et al. [97] verwendeten multiple Architekturen, um zu den gewünschten Ergebnissen zu kommen.

### 3.5.2 CNN-Architekturen und Metriken

Um das Potenzial der künstlichen Intelligenzmodelle zeigen zu können, wurden unterschiedliche Metriken genutzt.

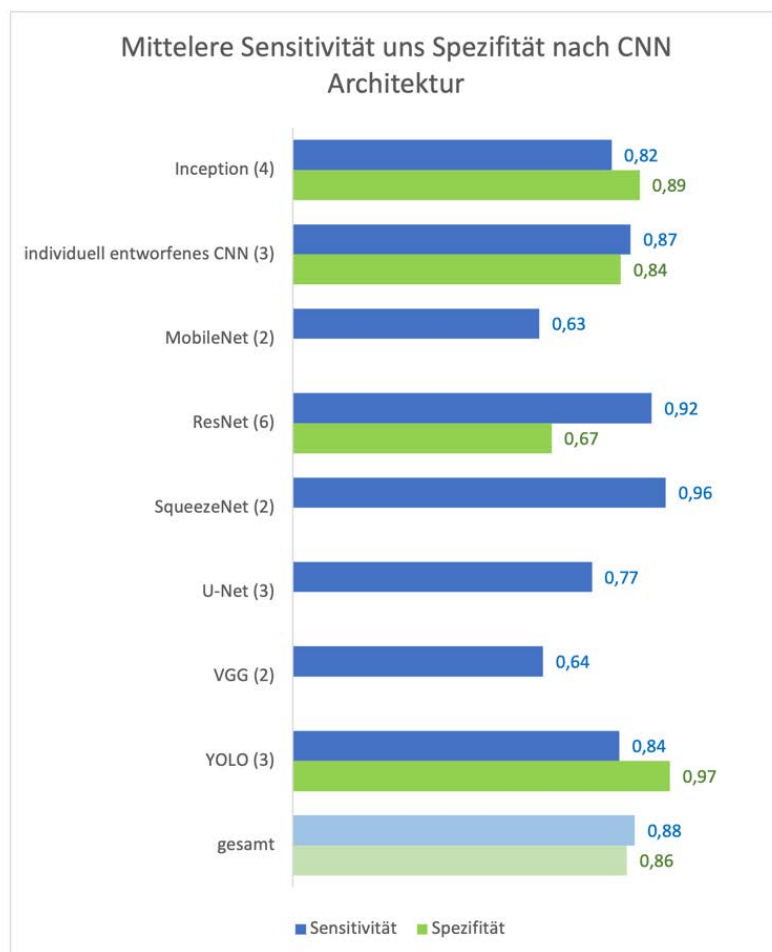
20 Autor\*innen verwendeten die Sensitivität und Spezifität (n = 14), um eine Aussage über Leistungsstärke machen zu können. Es lässt sich ein arithmetisches Mittel für alle angegebenen Spezifitäten von 0,88 erkennen mit einer Standardabweichung von  $\pm 0,11$ . Ein Mittelwert von 0,86 für die Spezifität mit einer Standardabweichung von  $\pm 0,16$  (**Abbildung 22, Tabelle 2**).

Weitere Metriken die genutzt wurden sind Accuracy (MW 0,89; SD  $\pm 0,09$ ), AUC (MW 0,91; SD  $\pm 0,05$ ) Precision (MW 0,82; SD  $\pm 0,16$ ), F-Measure (MW 0,87; SD  $\pm 0,08$ ), F1-Score (MW 0,85; SD  $\pm 0,15$ ), PPV (MW 0,77; SD  $\pm 0,10$ ), NPV (MW 0,93; SD  $\pm 0,08$ ), TPR (MW 0,51), Youden Index (MW 0,81), Mean DSC (MW 0,87).

Für die jeweilig verwendeten künstlichen Intelligenzmodelle ließen sich folgende Mittelwerte und Standardabweichungen bezugnehmend auf die Sensitivität, Spezifität und Accuracy errechnen:

Indiv. CNN	0,87	0,08		$\pm 0,1$	0,8€	$\pm 0,07$
MobileNet	0,63	0,48			0,64	$\pm 0,50$
ResNet	0,92	0,7		$\pm 0,1$	0,91	$\pm 0,08$
U-Net	0,77	0,17				

**Tabelle 2** CNN-Modelle und Metriken



**Abbildung 22** Arithmetisches Mittel der Spezifität und Sensitivität nach CNN-Architekturen (eigene Darstellung)

## 4 Diskussion

Die KI treibt die Modernisierung der Zahnmedizin, insbesondere den Bereich der Diagnostik, voran. KI-basierte Systeme werden häufig für die Entwicklung automatisierter Softwareprogramme verwendet, die die Diagnose und die Datenverwaltung in der Zahnmedizin automatisieren [42]. Meistens handelt es sich dabei um klinische Entscheidungshilfesysteme, die Expert\*innen dabei unterstützen und anleiten, rascher und bessere Entscheidungen zu treffen. Diese Systeme können für eine Reduktion der befunderabhängigen Bias genutzt werden [39]. Die Nachfrage nach diesen Systemen boomt aufgrund ihrer Effektivität bei der Bereitstellung von Erklärungen und Argumenten [58].

KI könnte den Bereich der Zahnmedizin revolutioniert und die Arbeit der Zahnärzt\*in erleichtern. Die klinischen Entscheidungsunterstützungssysteme, die auf der KI-Technologie basieren, sind in erster Linie darauf ausgelegt, den Angehörigen der Gesundheitsberufe fachliche Unterstützung zu bieten [193]. Klinische Entscheidungsunterstützungssysteme sind definiert als Computerprogramme, die den Angehörigen der Gesundheitsberufe dabei helfen, klinische Entscheidungen zu treffen und die sich auch mit medizinischen Daten oder medizinischem Wissen befassen, das zur Interpretation solcher Daten erforderlich ist [194].

In dieser systematischen Übersichtsarbeit wurden Studien über die Anwendung von ML-Technologien in der Zahnmedizin analysiert und ihre Leistung bewertet.

### ***4.1 Vergleich der Arbeiten bezogen auf die unterschiedlichen Anwendungsbereiche mit Rücksicht auf die verwendeten Bildgebungsarten***

Wie aus den Ergebnissen bereits ersichtlich, wurden in den 24 behandelten Publikationen sechs unterschiedliche Anwendungsbereiche behandelt: Anatomische Strukturerkennung, Kariesdetektion, Radiologische Parodontalanalyse, Erkennung periapikaler Läsionen, Klassifikation zystischer Läsionen und Implantatanalyse. Die Autor\*innen behandelten die jeweiligen Gebiete mit Daten, die von unterschiedlichen bildgebenden Verfahren stammten. Abhängig von den verwendeten Bildgebungsarten und Zielen wurden die

untersuchte Literatur in Subgruppen geteilt, um eine bessere Vergleichbarkeit zu erzielen.

#### **4.1.1 Anatomische Strukturerkennung auf der Grundlage von Orthopantomogrammen**

Der Großteil der Publikationen verwendete OPGs als Grundlage für die verwendeten Datensätze. Die Publikationen von Tuzoff et al. [88], Mahdi et al. [89], Ha et al. [45] und Vila-Blanco et al. [188] beschäftigen sich mit dem Thema des Maschinellen Lernens beziehungsweise auf den Anwendungsbereich der Anatomischen Strukturerkennung [45, 88, 89, 188].

Tuzoff et al. [88] zeigte sehr gute Ergebnisse für die Nummerierung und Erkennung von Zähnen auf OPGs. Obwohl Probleme vorwiegend in Lückenbereichen auftraten, lieferte das System gute Ergebnisse. Tuzoff et al. [88] konnten eine Spezifität von 0,99 erreichen. Weitere Verbesserungen könnten allerdings durch modernere CNN-Architekturen und die Erweiterung des Datensatzes zum Training des Systems erzielt werden. Außerdem berichtet Tuzoff et al. [88], dass es vermutlich möglich sein wird, die bestehenden CNN-Modelle zu erweitern und so unterschiedliche Anwendungsbereiche abzudecken. Dazu werden allerdings größere Datenmengen benötigt. Die automatisierten Interpretationen waren den Interpretationen der Expert\*innen in den aktuellen Arbeiten beinahe ident. Aus den vorliegenden Ergebnissen lässt sich schließen, dass die Qualität hoch genug ist, um eine Software zu kreieren, die gut im Alltag anwendbar ist [88].

Im Unterschied zu Tuzoff et al. [88] verwendete Mahdi et al. [89] eine Kombination aus ResNet-50 und ResNet-10. Mahdi et al. [89] erzielte vergleichbare Ergebnisse mit ähnlich großen Datensätzen. Tuzoff et al. [88] trainierten ihre KI mit 1325 Bildern des Trainingsdatensatzes, der Trainingsdatensatz von Mahdi et al. [89] umfasste 900 Bilder [88, 89]. Auch diese Ergebnisse weisen auf eine deutliche Hilfe für Kliniker\*innen in der täglichen Praxis hin. Des Weiteren planen Mahdi et al. [89] einen Ausbau des bestehenden Modells, um eine automatisierte Bewertung des Zahnzustandes zu ermöglichen und den Bedarf an notwendigen prothetischen Versorgung zu erkennen [88, 89].

Im Kontrast zu Tuzoff et al. [88] und Mahdi et al. [89], hatten Ha et al. [45] das Ziel, ein CNN-Modell zu entwerfen, welches Mesiodentes auf Panoramaröntgenbildern erkennen soll [45, 88, 89].

Ha et al. [45] machen darauf aufmerksam, dass eine multizentrische Sammlung an Daten besonders wichtig ist, um das System robuster zu machen und dadurch eine Verwendung im realen Klinikbetrieb zu ermöglichen. Genauer ist es von Vorteil verwendete KI-Modell mit Daten zu validieren, die mit Hilfe anderer Röntgengeräte aufgenommen wurden als jene, welche die Bilder für den Trainingsdatensatz lieferten. In der Forschungsarbeit von Ha et al. [45] wurden aus diesem Grund Daten zweier Geräte für das Training und die Validierung genutzt. Getestet wurde die KI mit Bildern, die in unterschiedlichen Kliniken aufgenommen wurden. Wie zu erwarten konnten mit Hilfe des internen Testdatensatzes ein besseres Ergebnis erzielt werden als bei der Anwendung des externen Datensatzes. Allerdings war die Leistung nur geringfügig schlechter. Der interne Datensatz, zeigte eine Accuracy von 0,96, eine Sensitivität von 0,95 und eine Spezifität von 0,96. Im Gegensatz dazu konnte der externe Datensatz nur eine Accuracy von 0,89, Sensitivität von 0,87 und eine Spezifität von 0,91 aufweisen [45].

In der Studie wurden Bilder von Patient\*innen aller Altersgruppen verwendet. Das heißt, es wurde kein Unterschied zwischen Milch-, Wechsel- oder bleibenden Gebiss gemacht. Es konnte eine hohe Genauigkeit in allen Gebissarten gezeigt werden. Die Sensitivität und Spezifität zeigten ebenfalls die gute Leistung des Modells [45].

Da OPGs im OK Frontzahnbereich häufig unscharf sind, hat das Modell in diesem Bereich Mesiodentes oft nicht erkannt [45].

Eine weitere Einschränkung der Studie war die geringe Zahl der verwendeten Proben. Der interne Datensatz bestand aus 130 Bildern unterschiedlicher Dentition, jeweils 65 Aufnahmen mit und ohne Mesiodentes. Der externe Datensatz war noch kleiner, 118 Aufnahmen, bestehend aus 58 Bildern von Patient\*innen mit Mesiodentes und 60 ohne [45].

Das verwendete CNN-Modell für die vollautomatische Erkennung von Mesiodentes zeigte in multizentrischen Tests eine hohe Leistung in allen Gebissarten, einschließlich des Milchgebisses, des Wechselgebisses und des bleibenden

Gebisses. Ha et al. konkludieren, dass KI das Potenzial hat, Zahnärzt\*innen bei der Diagnose von Mesiodentes auf Panoramaröntgenbildern zu unterstützen [45]. Allerdings benötigt es weitere Forschungen mit Daten aus mehreren Zentren und Geräten, um die Leistung des Modells zu verbessern [45].

Ähnlich wie Ha et al. [45] beschäftigten sich Ahn et al. [44] ebenfalls mit der automatisierten Erkennung von Mesiodentes auf OPGs.

Ahn et al. [44] haben versucht, ein CNN-Modell zu erschaffen, welches Kliniker\*innen helfen kann, eine genaue und schnelle Diagnose zu stellen und eine automatisierte Klassifizierung von Mesiodentes auf Panoramaröntgenbildern ermöglicht [44].

Dafür wurden vier unterschiedliche, populäre vortrainierte CNN-Architekturen verwendet. Alle getesteten Architekturen konnten eine hohe Genauigkeit erzielen. Allerdings wurde deutlich, dass die Tiefe des Netzes einen Einfluss auf die Genauigkeit hatte. Je tiefer das Netz, desto besser die Leistung. Ahn et al. [44] konnte mit der CNN-Architektur Inception-ResNet-V2 eine Sensitivität von 0,91 erreichen, Ha et al. [45] erzielten mit dem internen Datensatz eine Sensitivität von 0,95 [44, 45].

Die Klassifizierungsleistung der KI wurde direkt mit menschlichen Gutachter\*innen verglichen. Dazu wurden erfahrene Kinderzahnärzt\*innen und junge, wenig erfahrene Zahnärzt\*innen gebeten, idente Bilder zu Befunden, wie die KI. Es konnte gezeigt werden, dass die Genauigkeit der Gutachter\*innen überlegen war, das AI-Modell allerdings deutlich schneller zu den Ergebnissen gelangt ist. Das System konnte die Ergebnisse in wenigen Sekunden liefern, während die Zahnärzt\*innen durchschnittlich ungefähr sieben Minuten dafür benötigten [44].

Ahn et al. [44] berichtet über eine mögliche Verbesserung der Genauigkeit der CNN-Architekturen durch die Vergrößerung des Trainingsdatensatzes. Insgesamt umfasste der Datensatz 1100 Bilder, 500 davon wurden zum Training des Algorithmus verwendet, 100 zur Validierung und 500 zur Testung des Modells [44]. Ein Problem der Studie war, dass nur Röntgenbilder von Patient\*innen mit Wechselgebiss verwendet wurden. In einer Folgestudie sollen intraorale Aufnahmen des OK Frontzahnbereichs anstatt der OPGs verwendet werden, um eine exaktere Diagnosestellung zu ermöglichen [44].

In der Regel konnten die getesteten CNN-Modelle die tatsächlichen Positionen der Mesiodentes und der sie umgebenden Zähne erkennen [44].

Die Ergebnisse dieser Studie sollen Kliniker\*innen zeigen, dass es KI-Modelle gibt, die sie bei der Diagnostizierung von Mesiodentes unterstützen können, indem sie diese Zähne auf Panoramaröntgenbildern, die während des Durchbruchs der Oberkieferfrontzähne aufgenommen wurden, automatisch erkennen können [44].

Ahn et al. [44] verwendeten im Unterschied zu Ha et al. [45] nur Panoramaröntgenbilder von Patient\*innen mit Wechselgebiss. Ahn et al. [44] sagen aus, dass da der OK Frontzahnbereich des Wechselgebisses im OPG häufig insuffizient dargestellt ist, ist es auch für gut funktionierende CNN-Architekturen schwer diesen Bereich verlässlich und genau zu segmentieren. Darum ist es besonders wichtig, beim Training der Modelle auf die Diversität der Daten und die Anzahl der vorhandenen Bilder zu achten [44, 45].

In beiden Publikationen wurde allerdings deutlich, dass computerunterstützte Diagnosetools eine große Hilfe, vor allem für junge Zahnärzt\*innen, sein können [44, 45].

Vila-Blanco et al. [188] stellten in ihrer Publikation einen CNN-Algorithmus vor, der einen objektiven, wiederholbaren und vollautomatischen Ansatz zur quantitativen Beschreibung der Unterkieferkontur auf der Grundlage von Orthopantomogrammen darstellt [188].

Für die quantitative Beschreibung des Unterkiefers wurden vier verschiedene Deskriptoren verwendet. Die Kombination der Formparameter und der Schwerpunktgröße ermöglichte, dass die Form- und Größeninformationen numerisch zusammengefasst werden konnten. Anschließend wurden diese Forminformationen verwendet, um die Beschreibung des Unterkiefers sowohl für eine halbautomatische als auch für eine vollautomatische Methode für das ausgewählte Experiment zu vergleichen. Die beiden Methoden wurden dann in verschiedenen Szenarien bewertet. Bei der halbautomatischen Methode musste eine Expert\*in die Orientierungspunkte der Unterkieferkontur beschriften. Bei der automatischen Methode wurde die durch das CNN extrahierte Unterkieferkontur abgerufen [188].

Die von Vila-Blanco et al. [188] vorgeschlagene Methode, die auf der automatischen Beschreibung des Unterkiefers basiert konnte sehr gute Ergebnisse erzielen. Sie zeigten eine Accuracy von 0,87. Die Architektur ist vielseitig einsetzbar, bei der Diagnose von Krankheiten oder vor chirurgischen Eingriffen beispielsweise [188]. Zusammenfassend sagen Vila-Blanco et al. [188], dass die in diesem Beitrag beschriebene automatische Methode zur Darstellung der Unterkieferkontur sehr zuverlässig ist und die dafür benötigte Zeit drastisch verkürzt hat [188].

#### **4.1.2 Kariesdetektion auf der Grundlage von Orthopantomogrammen**

Vinayahalingam et al. [189] untersuchte die Leistung eines ML-Modells, im Rahmen einer Pilotstudie, welches kariöse Läsionen an dritten Molaren erkennen sollte. Laut DGZMK Richtlinien ist Karies am 3.Molaren eine von mehreren therapeutischen Indikationen vor der chirurgischen Entfernung eines Weisheitszahnes [195]. Aus diesem Grund sind die sehr vielversprechenden Ergebnisse (Sensitivität: 0,86, Spezifität: 0,88, Accuracy: 0,87), die von Vinayahalingam et al. [189] erzielt werden konnten, um so erfreulicher. Eine Einschränkung der Studie bestand darin, dass nur beschnittene Bilder verwendet wurden. Dies führte zu besseren Ergebnissen, als wenn das gesamte OPG befundet worden wäre. Die positiv zu bewertenden Ergebnisse von Vinayahalingam et al. [189] geben einen guten Einblick in das Potential des verwendeten CNN-Modells [189].

#### **4.1.3 Radiologische Parodontalanalyse auf der Grundlage von Orthopantomogrammen**

Krois et al. [187], Thanathornwong et al. [190] und Kim et al. [58] befassten sich mit der CNN unterstützten Parodontalanalyse auf OPGs.

Thanathornwong et al. [190] untersuchte die automatisierte Erkennung parodontal geschädigter Zähne [190].

In dieser Studie konnten akzeptable Leistungen erzielt werden. Es wurde eine Sensitivität von 0,84, eine Spezifität von 0,88 und eine Genauigkeit von 0,81 erreicht. Allerdings sind die Ergebnisse des CNNs nicht direkt mit den Ergebnissen

der Expert\*innen vergleichbar, da die Parodontalanalyse nicht rein radiologisch erfolgt. Thanathornwong et al. [190] planen weitere Studien, welche die Identifizierung parodontal gefährdeter Zähne anhand konventioneller klinischer und radiologischer Befunde mit und ohne Unterstützung eines CNN-Modells vergleichen. Außerdem sind weitere Verbesserungen, beispielsweise die Erweiterung des Datensatzes oder die Verwendung modernerer CNN-Architekturen in Planung [190].

Zusammenfassend zeigten Thanathornwong et al. [190], dass trotz einer geringen Datenmenge von nur 100 verwendeten Bildern, zufriedenstellende Ergebnisse erreicht werden konnten [190].

Zu Beginn der Studie gingen Krois et al. [187] davon aus, dass ein KI-Modell nützlich sein kann. Da es eine höhere Genauigkeit und Zuverlässigkeit aufweist als Zahnärzt\*innen und gleichzeitig den diagnostischen Aufwand durch Zeitersparnis und weniger Dokumentation verringert. Das könnte eine gezieltere und anschließend genauere Diagnostik und Behandlung ermöglichen. Allerdings wurde diese Hypothese verworfen, da keine signifikant besseren Ergebnisse erzielt werden konnten. Das CNN, das auf einer begrenzten Anzahl von Bildsegmenten trainiert wurde (Trainingsdatensatz: 1400 Bild-Daten), zeigte ein ähnliches Diagnoseverhalten wie das der Zahnärzt\*innen. Krois et al. [187] konnten eine Sensitivität von 0,81 und eine Spezifität von 0,81 zeigen. Die Ergebnisse wurden allerdings auch von den sehr unterschiedlichen Ergebnissen der Befunder\*innen unterstrichen. Eine höhere Genauigkeit hätte, laut Krois et al. [187], durch einen größeren Datensatz erreicht werden können. Des Weiteren wurde zu Beginn der Studie versucht mit einem bereits vortrainierten CNN-Modell zu arbeiten, durch die weit gefassten Einschlusskriterien musste allerdings im Laufe der Studie ein maßgeschneidertes CNN- konstruiert werden. Krois et al. [187] hatten sich aktiv gegen engere Einschlusskriterien entschieden, da eine relevante Aufgabe eines CNN darin bestehen sollte, die zahnärztliche Diagnostik auch bei schwer zu beurteilenden Bildern zu verbessern [187].

Kim et al. [38] konnten in ihrer Studie zeigen, dass eine vollautomatische Methode zur Erkennung des knöchernen Attachmentverlustes möglich ist. Das von Kim et al. [38] verwendete CNN-Modell ist ein individuell angefertigtes Modell namens

DeNTNet. Das verwendete CNN-Modell erzielte Ergebnisse (Sensitivität: 0,87, Spezifität: 0,96), die denen der Zahnärzt\*innen, welche die verwendeten Bilder zuvor markiert hatten, überlegen waren. Allerdings zeigte sich auch, dass das große Sichtfeld der Panoramaröntgenaufnahmen die Gesamtempfindlichkeit sowohl von Zahnärzt\*innen als auch die einer AI-Architektur bei der PBL-Erkennung begrenzt. Wie bereits erwähnt konnten allerdings sehr zufriedenstellende Ergebnisse erreicht werden, die durch eine größere Datenmenge weiter verbessert werden können. Kim et al. [38] gehen davon aus, dass dieser Ansatz für die klinische Praxis von großem Nutzen sein wird, da er die Effizienz der PBL-Diagnose verbessert und zusätzlich den Arbeitsaufwand verringert [38].

Krois et al. [187], Thanathornwong et al. [190] und Kim et al. [38] kamen alle zu dem Entschluss, dass das Potential des maschinellen Lernens im Hinblick auf die Parodontalanalyse eindeutig erkennbar ist. Allerdings weisen alle drei Autor\*innen auch deutlich auf die Notwendigkeit eines großen Datensatzes hin und beschreiben, dass es nicht möglich ist, die parodontale Prognose eines Zahnes rein radiologisch vorherzusagen [38, 187, 190]. Krois et al. [187] und Kim et al. [38] verwendeten eigens angefertigte CNN-Architekturen, um zufriedenstellende Ergebnisse zu erzielen [38, 187].

#### **4.1.4 Erkennung Periapikaler Läsionen auf der Grundlage von Orthopantomogrammen**

Die Studie von Endres et al. [191] dreht sich um die Erkennung periapikaler Läsionen auf Orthopantomogrammen, welche von Mund-, Kiefer-, Gesichtschirurg\*innen vor befundet wurden [191]. Es wurde ein maschineller Lernalgorithmus entwickelt, der zur Erkennung periapikaler Aufhellungen dient. Dieser hat nicht nur besser abgeschnitten als die Hälfte der erfahrenen MKG-Chirurg\*innen, sondern kann auch als ergänzendes Diagnoseinstrument und als Grundlage für ein umfassenderes und vollautomatisches Instrument zur Erkennung periapikaler Aufhellungen in der Zukunft dienen. Obwohl die Ergebnisse (Precision: 0,6) vielversprechend sind, gab es einige Einschränkungen in dieser Studie. Erstens wurde der Algorithmus anhand von Daten trainiert, die von MKG-Chirurg\*innen auf

der Grundlage von Röntgenbildern und nicht von klinischen Tests beschriftet wurden. Folglich kann der verwendete Algorithmus die inhärenten Einschränkungen und Voreingenommenheiten dieser MKG-Chirurg\*innen widerspiegeln, was zu einer Verschlechterung der Leistung führen kann. Des Weiteren beschreiben Endres et al. [191], dass ein Trainingsdatensatz, der an mehreren Standorten gesammelt wurde und eine größere Datenmenge umfasst, wahrscheinlich zu einer größeren Robustheit des Algorithmus führen würde [191].

#### **4.1.5 Klassifikation zystischer Läsionen auf der Grundlage von Orthopantomogrammen**

Vier Arbeiten dieser Literaturrecherche beschäftigten sich mit der Klassifikation zystischer Läsionen unter Verwendung von Panoramaröntgenbildern.

Kwon et al. [39] entwickelte ein modifiziertes CNN, um zystische Läsionen in beiden Kiefern automatisch zu erkennen und klassifizieren [39]. Es wurden odontogene Zysten (DZ), periapikale Zysten (PZ), odontogene Keratozysten (OKZ) und Ameloblastome (AB) befundet. Kwon et al. [39] erzielten sehr gute Ergebnisse, was vermutlich auf die große Menge an Daten und das hochmoderne CNN-Modell zurückzuführen ist. Der Algorithmus wurde mit 1026 Bildern „gefüttert“ und konnte eine Sensitivität von 0,88, Spezifität von 0,97 und eine Accuracy von 0,95 erreichen. Eine Schwierigkeit stellten die vielen gemeinsamen radiologischen Merkmale der Zysten und Tumore da, welche in dieser Studie klassifiziert wurden. Da es durch viele anatomische Strukturen zu Überlagerungen auf den Röntgenbildern kommt, ist es vor allem im OK zu Problemen aufgrund dieses Phänomens gekommen [39]. Das verwendete CNN-Modell diagnostizierte häufig ABs fälschlicherweise als OKZs, was an der geringen Zahl an Ameloblastomen liegen könnte. Allerdings ist eine definitive Diagnose rein radiologisch nicht möglich, da eine Histologische Abklärung dafür unumgänglich ist [39].

Kwon et al. [39] kamen zu dem Entschluss, dass sie ein CNN-Modell entwickelt haben, das Zahnärzt\*innen dabei helfen kann, Pathologien effizienter zu diagnostizieren und Patient\*innen dadurch besser zu behandeln. Dadurch kann so die Patient\*innenversorgung verbessert werden [39].

Yang et al. [47] haben in ihrer Forschungsarbeit die Vor- und Nachteile eines CNN-Algorithmus bei der automatischen Erkennung odontogene Zysten, Ameloblastome und odontogene Keratozysten untersucht [47]. Es wurden zystische Läsionen im OK und UK klassifiziert [47].

In dieser Studie wird darauf aufmerksam gemacht, dass die Diagnose der verschiedenen Zysten und Tumore vor allem im Anfangsstadium besonders herausfordernd ist, da das frühe radiologische Erscheinungsbild häufig sehr ähnlich ist [47].

Der von Yang et al. [47] verwendete Algorithmus konnte solide Ergebnisse erzielen. 1422 Bilder wurden zum Training des Algorithmus verwendet und anschließend wurde das CNN mit 181 Bildern getestet. Es wurde eine Sensitivität von lediglich 0,68 erreicht. Nur einer der fünf Gutachter\*innen konnte die KI übertreffen. Das lässt darauf schließen, dass es ein leistungsfähiges Instrument für die computerunterstützte Erkennung sein könnte [47].

Die verwendete Architektur hat anderen CNN-Modellen gegenüber den großen Vorteil, dass es sehr schnell arbeitet. In Anbetracht der Tatsache, dass die Fähigkeit der verwendeten Architektur, die Pathologie zu lokalisieren, gleichwertig mit den Fähigkeiten der an der Studie beteiligten Kliniker\*innen war, bestätigt die hohe Erkennungsgeschwindigkeit. Dies impliziert einen Vorteil bei der Befundung in der täglichen Praxis [47].

Im Gegensatz zu Yang et al. [47] konnten Kwon et al. [39] eine Sensitivität über 0,8 erreichen. Verwunderlich ist, dass dieselbe CNN-Architektur (YOLO) verwendet wurde und auch die Datensätze ähnlich groß waren (Yang et al. [47] 1603 Bilder, Kwon et al. [39] 1283 Bilder). Möglicherweise wurden unterschiedliche Ergebnisse durch die Definition des Goldstandards erreicht. In der Publikation von Kwon et al. [39] wurde er von zwei Radiolog\*innen definiert und Yang et al. [47] hatte fünf Expert\*innen aus Fachbereichen der MKG-Chirurgie und Allgemeinmedizin [39, 47].

Liu et al. [137] untersuchen in ihrer Arbeit das Potential eines KI-Modells, bei der Erkennung und Unterscheidung von Ameloblastomen und odontogenen Keratozysten [137].

Es wurde ein CNN-Architektur gefertigt, die aus zwei vortrainierten Modellen besteht. Mit Hilfe dieses Algorithmus konnten Ergebnisse (Sensitivität: 0,92, Spezifität: 0,87, Accuracy: 0,90) erzielt werden, die darauf schließen lassen, dass Zahnmediziner\*innen vor chirurgischen Eingriffen genauere Prognosen abgeben können, wenn sie die Unterstützung des Programms nützen [137].

Trotz des kleinen Datensatzes konnten eine zufriedenstellende Leistung erreicht werden. Um die Genauigkeit des Algorithmus zu verbessern, werden Liu et al. [137] die Anzahl und die Art der Proben erweitern [137].

In der Arbeit von Lee et al. [41] wurde die Leistung eines DL-Modells zur Erkennung von Staphne Kochenzysten (SBC) auf OPGs untersucht [41].

Da die Staphne Knochenzyste asymptomatisch und selbstlimitierend wächst, bedarf es keinerlei Behandlung [132]. Da die SBC vermehrt im UK auftritt, wurde in den verwendeten Bildern, ausschließlich das Unterkiefer inspiziert. Die Diagnose kann so vereinfacht werden und folglich auf einen chirurgischen Eingriff verzichtet werden. Da die Staphne Knochenzyste sich radiologisch meist als bohnenförmiger, scharf begrenzter Raum zeigt, der eine hohe Strahlentransparenz aufweist, was darauf hindeutet, dass es sich um einen leeren Hohlraum handelt, könnte der Einsatz einer MRT Bildgebung als sinnvoll erachtet werden. Eine Fehldiagnose kann auch schwerwiegender Folgen. Um das CNN robuster zu machen, wurden Daten verwendet, die von unterschiedlichen Panoramaröntgengeräten aufgenommen wurden [41].

In der Forschungsarbeit wurden die meisten SBC von der CNN-Architektur richtig diagnostiziert, indem das Modell einen runden, gut definierten, röntgenstrahlendurchlässigen, leeren Bereich direkt über dem unteren Rand des Unterkiefers als SBC erkannte. Nur ein Fall wurde fälschlicherweise als pathologische Läsion diagnostiziert. Dieser Fall zeigte multilokuläre und lappige Ränder, anders als bei gewöhnlicher SBC. Das CNN-Modell erzielte eine sehr hohe Sensitivität (0,98) und Spezifität (1) [41].

Da es auch atypische Formen der Staphne Knochenzyste gibt, kann das vorgestellte Diagnosetool als Hilfsmittel, laut Lee et al. [41], für Zahnmediziner\*innen dienen. Lee et al. [41] stellen in dieser Arbeit ein Modell vor, das den Behandler\*innen bei der Entscheidung helfen soll, ob weitere Untersuchungen oder chirurgische Eingriffe notwendig oder vermeidbar sind [41].

Kwon et al. [39] und Yang et al. [47] untersuchten odontogene Zysten, odontogene Keratozysten und Ameloblastome [39, 47]. Beide Autor\*innen konnten in ihren Arbeiten Ergebnisse erreichen, die mit den Ergebnissen der Gutachter\*innen vergleichbar waren. Sie erhoffen mit den gezeigten Leistungen deutlich gemacht zu haben, dass die vorgestellten Modelle eine bessere, schnellere und genauere Befundung und in weiterer Folge auch die richtige Diagnosestellung ermöglichen [39, 47].

Lee. et al. [41] zeigten in der Arbeit, dass zukünftig zahlreiche Eingriffe an SBCs vermieden werden können, wenn der CNN-unterstützte Ärzt\*in die richtige Diagnose stellt [41]. Die verglichenen Studien lassen das Potential der AI-unterstützten Erkennung und Klassifizierung diverser Zysten und Tumore deutlich erkennen [39, 41, 47, 137].

#### **4.1.6 Anatomische Strukturerkennung auf der Grundlage von DVT-Daten**

Minnema et al. [48] verfolgten das Ziel ein CNN-Modell zu entwickeln, welches die Knochensegmentierung in DVT Aufnahmen, die durch Aufhärungsartefakte beeinträchtigt sind, automatisiert ermöglicht [48].

Da es sehr anspruchsvoll sein kann 3D-Bilder genau zu interpretieren, kann eine computergestützte Verarbeitung tomographischer Daten von großer Hilfe sein. Es ist notwendig, die vorhandenen 3D-Bilddaten so zu adaptieren, dass die Überlagerung unterschiedlicher Datenformate und beispielsweise die Erkennung von Strukturen möglich ist [196]. Die Identifizierung als auch die Segmentierung von Daten, im speziellen in der zahnärztlichen Chirurgie, kann zum Beispiel für die Operationsplanung oder die Heilungsbeurteilung von Läsionen von Vorteil sein. Dieser neue Bereich umfasst die virtuelle chirurgische Planung, den 3D-Druck personalisierter Konstrukte, sowie anatomischer Modelle, chirurgische Schablonen, virtuelle und erweiterte Realität und robotergeführte Chirurgie. Um anatomische Modelle, chirurgische Schablonen für die computergestützte Chirurgie zu erhalten, ist eine genaue Segmentierung knöcherner Strukturen erforderlich. Dieser Schritt

der Bildsegmentierung wird jedoch häufig beispielsweise durch Metallartefakte behindert. [48].

Aufhärungsartefakte, die durch Füllungen, Implantate oder andere Restaurationen verursacht werden, stellen eine Herausforderung bei der DVT Befundung dar. Diese Artefakte können knöcherne Regionen im Unter- und Oberkiefer verdecken und zu Ungenauigkeiten und Zeitverlusten bei der Bildsegmentierung führen [48].

Minnema et al. [48] nutzte drei unterschiedliche CNN-Modelle. Alle in dieser Studie trainierten Architekturen waren in der Lage, knöcherne Strukturen zu segmentieren und Aufhärungsartefakte genauer als Hintergrund zu klassifizieren als die derzeitige klinische Benchmark. Weiters segmentierten alle verwendeten Architekturen die Bilder in unter fünf Minuten [48].

Das Vorhandensein von Aufhärungsartefaktem erschwert selbst erfahrenen Gutachter\*innen die Segmentierung von Bildern. Dies kann eine mögliche Herausforderung in Bezug auf die Genauigkeit des Goldstandards darstellen. Da die Qualität des Goldstandards sich direkt auf die Qualität der KI auswirkt, ist es umso wichtiger, mehrere erfahrene Befunder\*innen zur Segmentierung des Testdatensatzes einzusetzen. Eine weitere Möglichkeit diese Hürde zu umgehen ist ein bereits vortrainiertes CNN-Modell zu nutzen, welches die Bilder segmentiert. Ein oder mehrere Gutachter\*innen müssen somit nur die Korrektur der bereits befundeten Bilder vornehmen [48].

Mit einem durchschnittlichen DSC von 0,87 machen Minnema et al. [48] deutlich, dass vielversprechende Ergebnisse erreicht werden konnten. Sie zeigen, dass Deep Learning einzigartige Möglichkeiten zur Beseitigung der durch Aufhärungsartefakte verursachten Ungenauigkeiten im computerunterstützten Arbeitsablauf bietet [48].

Minnema et al. [48] sehen außerdem großes Potential für künftige Forschungen im Einsatz von 3D-CNNs [48].

#### **4.1.7 Erkennung periapikaler Läsionen auf der Grundlage von DVT-Daten**

Orhan et al. [36] versuchten in ihrer Arbeit die diagnostische Leistung eines künstlichen Intelligenzsystems zu zeigen, welches periapikale Läsionen auf DVT-Bildern richtig diagnostiziert.

Dadurch, dass auf konventionellen intraoralen oder extraoral Röntgenaufnahmen eine 3D-Struktur auf eine 2D-Ebene projiziert wird, resultieren Überlagerungen anatomischer Strukturen. Diese Überlagerungen erschweren den Behandler\*innen die Bildinterpretation und die Identifizierung von Strukturen, wobei Verzerrung und Vergrößerung zu einer Verringerung der Messgenauigkeit führen können. Obwohl herkömmliche Röntgenaufnahmen bei der Diagnose endodontischer Pathologien recht genau sind, haben sich die DVT-Aufnahmen als vorteilhaft für die Diagnose periapikaler Läsionen erwiesen. Deshalb wurden in der beschriebenen Arbeit DVT Aufnahmen genutzt. Durch die 3D-Darstellung der Wurzelstrukturen und die hohe Auflösungskapazität eignet sich die DVT-Aufnahme gut zur Erkennung möglicher Aufhellungen um die Apizes der betroffenen Zähne. Das führt zu einer besseren Diagnosestellung, Behandlungsplanung und ermöglicht eine genauere Prognose der betroffenen Zähne [35, 36].

Orhan et al. [36] konnten in ihrer Arbeit Ergebnisse vorstellen, die eine positive Korrelation zwischen den von den Radiolog\*innen vorgenommenen volumetrischen Messungen und den vom Gerät ermittelten Werten zeigen [36].

Das CNN-System war in der Lage, 142 von insgesamt 153 periapikalen Läsionen zu erkennen. Dies entspricht einer Zuverlässigkeit von 92,8%. Probleme erkannten Orhan et al. [36] bei der Erkennung getrennter Läsionen. Auch das Vorhandensein von Paro-Endo Läsionen und stark parodontal geschädigten Zähnen haben die KI beeinflusst. Des Weiteren wurden physiologische, anatomische Strukturen fälschlicherweise segmentiert (e.g. Foramen mentale). Es wurde beschlossen, dass weitere Modifizierungen des Modells notwendig sind, um einige dieser Probleme zu lösen [36].

Abschließend kamen Orhan et al. [36] zu dem Entschluss, dass KI-Systeme, die auf Deep-Learning-Methoden basieren, bei der Erkennung periapikaler Läsionen auf DVT- Aufnahmen für die klinische Anwendung nützlich sein können [36].

Setzer et al. [35] konzentrierte sich ebenfalls auf die computerunterstützte Segmentierung periapikaler Läsionen auf DVT-Bildern [35].

Die Daten, die in dieser Studie verwendet wurden, wurden im Vorfeld beschnitten, um dem verwendeten Modell nur bestimmte Ausschnitte zum Training anzubieten. Die umgebenden Strukturen wurden halbautomatisch segmentiert und anschließend manuell überarbeitet. In dieser begrenzten Umgebung erreichte die CNN-Architektur eine ausgezeichnete Genauigkeit bei der Erkennung von Läsionen. Die Ergebnisse waren vergleichbar mit denen der Kliniker\*innen. Die Architektur lieferte zwei falsch-negative Befunde. Setzer et al. [35] berichten über eine Sensitivität von 0,93 und einer Spezifität von 0,88, wobei jedoch nur 20 Datensätze verwendet wurden [35].

Eine übersehene Läsion war nur minimal größer als das Doppelte der Breite des Parodontalspalts und die andere wurde zwar zunächst erkannt, aber in den letzten Nachbearbeitungsschritten eliminiert. Das zeigt eine hohe Konsistenz des verwendeten CNN-Modells [35].

Setzer et al. [35] verwendeten eine U-Net Struktur, die den großen Vorteil hat, dass sie, anders als andere CNN-Architekturen, die eingespeisten Daten selbstständig erweitern kann. Dadurch konnte trotz der kleinen Datenmenge des Trainingsdatensatzes und der geringen Bildqualität mancher verwendeter Bilder eine hervorragende Genauigkeit erzielt werden. Es wurden lediglich Bilder ausgeschlossen, bei denen starke Strahlungsartefakte zu erkennen waren (beispielsweise verursacht durch Implantate) [35].

Das CNN-Modell hat das Potenzial noch bessere Ergebnisse zu liefern, wenn der Umfang des Trainingsdatensatzes vergrößert wird und anatomische Strukturen von der KI berücksichtigt werden [35].

Setzer et al. [35] machen Hoffnung auf die computerunterstützte Bildanalyse in naher Zukunft [35].

Sowohl Orhan et al. [36] als auch Setzer et al. [35] machen trotz der vielversprechenden Ergebnisse deutlich, dass eine große Datenmenge wichtig ist, um eine robuste CNN-Architektur trainieren zu können. Beide Studien lieferten ML-Modelle, die den Großteil der zu befundenden Läsionen richtig segmentiert haben. Die Probleme in den Studien waren vergleichbar. Die zwei größten Fehlerquellen waren die Menge der vorhandenen Daten und die ausgeprägte Ähnlichkeit mancher anatomischer Strukturen mit pathologischen Veränderungen [35, 36].

#### **4.1.8 Beleuchtung mehrere Anwendungsberieche auf der Grundlage von DVT-Daten**

Die Publikation von Ezhov et al. [37] war die einzige der 24 in dieser Literaturrecherche verglichenen, die sich mit mehr als einem Forschungsbereich befasste [37].

In der Veröffentlichung von wird ein DL-System vorgestellt, das in der Lage ist, automatisiert Zähne und andere anatomische Strukturen zu erkennen und sie richtig zu benennen, röntgenologisch sichtbaren parodontalen Knochenabbau zu erkennen, periapikale Aufhellungen zu zeigen und kariöse Läsionen zu identifizieren [37].

Das vorgestellte System wird Diagnocat genannt. Es handelt sich um eine Deep-Learning-Methode, die durch die automatische Ermittlung von Bildmerkmalen Ergebnisse liefert. Diagnocat wurde erstmals im Jahr 2018 veröffentlicht. In dieser Studie wurde die Leistung von Diagnocat im Vergleich zu erfahrenen Zahnärzt\*innen getestet. Es wurde die diagnostische Leistung und die dafür aufgebrauchte Zeit untersucht. Dafür wurden zwei Vergleichsgruppen gebildet. Eine Gruppe von Zahnärzt\*innen wurde von Diagnocat unterstützt und die andere Gruppe nicht. Als Grundlage dienten 1346 Bild-Daten, die zum Training und zur Validierung des Modells verwendet wurden [37].

Die Leistung, welche die Gruppe, die von Diagnocat unterstützt wurde, ist durchaus positiv zu bewerten. Ungenauigkeiten des Modells könnten auf eventuelle Unterschiede bei der Vorbefundung der Daten, welche durch 24 Zahnärzt\*innen erfolgte, verursacht worden sein. Feine anatomische Details sowie die Bewertung von Karies und parodontalem Knochenschwund können bei menschlichen Beobachter\*innen zu unterschiedlichen Segmentierungen führen. Es steht jedoch fest, dass die mit dem Diagnocat durchgeführten Röntgenauswertungen sehr präzise sind [37].

Die Gruppe mit KI-Unterstützung erreichte eine durchschnittliche Sensitivität von 0,85 und einen Spezifität von 0,97 gegenüber 0,77 bzw. 0,96 für die Gruppe ohne Unterstützung. Außerdem verkürzte das KI-System die durchschnittliche Zeit um 1,19 Minuten (6,78 %) [37].

Diagnocat kann eingesetzt werden, um die Behandler\*innen zu unterstützen. Es ermöglicht eine bessere Diagnosestellung, unterstützt die Behandlungsplanung und

hilft Behandlungsergebnisse vorherzusagen. Der Einsatz von Systemen zur Entscheidungsunterstützung als Zweitmeinung kann die Genauigkeit der Diagnose verbessern und Zeit bei der Bewertung und Bezeichnung einsparen [37].

Im direkten Vergleich mit der Gruppe ohne Unterstützung eines KI-Modells, konnte gezeigt werden, dass die Spezifität und Sensitivität des Bewertungsprozesses in der KI-gestützten Gruppe verbessert und die benötigte Diagnosezeit reduziert werden konnte [37].

Nichtsdestotrotz hatte die Studie Einschränkungen. Es wurden beispielsweise zwar Daten verwendet, welche von drei unterschiedlichen DVT-Geräten stammten, allerdings würden eine größere Diversität zu genaueren Ergebnissen führen.

Zusammenfassend konnten Ezhov et al. [37] einen signifikanten Unterschied zwischen der KI-Unterstützten Gruppe und der Gruppe ohne Unterstützung zeigen. Diagnocat hat die Diagnoseleistung der Befunder\*innen deutlich verbessert und kann als Entscheidungshilfe im klinischen Alltag verwendet werden [37].

#### **4.1.9 Kariesdetektion auf der Grundlage von intraoralen Kleinbildaufnahmen**

In dem von Zheng et al. [46] veröffentlichten Artikel werden drei unterschiedliche CNN-Architekturen getestet, welche tiefe kariöse Läsionen auf intraoralen Kleinbildröntgen automatisiert erkennen sollen [46].

Es zeigte sich, dass eine der drei Architekturen eine deutlich verbesserte Genauigkeit aufweisen konnte als die anderen zwei getesteten sowie die Vergleichszahnärzt\*innen. Die KI zeigte eine signifikant verbesserte Leistung und damit ein vielversprechendes Potenzial. Es konnte eine Accuracy von 0.82, eine Sensitivität von 0.85 und eine Spezifität von 0.81 erreicht werden [46].

Zheng et al. [46] beschrieben, dass der verwendete Datensatz, bestehend aus 844 intraoralen KB-Aufnahmen, aufgrund des hohen Zeit- und Arbeitsaufwands klein war. Aus diesem Grund wurden vortrainierte CNN-Modelle verwendet und Techniken zur Datenerweiterung angewandt [46].

Diese Studie weist auch einige Einschränkungen auf. Obwohl die Diagnose der in die Studie einbezogenen Fälle einstimmig von einem Gremium aus drei Endodontolog\*innen mit mehr als zehn Jahren klinischer Erfahrung gestellt wurde,

kann sie nicht als Goldstandard für die Diagnose von tiefer Karies und Pulpitis dienen, da die Diagnosestellung nicht rein röntgenologisch möglich ist. Außerdem konzentrierte sich die Arbeit auf Zähne mit einer einzigen kariösen Läsion [46].

Da es selbst für erfahrene Kliniker\*innen, trotz guter Bildqualität, schwierig ist die gesunden und kranken Bereiche genau zu unterscheiden und die visuelle Beurteilung der Eindringtiefe der Karies auf den jeweiligen Röntgenbildern subjektiv sein kann und stark von der klinischen Erfahrung der Zahnärzt\*in beeinflusst werden kann, ist eine zuverlässige computerunterstützte Hilfe von großem Vorteil.

Unter der Berücksichtigung der klinischen Parameter, zeigte eines der drei getesteten KI-Modelle eine deutlich verbesserte Leistung, die ein vielversprechendes Potenzial für die klinische Diagnose von tiefer Karies und Pulpitis zeigt [46].

#### **4.1.10 Implantatanalyse auf der Grundlage von intraoralen Kleinbildaufnahmen**

Kim et al. [58] stellten sich in ihrer Studie der Frage, ob tiefe neuronale Netze vier verschiedene Arten von Implantaten auf intraoralen Röntgenbildern identifizieren können [58].

Da es im klinischen Alltag häufig auftritt, dass Patient\*innen mit Komplikationen oder dem Wunsch einer Neuversorgung eines Implantats vorstellig werden, ist es von großer Bedeutung, dass die Behandler\*innen sicherstellen können, um welches Implantatsystem es sich handelt. Häufig liegen keine genauen medizinischen Aufzeichnungen vor. In solchen Fällen ist das Wissen der Zahnärzt\*innen besonders gefragt. Vor allem junge, unerfahrene Mediziner\*innen stehen an diesem Punkt oft vor Problemen. Darum ist es von Bedeutung, KI unterstützte Algorithmen zu entwickeln, die eine automatisierte Erkennung ermöglichen [58].

Bilder der vier folgenden Implantatsysteme wurden für die Forschungsarbeit genutzt: Brånemark Mk TiUnite®, Dentium Implantium®, Straumann Bone Level® und Straumann Tissue Level®. Um eine geeignete CNN-Architektur ermitteln zu können, testeten Kim et al. [58] fünf unterschiedliche vortrainierte Architekturen. Weiters wurden ausschließlich Bilder verwendet, die von intraoralen Kleinbildern stammen, welche in der Rechtwinkeltechnik aufgenommen wurden [58].

Die von Kim et al. [58] getesteten CNN-Modelle weisen unterschiedliche Tiefe auf. In der Literatur wird häufig beschrieben, dass die Tiefe des Netzes direkt proportional mit der Genauigkeit der Architektur zusammenhängt – das konnten Kim et al. [58] in ihrer Arbeit nicht bestätigen. Die verwendete Architektur ResNet-50 erreichte die höchste Genauigkeit (0,98) der getesteten Modelle [58].

Es konnte bestätigt werden, dass ein CNN radiologische Aufnahmen von Implantaten analysieren und die vier ausgewählten Implantatsysteme mit hoher Genauigkeit automatisch klassifizieren kann. Man konnte zeigen, dass die trainierten Modelle genau nach einem bestimmten Teil jedes Implantats suchen, um sie zu verlässlich zu erkennen (e.g. transgingivaler Teil an Straumann Tissue Level Implantaten). Es handelt sich um Bereiche, die für jeden Implantattyp charakteristisch sind [58].

Die Studie wies auch einige Schwierigkeiten auf. Da im klinischen Betrieb weitaus mehr als vier unterschiedliche Implantatsysteme verwendet werden, ist es für zukünftige Studien wichtig, eine Datenbank mit größeren Mengen an unterschiedlichen Systemen aufzubauen. Diese Datenbank sollte speziell auch Implantattypen beinhalten, die nur selten eingesetzt werden. Um das KI-Modell robuster zu machen, ist außerdem eine größere Datenmenge, als die in dieser Studie verwendeten, notwendig. Kim et al. [58] untersuchte nur Bilder, die ein Implantat enthielten, darum wären weitere Forschungen sinnvoll, die sich auf die Erkennung mehrerer Implantate auf einem Bild konzentriert. Da wie bereits erwähnt ausschließlich intraorale Kleinbildaufnahmen verwendet wurden, wäre es außerdem von Vorteil, das KI-Modell so zu trainieren, dass es in der Lage ist auch Panoramaröntgenbilder richtig zu befunden [58].

In der Zukunft soll das Netzwerk in der Lage sein nicht nur den Typ des Implantats zu erkennen, sondern auch Implantatlänge und Durchmesser erkennen können. Dadurch wäre auch eine Zustandsprognose und Periimplantitis Diagnose zu ermöglichen. Zusammenfassend lässt sich sagen, dass Kim et al. [58] in ihrer Studie zeigen konnten, dass die Klassifizierung unterschiedlicher Implantate durch ein KI-System, welches trainiert wurde, automatisiert und mit hoher Genauigkeit ermöglicht [58].

#### **4.1.11 Implantatanalyse auf der Grundlage von Orthopantomogrammen und intraoralen Kleinbildaufnahmen**

Lee et al. [42], und Lee et al. [192], nutzen in ihren Forschungsarbeiten sowohl KB-Röntgen-, als auch Panoramaröntgen Aufnahmen. In beiden Veröffentlichungen wurde der Anwendungsbereich der Implantatanalyse beleuchtet.

Zu Beginn der Studie von Lee et al. [42], wurde das Ziel definiert. Ziel war es, die Wirksamkeit des CNN-Algorithmus für die Identifizierung und Klassifizierung von Implantatsystemen zu bewerten [42].

Es wurden Panoramaröntgenbilder und intraorale Kleinbildaufnahmen für das Training, die Testung und die Validierung des AI-Algorithmus verwendet. Außerdem wurden drei unterschiedliche Implantatsysteme mit ähnlichen Formen verwendet, Osstem® TSIII, Dentium Superline® und Straumann BLT® [42].

Die erzielten Ergebnisse waren durchwegs positiv. Das verwendete, vortrainierte KI-Modell lieferte zuverlässige Leistungen und war einer erfahrenen Zahnärzt\*in, welche als Kontrollgruppe diente, überlegen. Es wurde deutlich, dass die Leistung der Zahnärzt\*in bei der Identifizierung der Implantate auf KB-Aufnahmen besser war als bei der Verwendung von Panoramabildern. Die Ergebnisse für das CNN-Modell waren sehr ähnlich, egal welche Art der Bildgebung verwendet wurde. Das Implantat der Firma Straumann wurde von dem System am häufigsten richtig klassifiziert. Dies könnte auf die Form des Implantats zurückzuführen sein. Ein Problem stelle die kleine Menge an zur Verfügung stehenden Daten dar. Die praktische Anwendung des Systems wird außerdem durch die nicht vorhandene Datenbank aller denkbaren Implantatsysteme eingeschränkt. Die eindeutige Identifizierung wird auch durch die Verzerrung, die die 2D-Bildgebungsverfahren mit sich bringen, erschwert. Wenn allerdings Informationen wie Länge und Durchmesser des Implantats in den Datensatz aufgenommen werden, kann die Klassifizierungsgenauigkeit weiter verbessert werden. Dies kann beispielsweise durch 3D-Bildgebungsverfahren ermöglicht werden [42].

Lee et al. [42], kamen zu dem Entschluss, dass KI-Modelle die Kliniker\*innen bei der Klassifizierung unterschiedlicher Implantatsysteme behilflich sein können.

In der Publikation von Lee et al. [192], wurde die Leistung eines, auf ML basierten Systems mit der Leistung zahnärztlicher Fachleute verglichen. Dafür wurden

insgesamt 11980 Panorama- und KB-Röntgenbilder aus drei unterschiedlichen Kliniken und sechs unterschiedliche Implantatsysteme verwendet. Astra OsseoSpeed® TX, Implantium®, Superline®, TSIII®, SLActive® BL und SLActive® BLT. Die gesamten Daten wurden in drei Gruppen geteilt, so entstand ein Trainingsdatensatz, ein Datensatz zur Testung des Algorithmus und einer zur Validierung. Zum Vergleich wurden 180 Bilder zufällig aus dem Testdatensatz entnommen und von 25 Zahnärzt\*innen, unterschiedlicher Spezialisierungen und Erfahrung, identifiziert. Um die Genauigkeit des Algorithmus mit der des zahnärztlichen Personals zu vergleichen, wurden die Panorama- und periapikale Röntgenbilder in einem Datensatz zusammengefasst (und nicht in separate Datensätze aufgeteilt). Da die in dieser Studie verwendeten Implantatsysteme alle ähnliche Form, aber unterschiedliche Durchmesser und Längen hatten, wurden sie nicht nach Durchmesser und Länge unterteilt, um den Datensatz zu erstellen. Da das Straumann SLActive® BLT-Implantat im Vergleich zu den anderen Implantaten eine große, konische Form aufweist, erzielten das automatisierte CNN und die Zahnärzt\*innen eine angemessen hohe Genauigkeit bei der Klassifizierung. Die übrigen Implantatsysteme, welche keine charakteristischen Auffälligkeiten aufwiesen, klassifizierte der verwendete Algorithmus korrekt, während das zahnärztliche Fachpersonal eine niedrigere Genauigkeit erzielte. Auf der Grundlage dieser Ergebnisse zeigte das automatisierte CNN eine statistisch signifikant höhere Klassifizierungsgenauigkeit als zahnärztliches Fachpersonal, einschließlich erfahrener Zahnärzt\*innen. Außerdem wurde aus den Ergebnissen deutlich, dass die Erfahrung der Befunder\*innen einen deutlichen Unterschied macht. Nicht nur beim Erkennen der verschiedenen Implantatsysteme, sondern auch bei der Interpretation der Röntgenbilder [42, 192].

Obwohl sechs Implantatsysteme aus drei verschiedenen Zahnkliniken ausgewählt und als Datensatz kategorisiert wurden, war der Trainingsdatensatz für die klinische Praxis noch nicht ausreichend. Daher ist es notwendig, einen qualitativ hochwertigen und umfangreichen Datensatz zu erstellen, der verschiedene Arten von Implantaten enthält. Lee et al. [42] vermuten, dass die Verwendung von DVT-Daten die Diagnoseleistung des KI-Modells weiter steigern könnte, da es zu keinerlei Verzerrung kommt [42].

Lee et al. [192] beschreiben, dass sie zeigen konnten, dass die Leistung des verwendeten Algorithmus die der meisten teilnehmenden Zahnärzt\*innen übertraf.

Vor allem die Gruppe der weniger erfahrenen Inspektor\*innen wurde von der KI übertroffen. Es wird angenommen, dass das automatisierte CNN Kliniker\*innen bei der Klassifizierung diverser Implantatsysteme auf der Grundlage von Panorama- und KB Röntgenbildern helfen kann [192].

Ein Vergleich der beiden Studien macht deutlich, dass sowohl Lee et al. [42], als auch Lee et al. [192] keine signifikanten Unterschiede bei der Befundung der zwei verglichenen Bildgebungsverfahren zeigen. Außerdem konnte gezeigt werden, dass die Leistung der Genauigkeit der CNN-Architekturen die Leistung der meisten Kliniker\*innen übertraf. Die Ergebnisse zeigten, dass es einen unbedeutenden Unterschied in der Genauigkeit der Klassifizierung zwischen den OPG-Daten und den KB-Daten Datensätzen gibt [42, 192].

#### **4.1.12 Kariesdetektion auf der Grundlage von Bissflügel Röntgenaufnahmen**

Im zahnärztlichen Alltag ist die Verwendung von Bissflügelröntgen zur Befundung von Approximalraumkaries weit verbreitet. Moran et al. [97] und Lee et al. [43] präsentierten in ihren Studien KI-Algorithmen, die eine automatisierte Befundung dieser Röntgenbilder ermöglichen sollen [43, 97].

Lee et al. [43] haben in ihrem Artikel ein CNN-Modell für die Karieserkennung auf Bissflügel-Röntgenbildern vorgestellt und untersucht, ob dieses Modell die Leistung der Kliniker\*innen verbessern kann [43].

Da vor allem das Erkennen von initialer Karies sehr schwer sein kann, verglichen Lee et al. [43] die Diagnoseleistung von Zahnarzt\*innen vor und nach dem Einbeziehen der Kariesvorhersage eines CNN-Algorithmus. Dafür befundeten drei Zahnmediziner\*innen den Evaluierungsdatensatz, die niedrigste Sensitivität wurde für die Initialkaries festgestellt. Je tiefer die Läsion, desto eher wurde sie von den Kliniker\*innen erkannt. Nach der Inspektion der Kariesvorhersage der KI wurden kleinere Läsionen deutlich häufiger und schneller von den Gutachter\*innen entdeckt. Es konnte ein signifikanter Unterschied zu der Vergleichsgruppe festgestellt werden. Daher waren die Hinweise des Deep-Learning-Modells sinnvoll, um Kliniker\*innen bei der Erkennung von Karies im Frühstadium zu helfen, die sonst

fälschlicherweise übersehen worden wären. Mit der Unterstützung durch das CNN-Modell, diagnostizierten die Mediziner\*innen mehr Karies mit höherer Sensitivität [43].

Das angewendete CNN-Modell zeigte eine recht genaue Erkennungsleistung und bestätigt, dass dieses Modell Kliniker\*innen bei der Erkennung von Karies in klinischen Situationen sinnvoll helfen kann [43].

Es werden auch Probleme beschrieben. Zum einen beschreiben Lee et al. [43], dass eine größere Datenmenge für das Training des Modells erforderlich ist, um eine robuste Struktur gestalten zu können. Da der verwendete Datensatz lediglich 354 Bilder umfasste. Des Weiteren wurden in dieser Studie lediglich Daten aus zwei unterschiedlichen Kliniken, welche die idente Röntgengeräte nutzen, herangezogen. Um in einem klinischen Umfeld ein sinnvolles Maß an Genauigkeit zu erreichen, muss zuvor geprüft werden, ob eine gleich gute oder ähnlich gute Leistung bei der Karieserkennung erzielt werden kann, wenn Röntgenaufnahmen von Milchzähnen oder Röntgenaufnahmen verwendet werden, die mit Geräten mehrerer klinischer Einrichtungen aufgenommen wurden. Ein weiteres Problem ist, dass in dieser Studie die kariösen Läsionen rein auf radiologischem Weg beurteilt wurden. Ein Goldstandard sollte eigentlich erst definiert werden, wenn das Vorhandensein von Karies tatsächlich belegt wurde [43].

Da der verwendete Algorithmus auch Bereiche befundet, die im hektischen klinischen Alltag versehentlich übersehen werden können, kann es die Zahnärzt\*in dazu veranlassen, sich diese Bereiche noch einmal genauer anzusehen, wodurch die Wahrscheinlichkeit erhöht wird, Karies frühzeitig zu erkennen [43].

In der Arbeit von Moran et al. [97] wurde eine neue Methode vorgeschlagen, die Bildverarbeitungstechniken und neuronale Faltungsnetzwerke kombiniert, um Approximalraumkaries in Röntgenbildern zu erkennen und sie nach dem Schweregrad der Läsion zu klassifizieren [97].

Moran et al. [97] nutzen zwei unterschiedliche ML-Strategien, ResNet und Inception. Diese wurden auf der Basis eines Trainingsdatensatzes trainiert und anschließend getestet und validiert. Die kariösen Läsionen auf den verwendeten Bildern wurden im Vorfeld von Zahnärzt\*innen markiert und in drei Schweregrade eingeteilt [97].

Bei beiden Modellen ist eine große Ungleichheit in der Diagnoseleistung für die drei verschiedenen Klassen zu erkennen. Die ausgewogensten Ergebnisse lieferte die ML-Architektur Inception.

Inception zeigt auch vielversprechende Ergebnisse, wenn es mit der Leistung von Zahnärzt\*innen verglichen wird. Diese Ergebnisse deuten darauf hin, dass die vorgeschlagene Methode Zahnmediziner\*innen bei der Auswertung von BF-Röntgenbildern und der Bestimmung des Kariesschweregrads helfen kann [97].

Die Studien von Moran et al. [97] und Lee et al. [43] lassen sich gut miteinander vergleichen, da die gewünschten Parameter ähnlich definiert waren [43, 97]. Beide Artikel schlugen artifizielle Intelligenzmodelle vor, die zur automatisierten Befundung und Bestimmung des Schweregrads kariöser Läsionen dienen sollen. Es konnte gezeigt werden, dass in den genannten Studien ähnliche Probleme aufgetreten sind. Das Stadium der initialen Karies stellte für die Gutachter\*innen beider Studien die größte Schwierigkeit dar. Sowohl Lee et al. [43] als auch Moran et al. [97] zeigten, dass die Definition eines Goldstandards nicht möglich ist, wenn nur radiologische Befunde erhoben werden, es sollte sowohl eine klinische und auch histologische Beurteilung der Läsionen erfolgen. Um die Strukturen robuster und damit auch für den klinischen Betrieb verwendbar zu machen, sollten die Daten, die zum Training der Modelle verwendet werden sowohl multizentrisch erhoben werden, als auch eine möglichst große Menge an Daten verwendet werden [43, 97].

## 5 Konklusion

Die in dieser systematischen Übersicht analysierten Studien haben gezeigt, dass die KI-Technologie in verschiedenen Fachbereichen der Zahnmedizin weit verbreitet ist. Ein direkter Vergleich der eingeschlossenen Studien wird durch die vielen unterschiedlichen Anwendungsbereiche, Bildgebungsarten, ML-basierten Modelle und Metriken der Publikationen deutlich erschwert.

Die meisten Autor\*innen standen vor den gleichen Hürden. Da ML-Strategien darauf basieren aus den bereits bekannten Daten zu lernen, ist es von großem Vorteil, wenn der Datensatz, mit dem die Architektur trainiert wird, möglichst groß ist. Imbalancen der pathologischen Veränderungen spielen ebenfalls eine Rolle. Weiters ist es nur dann möglich einen robusten Algorithmus zu kreieren, wenn die eingespeisten Daten möglichst divers sind, sprich von vielen unterschiedlichen Geräten stammen. Eine weitere Schwierigkeit ist die Definition des Goldstandards. Da die Anzahl und die Expertise der Gutachter\*innen stark variieren. In den meisten diskutierten Forschungsberichten beruht die Erstellung eines Goldstandards auf Befunden, die rein radiologisch erhoben wurden, nicht möglich. Die parodontale Prognose eines Zahnes ist beispielsweise von vielen Parametern abhängig, die von erfahrenen Zahnmediziner\*innen klinisch erhoben werden müssen.

Die Unterstützung durch KI-Systeme, die auf dem Grundprinzip des maschinellen Lernens basieren, kann eine gezieltere und anschließend genauere Diagnostik, Behandlungsplanung und anschließende Behandlung ermöglichen. Vor allem junge und unerfahrenere Zahnärzt\*innen können von diesen Hilfetools profitieren, da sie zu einer exakten Diagnosestellung beitragen können. Dadurch kann eventuell eine Vielzahl von Pathologien, die sonst unerkannt geblieben wären, frühzeitig erkannt und behandelt werden. Außerdem wurde in einigen der Studien gezeigt, dass durch die Hilfe der Algorithmen auch eine deutliche Zeitersparnis gewährleistet sein kann, was im häufig sehr stressigen klinischen Alltag einen großen Vorteil bringen kann.

Die künstliche Intelligenz ist auf dem besten Weg, ein wertvolles Hilfsmittel für Fachleute im Gesundheitswesen zu werden. Obwohl weitere Forschungsarbeiten erforderlich sind, um die unzähligen offenen Fragen zu klären, stellen viele Arbeit

vielversprechende erste Schritte zur Realisierung eines ML-basierten Hilfsmittels in der Zahnmedizin dar. In dem Ausmaß, wie die Rolle der KI im Gesundheitswesen an Bedeutung gewinnt, kann man optimistisch sein, dass die Organisationen des Gesundheitswesens ihre Datenerfassungspraktiken anpassen werden, um sie besser auf die Bedürfnisse von ML abzustimmen. Dies wird letztendlich die Entwicklung von datenfusionierten Modellen ebnen und möglicherweise dazu führen, dass Röntgenbilder mit anderen Patient\*innendaten kombinierbar werden, um äußerst zuverlässige Diagnosen erstellen zu können.

## Literaturverzeichnis

1. Fiorellini, J.P., et al., *Randomized study evaluating recombinant human bone morphogenetic protein-2 for extraction socket augmentation*. *J Periodontol*, 2005. 76(4): p. 605-13.
2. Yasaka, K. et al., *Deep learning and artificial intelligence in radiology: Current applications and future directions*. *PLoS Med*, 2018. 15(11): p. e1002707.
3. Pesapane, F. et al., *Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine*. *Eur Radiol Exp*, 2018. 2(1): p. 35.
4. Nevin, L. et al., *Advancing the beneficial use of machine learning in health care and medicine: Toward a community understanding*. *PLOS Medicine*, 2018. 15(11): p. e1002708.
5. Gulshan, V., et al., *Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs*. *JAMA*, 2016. 316(22): p. 2402-2410.
6. Mazurowski, M.A., et al., *Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI*. *J MAGN RESON IMAGING* , 2019. 49(4): p. 939-954.
7. Esteva, A., et al., *Dermatologist-level classification of skin cancer with deep neural networks*. *Nature*, 2017. 542(7639): p. 115-118.
8. Marcus, G. et al., *Deep learning: A critical appraisal*. *arXiv preprint arXiv:1801.00631*, 2018.
9. Doi, K. et al., *Computer-aided diagnosis in medical imaging: historical review, current status and future potential*. *Comput Med Imaging Graph*, 2007. 31(4-5): p. 198-211.
10. Rezaei, M. et al., *Deep Neural Network with l2-Norm Unit for Brain Lesions Detection*. in *Neural Information Processing*. 2017. Cham: Springer International Publishing.
11. LeCun, Y. et al., *Deep learning*. *Nature*, 2015. 521(7553): p. 436-444.
12. Khanagar, S.B., et al., *Developments, application, and performance of artificial intelligence in dentistry - A systematic review*. *J Dent Sci*, 2021. 16(1): p. 508-522.
13. Rajaraman, V. et al., *JohnMcCarthy — Father of artificial intelligence*. *Resonance*, 2014. 19(3): p. 198-207.
14. Council, N.R. et al., *Funding a revolution: Government support for computing research*. 1999: National Academies Press.
15. Velarde, G. et al., *Artificial Intelligence and its Impact on the Fourth Industrial Revolution: A Review*. Vol. 10. 2019.
16. Bellman, R. et al., *An introduction to artificial intelligence: can computers think?* 1978: Thomson Course Technology.
17. Turing, A.M. et al., *Computing machinery and intelligence, in Parsing the turing test*. 2009, Springer. p. 23-65.
18. Tegmark, M. et al., *Life 3.0: Being human in the age of artificial intelligence*. 2017: Vintage.
19. Ahuja, A.S. et al., *The impact of artificial intelligence in medicine on the future role of the physician*. *PeerJ*, 2019. 7: p. e7702.

20. Hung, K., et al., *The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review.* *Dentomaxillofac Radiol*, 2020. 49(1): p. 20190107.
21. Akst, J. et al., *A primer: artificial intelligence versus neural networks*, in *The Scientist: Exploring Life, Inspiring Innovation*. 2019.
22. Wang, H., et al., *Machine learning basics. Deep learning*, [[http://www.whdeng.cn/Teaching/PPT\\_01\\_Machine%20learning%20Basics.pdf](http://www.whdeng.cn/Teaching/PPT_01_Machine%20learning%20Basics.pdf)] 2016: p. 98-164.
23. Lanquillon, C. et al., *Grundzüge des maschinellen Lernens*, in *Blockchain und maschinelles Lernen*. 2019, Springer. p. 89-142.
24. Janiesch, C. et al., *Machine learning and deep learning.* *Electronic Markets*, 2021. 31(3): p. 685-695.
25. Alzubaidi, L., et al., *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions.* *J Big Data*, 2021. 8(1): p. 53.
26. Mahesh, B. et al., *Machine learning algorithms-a review.* *International Journal of Science and Research (IJSR)*. [Internet], 2020. 9: p. 381-386.
27. Tan, M. et al., *Prediction of student dropout in e-Learning program through the use of machine learning method.* *International journal of emerging technologies in learning*, 2015. 10(1).
28. Mitchell, T.M. et al., *The discipline of machine learning.* Vol. 9. 2006: Carnegie Mellon University, School of Computer Science, Machine Learning
29. O'Shea, K. et al., *An introduction to convolutional neural networks.* arXiv preprint arXiv:1511.08458, 2015.
30. Albawi, S. et al., *Understanding of a convolutional neural network.* in *2017 international conference on engineering and technology (ICET)*. 2017. Ieee.
31. Li, Y. et al., *Survey of convolutional neural network.* *J Com App*, 2016. 36(9): p. 2508.
32. Albawi, S., et al., *Social Touch Gesture Recognition Using Convolutional Neural Network.* *Comput Intell Neurosci*, 2018. 2018: p. 6973103.
33. Chauhan, R. et al., *Convolutional neural network (CNN) for image detection and recognition.* in *2018 First International Conference on Secure Cyber Computing and Communication (ICSCCC)*. 2018. IEEE.
34. Karam, A.-F., et al. *Applying convolutional neural networks for image detection.* in *2019 International Conference on Smart Applications, Communications and Networking (SmartNets)*. 2019. IEEE.
35. Setzer, F.C., et al., *Artificial Intelligence for the Computer-aided Detection of Periapical Lesions in Cone-beam Computed Tomographic Images.* *J Endod*, 2020. 46(7): p. 987-993.
36. Orhan, K., et al., *Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans.* *Int Endod J*, 2020. 53(5): p. 680-689.
37. Ezhov, M., et al., *Clinically applicable artificial intelligence system for dental diagnosis with CBCT.* *Sci Rep*, 2021. 11(1). [page 2-7]
38. Kim, J., et al., *DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs.* *Sci Rep*, 2019. 9(1).
39. Kwon, O., et al., *Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolution neural network.* *DMFR* , 2020. 49(8).

40. *Künstliche Intelligenz (KI) • Definition | Gabler Wirtschaftslexikon.*  
<https://wirtschaftslexikon.gabler.de/definition/kuenstliche-intelligenz-ki-40285> [12. August 2022]
41. Lee, A., et al., Deep learning neural networks to differentiate Stafne's bone cavity from pathological radiolucent lesions of the mandible in heterogeneous panoramic radiography. *PLoS ONE*, 2021. 16(7 July).
42. Lee, J.H. et al., Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: A pilot study. *Medicine*, 2020. 99(26): p. e20787-e20787.
43. Lee, S., et al., Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep*, 2021. 11: p. 16807-16807.
44. Ahn, Y., et al., Automated mesiodens classification system using deep learning on panoramic radiographs of children. *Diagnostics*, 2021. 11(8).
45. Ha, E.G., et al., Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Sci Rep*, 2021. 11(1).
46. Zheng, L., et al., Artificial intelligence in digital cariology: a new tool for the diagnosis of deep caries and pulpitis using convolutional neural networks. *Annals of Translational Medicine*, 2021. 9(9): p. 763-763.
47. Yang, H., et al., Deep learning for automated detection of cyst and tumors of the jaw in panoramic radiographs. *J Clin Med*, 2020. 9(6): p. 1-14.
48. Minnema, J., et al., Segmentation of dental cone-beam CT scans affected by metal artifacts using a mixed-scale dense convolutional neural network. *Med Phys*, 2019. 46(11): p. 5027-5035.
49. Targ, S. et al., Resnet in resnet: Generalizing residual architectures. *arXiv preprint arXiv:1603.08029*, 2016.
50. He, K., et al. Deep residual learning for image recognition. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
51. Simonyan, K. et al., Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
52. Ronneberger, O. et al., U-net: Convolutional networks for biomedical image segmentation. in *International Conference on Medical image computing and computer-assisted intervention*. 2015. Springer.
53. Shelhamer, E. et al., Fully Convolutional Networks for Semantic Segmentation. *IEEE Trans Pattern Anal Mach Intell*, 2017. 39(4): p. 640-651.
54. Nazem, F., et al., 3D U-Net: A Voxel-based method in binding site prediction of protein structure. *J Bioinform Comput Biol*, 2021. 19: p. 2150006.
55. Redmon, J., et al. You only look once: Unified, real-time object detection. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
56. Redmon, J. et al., YOLO9000: better, faster, stronger. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
57. Sengupta, A., et al., Going deeper in spiking neural networks: VGG and residual architectures. *Front neurosci*, 2019. 13: p. 95.
58. Kim, J.E., et al., Transfer learning via deep neural networks for implant fixture system classification using periapical radiographs. *J Clin Med*, 2020. 9(4). [page 1-11]

59. Collen, M.F. et al., *The history of medical informatics in the United States*. 2015: Springer.
60. Park, W.J. et al., *History and application of artificial neural networks in dentistry*. *European journal of dentistry*, 2018. 12(04): p. 594-601.
61. Ramesh, A.N., et al., *Artificial intelligence in medicine*. *Ann R Coll Surg Engl*, 2004. 86(5): p. 334-8.
62. Rajkomar, A. et al., *Machine Learning in Medicine*. *N Engl J Med*, 2019. 380(14): p. 1347-1358.
63. Wiens, J., et al., *Learning Data-Driven Patient Risk Stratification Models for Clostridium difficile*. *Open Forum Infect Dis*, 2014. 1(2): p. ofu045.
64. Henry, K.E., et al., *A targeted real-time early warning score (TREWScore) for septic shock*. *Sci Transl Med*, 2015. 7(299): p. 299ra122.
65. Colubri, A., et al., *Transforming Clinical Data into Actionable Prognosis Models: Machine-Learning Framework and Field-Deployable App to Predict Outcome of Ebola Patients*. *PLoS Negl Trop Dis*, 2016. 10(3): p. e0004549.
66. Motwani, M., et al., *Machine learning for prediction of all-cause mortality in patients with suspected coronary artery disease: a 5-year multicentre prospective registry analysis*. *Eur Heart J*, 2017. 38(7): p. 500-507.
67. Kehl, K.L., et al., *Assessment of deep natural language processing in ascertaining oncologic outcomes from radiology reports*. *JAMA oncology*, 2019. 5(10): p. 1421-1429.
68. Morgan, D.J., et al., *Assessment of machine learning vs standard prediction rules for predicting hospital readmissions*. *JAMA network open*, 2019. 2(3): p. e190348-e190348.
69. Sultan, A.S., et al., *The use of artificial intelligence, machine learning and deep learning in oncologic histopathology*. *J Oral Pathol Med*, 2020. 49(9): p. 849-856.
70. Leonardi, R.M., et al., *Accuracy of cephalometric landmarks on monitor-displayed radiographs with and without image emboss enhancement*. *Euro J Orthod*, 2010. 32(3): p. 242-247.
71. Xie, X. et al., *Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment*. *Angle Orthod*, 2010. 80(2): p. 262-266.
72. Moghimi, S. et al., *Design and implementation of a hybrid genetic algorithm and artificial neural network system for predicting the sizes of unerupted canines and premolars*. *Euro J Orthod*, 2012. 34(4): p. 480-486.
73. Jung, S.-K. et al., *New approach for the diagnosis of extractions with neural network machine learning*. *Am J Orthod Dentofacial Orthop*, 2016. 149(1): p. 127-133.
74. Wang, X., et al., *Objective method for evaluating orthodontic treatment from the lay perspective: an eye-tracking study*. *Am J Orthod Dentofacial Orthop*, 2016. 150(4): p. 601-610.
75. Patcas, R., et al., *Applying artificial intelligence to assess the impact of orthognathic treatment on facial attractiveness and estimated age*. *Int J Oral Maxillofac Surg*, 2019. 48(1): p. 77-83.
76. Kunz, F., et al., *Artificial intelligence in orthodontics*. *J Orofac Orthop*, 2020. 81(1): p. 52-68.
77. Arijji, Y., et al., *Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object*

- detection technique. *Oral Surg Oral Med Oral Pathol Oral Radiol*, 2019. 128(4): p. 424-430.
78. Ehtesham, H., et al., *Developing a new intelligent system for the diagnosis of oral medicine with case-based reasoning approach*. *Oral diseases*, 2019. 25(6): p. 1555-1563.
  79. Tamaki, Y., et al., *Construction of a dental caries prediction model by data mining*. *J oral sci*, 2009. 51(1): p. 61-68.
  80. Araki, K., et al., *Effect of computer assistance on observer performance of approximal caries diagnosis using intraoral digital radiography*. *Clin oral investig*, 2010. 14(3): p. 319-325.
  81. Lee, J.-H., et al., *Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm*. *J Dent*, 2018. 77: p. 106-111.
  82. Hung, M., et al., *Application of machine learning for diagnostic prediction of root caries*. *Gerodont*, 2019. 36(4): p. 395-404.
  83. Cantu, A.G., et al., *Detecting caries lesions of different radiographic extension on bitewings using deep learning*. *J dent*, 2020. 100: p. 103425.
  84. Geetha, V. et al., *Dental caries diagnosis in digital radiographs using back-propagation neural network*. *Health Inf Sci Syst*, 2020. 8(1): p. 1-14.
  85. Liu, L., et al., *Dental Caries Prediction Based on a Survey of the Oral Health Epidemiology among the Geriatric Residents of Liaoning, China*. *BioMed research international*, 2020. 2020.
  86. Schwendicke, F., et al., *Deep learning for caries lesion detection in near-infrared light transillumination images: A pilot study*. *J Dent*, 2020. 92: p. 103260.
  87. ISO. *Dentistry — Designation system for teeth and areas of the oral cavity Committee (ISO 3950:2016(en))*. 2016 [cited 2022 13.09.]; 4:[Available from: <https://www.iso.org/obp/ui/#iso:std:iso:3950:ed-4:v1:en>].
  88. Tuzoff, D.V., et al., *Tooth detection and numbering in panoramic radiographs using convolutional neural networks*. *Dentomaxillofac Radiol*, 2019. 48(4).
  89. Mahdi, F.P. et al., *Optimization technique combined with deep learning method for teeth recognition in dental panoramic radiographs*. *Sci Rep*, 2020. 10(1).
  90. Dye, B.A. et al., *Oral health disparities as determined by selected healthy people 2020 oral health objectives for the United States, 2009-2010*. *NCHS Data Brief*, 2012(104): p. 1-8.
  91. Dye, B.A., et al., *Trends in oral health status: United States, 1988-1994 and 1999-2004*. *Vital Health Stat 11*, 2007(248): p. 1-92.
  92. *Global, regional, and national incidence, prevalence, and years lived with disability for 328 diseases and injuries for 195 countries, 1990-2016: a systematic analysis for the Global Burden of Disease Study 2016*. *Lancet*, 2017. 390(10100): p. 1211-1259.
  93. Lee, S.-M., et al., *Association between maternal and child oral health and dental caries in Korea*. *J Pub Health*, 2019. 27(2): p. 219-227.
  94. Ismail, A.I. et al., *Prevention of early childhood caries*. *Community Dent Oral Epidemiol*, 1998. 26(S1): p. 49-61.
  95. Tinanoff, N. et al., *Early childhood caries: overview and recent findings*. *Pediat dent*, 1997. 19: p. 12-16.

96. Stookey, G.K., et al., *Dental caries diagnosis. Dent Clin North Am*, 1999. 43(4): p. 665-77, vi.
97. Moran, M., et al., *Classification of approximal caries in bitewing radiographs using convolutional neural networks. Sensors*, 2021. 21(15).
98. Wenzel, A. et al., *Perception of image quality in direct digital radiography after application of various image treatment filters for detectability of dental disease. Dentomaxillofac Radiol*, 1993. 22(3): p. 131-4.
99. Dove, S.B. et al., *A comparison of conventional intra-oral radiography and computer imaging techniques for the detection of proximal surface dental caries. Dentomaxillofac Radiol*, 1992. 21(3): p. 127-34.
100. Schwendicke, F., et al., *Convolutional neural networks for dental image diagnostics: A scoping review. J Dent*, 2019. 91: p. 103226.
101. Landry, R.G. et al., *Periodontal Screening and Recording (PSR) Index: precursors, utility and limitations in a clinical setting. Int Dent J*, 2002. 52(1): p. 35-40.
102. Papapanou, P.N., et al., *Periodontitis: Consensus report of workgroup 2 of the 2017 World Workshop on the Classification of Periodontal and Peri-Implant Diseases and Conditions. J Clin Periodontol*, 2018. 45 Suppl 20: p. S162-s170.
103. Persson, R.E., et al., *Comparison between panoramic and intra-oral radiographs for the assessment of alveolar bone levels in a periodontal maintenance population. J Clin Periodontol*, 2003. 30(9): p. 833-9.
104. Walsh, T.F. et al., *The relationship of bone loss observed on panoramic radiographs with clinical periodontal screening. J Clin Periodontol*, 1997. 24(3): p. 153-7.
105. Choi, I.G.G., et al., *Comparison of conventional imaging techniques and CBCT for periodontal evaluation: A systematic review. Imaging Sci Dent*, 2018. 48(2): p. 79-86.
106. Akesson, L. et al., *Comparison of panoramic and intraoral radiography and pocket probing for the measurement of the marginal bone level. J Clin Periodontol*, 1992. 19(5): p. 326-32.
107. Lin, P.L. et al., *Automatic methods for alveolar bone loss degree measurement in periodontitis periapical radiographs. Comput Methods Programs Biomed*, 2017. 148: p. 1-11.
108. Cachovan, G., et al., *Odontogenic infections: An 8-year epidemiologic analysis in a dental emergency outpatient care unit. Acta Odontol Scand*, 2013. 71(3-4): p. 518-524.
109. Koivisto, T. et al., *Frequency and distribution of radiolucent jaw lesions: a retrospective analysis of 9,723 cases. J Endod*, 2012. 38(6): p. 729-32.
110. Kirkevang, L.-L., et al., *Periapical status and quality of root fillings and coronal restorations in a Danish population. Int Endod J*, 2000. 33(6): p. 509-515.
111. Segura-Egea, J.J. et al., *Endodontic medicine: connections between apical periodontitis and systemic diseases. Int Endod J*, 2015. 48(10): p. 933-51.
112. Huuonen, S. et al., *Prevalence of apical periodontitis in root filled teeth: findings from a nationwide survey in Finland. Int Endod J*, 2017. 50(3): p. 229-236.
113. Braz-Silva, P.H., et al., *Inflammatory profile of chronic apical periodontitis: a literature review. Acta Odontol Scand*, 2019. 77(3): p. 173-180.

114. Natkin, E. et al., *The relationship of lesion size to diagnosis, incidence, and treatment of periapical cysts and granulomas*. *Oral Surg Oral Med Oral Pathol*, 1984. 57(1): p. 82-94.
115. ShROUT, M.K. et al., *Differentiation of periapical granulomas and radicular cysts by digital radiometric analysis*. *Oral Surg Oral Med Oral Pathol*, 1993. 76(3): p. 356-61.
116. Simon, J.H., et al., *Differential diagnosis of large periapical lesions using cone-beam computed tomography measurements and biopsy*. *J Endod*, 2006. 32(9): p. 833-7.
117. Trope, M., et al., *Differentiation of radicular cyst and granulomas using computerized tomography*. *Endod Dent Traumatol*, 1989. 5(2): p. 69-72.
118. Estrela, C., et al., *A new periapical index based on cone beam computed tomography*. *J Endod*, 2008. 34(11): p. 1325-1331.
119. Kaler, J. et al., *The inter-and intra-observer reliability of a locomotion scoring scale for sheep*. *Vet J*, 2009. 180(2): p. 189-194.
120. Leonardi Dutra, K., et al., *Diagnostic Accuracy of Cone-beam Computed Tomography and Conventional Radiography on Apical Periodontitis: A Systematic Review and Meta-analysis*. *J Endod*, 2016. 42(3): p. 356-364.
121. Chapman, M.N., et al., *Periapical lucency around the tooth: radiologic evaluation and differential diagnosis*. *Radiographics*, 2013. 33(1): p. E15-32.
122. González-Alva, P., et al., *Keratocystic odontogenic tumor: a retrospective study of 183 cases*. *J oral sci*, 2008. 50(2): p. 205-212.
123. Meara, J.G., et al., *The odontogenic keratocyst: a 20-year clinicopathologic review*. *Laryngoscope*, 1998. 108(2): p. 280-283.
124. Chaisuparat, R., et al., *Primary intraosseous odontogenic carcinoma arising in an odontogenic cyst or de novo: a clinicopathologic study of six new cases*. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod*, 2006. 101(2): p. 194-200.
125. Park, J.H., et al., *Volume change pattern of decompression of mandibular odontogenic keratocyst*. *Maxillofac Plast Reconstr Surg*, 2019. 41(1): p. 1-6.
126. Kim, J. et al., *Conservative management (marsupialization) of unicystic ameloblastoma: literature review and a case report*. *Maxillofac Plast Reconstr Surg*, 2017. 39(1): p. 1-6.
127. Choi, J.W. et al., *Assessment of panoramic radiography as a national oral examination tool: review of the literature*. *Imaging Sci Dent*, 2011. 41(1): p. 1-6.
128. Rohlin, M., et al., *Observer performance in the assessment of periapical pathology: a comparison of panoramic with periapical radiography*. *Dentomaxillofac Radiol*, 1991. 20(3): p. 127-131.
129. Bell, G.W., et al., *The accuracy of dental panoramic tomographs in determining the root morphology of mandibular third molar teeth before surgery*. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod*, 2003. 95(1): p. 119-125.
130. Mallya, S. et al., *White and Pharoah's Oral radiology E-book: principles and interpretation: Second South Asia Edition E-Book*. 2019: Elsevier India.
131. Bassetti, M.A., et al., *[The dentigerous cyst: two different treatment options illustrated by two cases]*. *Swiss Dent J*, 2019. 129(3): p. 193-203.

132. Rother, U.J. et al., *Moderne bildgebende Diagnostik in der Zahn-, Mund- und Kieferheilkunde*. 2006, Urban & Fischer Verlag/Elsevier GmbH: Munich. p. 220-229.
133. Kitisubkanchana, J., et al., *Odontogenic keratocyst and ameloblastoma: radiographic evaluation*. *Oral Radiol*, 2021. 37(1): p. 55-65.
134. Soluk-Tekkesin, M. et al., *The World Health Organization Classification of Odontogenic Lesions: A Summary of the Changes of the 2022 (5th) Edition*. *Turk Patoloji Derg*, 2022. 38(2): p. 168-184.
135. Ohashi, Y., et al., *Utilization of computer-aided detection system in diagnosing unilateral maxillary sinusitis on panoramic radiographs*. *Dentomaxillofac Radiol*, 2016. 45(3): p. 20150419.
136. Wright, J.M. et al., *Update from the 4th Edition of the World Health Organization Classification of Head and Neck Tumours: Odontogenic and Maxillofacial Bone Tumors*. *Head Neck Pathol*, 2017. 11(1): p. 68-77.
137. Liu, Z., et al., *Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs*. *International Int J Comput Assist Radiol Surg*, 2021. 16(3): p. 415-422.
138. Morita, L., et al., *Imaging features of Stafne bone defects on computed tomography: An assessment of 40 cases*. *Imaging Sci Dent*, 2021. 51(1): p. 81.
139. Ramanauskaite, A., et al., *Dental implant outcomes in grafted sockets: a systematic review and meta-analysis*. *J Oral Maxillofac Res*, 2019. 10(3).
140. Srinivasan, M., et al., *Survival rates of short (6 mm) micro-rough surface implants: a review of literature and meta-analysis*. *Clin Oral Implants Res*, 2014. 25(5): p. 539-545.
141. Albrektsson, T. et al., *Implant survival and complications. The Third EAO consensus conference 2012*. *Clin Oral Implants Res*, 2012. 23: p. 63-65.
142. Jokstad, A., et al., *Quality of dental implants*. *Int dent j*, 2003. 53(S6P2): p. 409-443.
143. Michelinakis, G. et al., *Identification of dental implants through the use of Implant Recognition Software (IRS)*. *Int dent j*, 2006. 56(4): p. 203-208.
144. Al-Johany, S.S., et al., *Dental implant length and diameter: a proposed classification scheme*. *J Prosthodont*, 2017. 26(3): p. 252-260.
145. Jokstad, A. et al., *Systematic review of clinical and patient-reported outcomes following oral rehabilitation on dental implants with a tapered compared to a non-tapered implant design*. *Clin Oral Implants Res*, 2018. 29: p. 41-54.
146. Esposito, M. et al., *Interventions for replacing missing teeth: different types of dental implants*. *Cochrane database of syst rev*, 2014(7).
147. Palmer, R.M. et al., *Implants in clinical dentistry*. 2011: CRC Press.
148. Demenko, V., et al., *Ultimate masticatory force as a criterion in implant selection*. *J Dent Res*, 2011. 90(10): p. 1211-1215.
149. Lazzara, R. et al., *Criteria for implant selection: surgical and prosthetic considerations*. *Pract Periodontics Aesthet Dent*, 1994. 6(9): p. 55-62; quiz 64.
150. Group, M.R. et al., *European markets for dental implants and final abutments 2004: executive summary*. *Impl Dent*, 2004. 13(3): p. 193-196.
151. Binon, P.P. et al., *Implants and components: entering the new millennium*. *Int J Oral Maxillofac Implants*, 2000. 15(1): p. 76-94.

152. Jaarda, M.J. et al., Geometric comparison of five interchangeable implant prosthetic retaining screws. *J prosth dent*, 1995. 74(4): p. 373-379.
153. Al-Wahadni, A., et al., Dentists' most common practices when selecting an implant system. *J Prosthodont*, 2018. 27(3): p. 250-259.
154. Esposito, M., et al., Differential diagnosis and treatment strategies for biologic complications and failing oral implants: a review of the literature. *Int J Oral Maxillofac Implants*, 1999. 14(4).
155. Greenstein, G. et al., Failed dental implants: diagnosis, removal and survival of reimplantations. *J Am Dent Assoc*, 2014. 145(8): p. 835-841.
156. Chan, M., et al., Accuracy of extraoral bite-wing radiography in detecting proximal caries and crestal bone loss. *J Am Dent Assoc*, 2018. 149(1): p. 51-58.
157. Vandenberghe, B. et al., Modern dental imaging: a review of the current technology and clinical applications in dental practice. *Eur Radiol*, 2010. 20(11): p. 2637-2655.
158. Rafferty, E.A., et al., Assessing radiologist performance using combined digital mammography and breast tomosynthesis compared with digital mammography alone: results of a multicenter, multireader trial. *Radiology*, 2013. 266(1): p. 104-113.
159. Sabarudin, A. et al., Image quality assessment in panoramic dental radiography: a comparative study between conventional and digital systems. *Quant Imaging Med Surg*, 2013. 3(1): p. 43-8.
160. Kantor, M.L. et al., A clinical comparison of X-ray films for detection of proximal surface caries. *J Am Dent Assoc*, 1985. 111(6): p. 967-969.
161. Fitzgerald, R. et al., Error in Radiology. *Clin Radiol*, 2001. 56(12): p. 938-946.
162. Brady, A., et al., Discrepancy and error in radiology: concepts, causes and consequences. *Ulster med j*, 2012. 81(1): p. 3-9.
163. Valizadeh, S., et al., Designing of a Computer Software for Detection of Approximal Caries in Posterior Teeth. *Iran J Radiol*, 2015. 12(4): p. e16242.
164. White, S.C. et al., Comparison of xeroradiographs and film for detection of proximal surface caries. *J Am Dent Assoc*, 1984. 108(5): p. 755-759.
165. Molander, B. et al., Panoramic radiography in dental diagnostics. *Swed Dent J Suppl*, 1996. 119: p. 1-26.
166. Osman, F., et al., Use of panoramic radiographs in general dental practice in England. *Community Dent Oral Epidemiol*, 1986. 14(1): p. 8-9.
167. Brusis, T. et al., Panoramaaufnahme (Orthopantomogramm), in *HNO Röntgen-Aufnahmetechnik und Normalbefunde*. 1984, Springer. p. 54-55.
168. Pandolfo, I. et al., *Orthopantomography*. 2013: Springer.
169. Dreiseidler, T., et al., Comparison of cone-beam imaging with orthopantomography and computerized tomography for assessment in presurgical implant dentistry. *Int J Oral Maxillofac Implants*, 2009. 24(2): p. 216-25.
170. Horner, K. et al., Preoperative radiological evaluation of missing single teeth: A review. *Eur J Oral Implantol*, 2016. 9 Suppl 1: p. S69-88.
171. Wahab, M.H.A. et al., Interpretation of intraoral periapical radiographs. *Journal of Dentistry*, 1984. 12(4): p. 302-313.
172. Harris, D., et al., E.A.O. guidelines for the use of diagnostic imaging in implant dentistry 2011. A consensus workshop organized by the European

- Association for Osseointegration at the Medical University of Warsaw. *Clin Oral Implants Res*, 2012. 23(11): p. 1243-53.
173. Pasler, F.A. et al., *Pocket atlas of dental radiology*. 2007.
  174. Oenning, A.C., et al., Cone-beam CT in paediatric dentistry: DIMITRA project position statement. *Pediatr Radiol*, 2018. 48(3): p. 308-316.
  175. Kirnbauer, B. et al., 3-D-Diagnostik (DVT/CT) in der Zahnheilkunde. *Stomatologie*, 2014. 111(3): p. 80-85.
  176. Miracle, A.C. et al., Conebeam CT of the head and neck, part 2: clinical applications. *AJNR Am J Neuroradiol*, 2009. 30(7): p. 1285-92.
  177. Cassetta, M., et al., How accurate is CBCT in measuring bone density? A comparative CBCT-CT in vitro study. *Clin Implant Dent Relat Res*, 2014. 16(4): p. 471-8.
  178. Van Stralen, K.J., et al., Diagnostic methods I: sensitivity, specificity, and other measures of accuracy. *Kidney int*, 2009. 75(12): p. 1257-1263.
  179. Parikh, R., et al., Understanding and using sensitivity, specificity and predictive values. *Indian J Ophthalmol*, 2008. 56(1): p. 45.
  180. Chu, K. et al., An introduction to sensitivity, specificity, predictive values and likelihood ratios. *Emergency Medicine*, 1999. 11(3): p. 175-181.
  181. Streiner, D.L. et al., "Precision" and "accuracy": two terms that are neither. *J clin epidemiol*, 2006. 59(4): p. 327-330.
  182. Cork, R.C. et al., Precision and accuracy of intraoperative temperature monitoring. *Anesth Analg*, 1983. 62(2): p. 211-214.
  183. Bolas, A. et al., *DENTAL PRACTICE RADIATION FILE Guidelines for Radiation Protection in a Dental Practice*. HSE, 2017.
  184. Ren, R., et al., Machine learning in dental, oral and craniofacial imaging: a review of recent progress. *PeerJ*, 2021. 9: p. e11451.
  185. Arksey, H. et al., Scoping studies: towards a methodological framework. *International J Soc Rese Methodol*, 2005. 8(1): p. 19-32.
  186. Moher, D., et al., Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. *Systematic Reviews*, 2015. 4(1): p. 1.
  187. Krois, J., et al., Deep Learning for the Radiographic Detection of Periodontal Bone Loss. *Sci Rep*, 2019. 9(1).
  188. Vila-Blanco, N., et al., Automated description of the mandible shape by deep learning. *International Int J Comput Assist Radiol Surg*, 2021. 16(12): p. 2215-2224.
  189. Vinayahalingam, S., et al., Classification of caries in third molars on panoramic radiographs using deep learning. *Sci Rep*, 2021. 11(1).
  190. Thanathornwong, B. et al., Automatic detection of periodontal compromised teeth in digital panoramic radiographs using faster regional convolutional neural networks. *Imaging Sci Dent*, 2020. 50(2): p. 169-174.
  191. Endres, M.G., et al., Development of a deep learning algorithm for periapical disease detection in dental radiographs. *Diagnostics*, 2020. 10(6).
  192. Lee, J.H., et al., A performance comparison between automated deep learning and dental professionals in classification of dental implant systems from dental imaging: A multi-center study. *Diagnostics*, 2020. 10(11).
  193. Khanna, S. et al., Artificial intelligence: contemporary applications and future compass. *Int Dent J*, 2010. 60(4): p. 269-72.

194. Shortliffe, E.H. et al., *Testing reality: the introduction of decision-support technologies for physicians. Methods Inf Med*, 1989. 28(1): p. 1-5.
195. Kunkel, M., et al., *Operative Entfernung von Weisheitszähnen. Der MKG-Chirurg*, 2013. 6(4): p. 282-289.
196. Cernazanu-Glavan, C. et al., *Segmentation of bone structure in X-ray images using convolutional neural network. Adv. Electr. Comput. Eng*, 2013. 13(1): p. 87-94.