

Państwowy Instytut Medyczny
Ministerstwa Spraw Wewnętrznych i Administracji

Natalia Turosz

**Ocena aktualnych możliwości zastosowania sztucznej
inteligencji w analizie zdjęć pantomograficznych**

Praca doktorska

Promotor: Dr hab. n. med. Maciej Sikora, Prof. PIM MSWiA, Prof. afiliowany PUM

Warszawa, 2025

Pragnę wyrazić serdeczne podziękowania

Panu dr. hab. n. med. Maciejowi Sikorze

Za opiekę naukową, poświęcony czas oraz motywację do dalszego rozwoju

Panu dr. Maciejowi Chęcińskiemu

Za wsparcie naukowe i gotowość pomocy

Spis treści

1. Wykaz publikacji będących podstawą pracy doktorskiej	4
2. Streszczenie w języku polskim	5
3. Streszczenie w języku angielskim	8
4. Spis używanych skrótów.....	10
5. Wstęp	11
5.1. Wprowadzenie do sztucznej inteligencji.....	11
5.2. Zastosowanie sztucznej inteligencji w stomatologii	14
5.3. Zdjęcia pantomograficzne w codziennej praktyce stomatologicznej.....	16
6. Cel pracy	18
7. Materiały i metody.....	19
7.1. Czas i miejsce badania	19
7.2. Techniki badawcze.....	19
8. Wyniki.....	22
8.1. Ocena aktualnych możliwości AI w analizie zdjęć pantomograficznych.....	22
8.2. Ocena stanu zdrowia jamy ustnej i potrzeb leczniczych przykładowej populacji w oparciu o wyniki automatycznej analizy zdjęć pantomograficznych przez oprogramowanie wykorzystujące AI.....	24
8.3. Ocena skuteczności algorytmu AI w analizie zdjęć pantomograficznych pacjentów z uzębieniem stałym.....	27
8.4. Ocena skuteczności algorytmu AI w analizie zdjęć pantomograficznych pacjentów z uzębieniem mieszanym	28
9. Wnioski	30
10. Podsumowanie	31
11. Piśmiennictwo.....	33
12. Załączniki.....	38

1. Wykaz publikacji będących podstawą pracy doktorskiej

Podstawą rozprawy doktorskiej jest cykl czterech spójnych tematycznie publikacji naukowych:

Nr artykułu	Opis bibliograficzny	Punktacja ministerialna	Impact Factor
1	Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of Artificial Intelligence in the Analysis of Dental Panoramic Radiographs: An Overview of Systematic Reviews. Dentomaxillofacial Radiology 2023, 20230284, doi:10.1259/dmfr.20230284	100	2.9
2	Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. Journal of Clinical Medicine 2024, 13, 3686, doi:10.3390/jcm13133686	140	3.0
3	Turosz, N.; Chęcińska, K.; Chęciński, M.; Sielski, M.; Sikora, M. Evaluation of Dental Panoramic Radiographs by Artificial Intelligence Compared to Human Reference: A Diagnostic Accuracy Study. Journal of Clinical Medicine 2024, 13, 6859, doi:10.3390/jcm13226859	140	3.0
4	Turosz, N.; Chęcińska, K.; Chęciński, M.; Lubecka, K.; Bliźniak, F.; Sikora, M. Artificial Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical Study. Pediatric Reports 2024, 16, 794–805, doi:10.3390/pediatric16030067	70	1.4

2. Streszczenie w języku polskim

Wstęp: Sztuczna inteligencja (AI) stała się jedną z najbardziej obiecujących technologii wspierających współczesną medycynę, w tym również stomatologię. Definiowana jest jako zdolność maszyn do wykonywania zadań zwykle wymagających ludzkiej inteligencji. Coraz częściej ułatwia lekarzom diagnozowanie, leczenie oraz opiekę nad pacjentem. Znaczny postęp w rozwoju sprzętu komputerowego obejmujący m.in. wzrost mocy obliczeniowej procesorów, zwiększająca się ilość danych, a także nowoczesne rozwiązania w zakresie projektowania algorytmów uczenia maszynowego, pozwoliły na istotną poprawę jakości analiz dokonywanych przez oprogramowanie komputerowe. W stomatologii AI jest coraz częściej stosowana podczas analizy obrazów radiologicznych, umożliwiając wykrycie różnego rodzaju patologii takich jak próchnica, torbiele czy złamania kości. Jednym z najczęściej stosowanych badań obrazowych wykorzystywanych w codziennej diagnostyce stomatologicznej jest zdjęcie pantomograficzne, pozwalające na jednoczesną ocenę stanu uzębienia, żuchwy, kości szczęk wraz z dużą częścią zatok szczękowych, podniebienia twardego i stawów skroniowo-żuchwowych. W ostatnich latach wprowadzana jest do użytku komercyjnego coraz większa ilość oprogramowań wykorzystujących AI do analizy radiogramów. Zasadna wydaje się zatem weryfikacja tego typu programów dostępnych w Polsce oraz ocena ich przydatności w procesie leczenia pacjentów.

Cel pracy: Celem rozprawy doktorskiej jest ocena możliwości zastosowania AI w analizie zdjęć pantomograficznych, ze szczególnym uwzględnieniem jej skuteczności w identyfikacji braków zębowych, próchnicy, wypełnień w obrębie koron i kanałów korzeniowych, zmian okołowierzchołkowych, implantów, koron osadzonych na zębach własnych i implantach oraz przeseł mostów.

Materiał i metody: W pracy nr 1 przeprowadzono syntezę przeglądów systematycznych dotyczących możliwości wykorzystania AI w analizie zdjęć pantomograficznych, zgodnie z metodologią PICOS oraz wytycznymi PRIOR Statement. Materiałów źródłowych poszukiwano w czterech bazach danych (PubMed, BASE, ACM, Google Scholar). Następnie, w manuskrypcie nr 2 wykorzystano oprogramowanie AI do automatycznej analizy 1025 zdjęć OPG. Do każdej pozycji zęba algorytm przypisał obecność lub brak następujących diagnoz: (1) brakujący ząb, (2) próchnica, (3) wypełnienie w obrębie korony, (4) wypełnienie kanałowe, (5) zmiana okołowierzchołkowa, (6) implant, (7) korona na implancie, (8) korona protetyczna

na zębie własnym, (9) przeszło mostu, (10) zdrowy ząb. Uzyskane wyniki pozwoliły na przeprowadzenie badania przekrojowego dotyczącego stanu zdrowia jamy ustnej i określenia potrzeb leczniczych badanej populacji, zgodnie z wytycznymi STROBE. Obliczono chorobowości punktowe oraz współczynniki korelacji Pearsona. Badania dokładności diagnostycznej zaprezentowane w artykułach nr 3 i 4, przeprowadzono wykorzystując checklistę CLAIM oraz standard STARD. Ponad 600 zanonimizowanych radiogramów poddano indywidualnej ocenie przez dwóch lekarzy dentystów. Aby zwalidować model dokonano klasyfikacji wyników, wykorzystując macierz błędów. Następnie obliczono wskaźniki takie jak czułość, swoistość, precyzja, dokładność oraz wykonano krzywe ROC.

Wyniki: Synteza przeglądów systematycznych wykazała, że algorytmy AI osiągają bardzo wysoką, ponad 90% dokładność w identyfikacji zębów, próchnicy oraz utraty kości w przebiegu zapalenia przyzębia. Modele uczenia maszynowego (ML) wykazały się również wysoką czułością (99,95%) i swoistością (92%) w detekcji zmian okołowierzchołkowych. Z powodzeniem mogą być wykorzystywane także do wykrywania osteoporozy, zapalenia zatok szczękowych czy rozpoznawania implantów. W przeprowadzonym badaniu epidemiologicznym, najczęściej wykrywaną patologią była próchnica, która dotknęła 99% pacjentów. Ponad dwie trzecie uczestników badania posiadało przynajmniej jedno wypełnienie kanałowe, a przy co piątym przeleczonym endodontycznie zębie obecna była zmiana okołowierzchołkowa. Pacjenci posiadali średnio 15 zdrowych zębów bez oznak wcześniejszego leczenia, które przeważnie występowały w łuku dolnym. W celu uzupełnienia braków zębowych częściej stosowano mosty niż implanty. Wszystkie badane wskaźniki oceny testowanego oprogramowania AI osiągnęły wartość powyżej 90% w przypadku wykrywania brakujących zębów, wypełnień kanałowych oraz koron na implantach. Średnia wartość czułości (74,7%) i precyzji (72%) została osiągnięta w identyfikacji zmian okołowierzchołkowych. Najniższa wartość precyzji (65%) wystąpiła przy oznaczaniu koron protetycznych osadzonych na zębach własnych. W badaniu przeprowadzonym w grupie pacjentów w wieku rozwojowym, algorytm osiągnął wysoką swoistość i dokładność wynoszącą ponad 85,9%, ale niską precyzję w rozpoznawaniu próchnicy, wypełnień w obrębie korony oraz brakujących zębów. Na pogorszenie wyników mogła wpłynąć obecność zębów mlecznych, błędnie identyfikowanych jako zęby stałe.

Wnioski: AI wykazuje wysoki potencjał we wspieraniu lekarzy dentystów podczas analizy zdjęć pantomograficznych. Jej wdrożenie w gabinecie może przyspieszyć diagnostykę oraz zmniejszyć ryzyko popełnienia błędu. Dodatkowo może być przydatnym narzędziem w badaniach epidemiologicznych. Przeprowadzone z jej użyciem badanie przekrojowe grupy około tysiąca pacjentów wykazało niezadowalający stan jamy ustnej populacji wymagający podjęcia odpowiednich środków leczniczych i profilaktycznych. Niemniej, automatyczna identyfikacja zmian okołowierzchołkowych i koron protetycznych osadzonych na zębach własnych, a także analiza uzębienia stałego przeprowadzana przy obecności zębów mlecznych wciąż istotnie odbiega od wyników osiągniętych przez wytrenowanych profesjonalistów i wymaga dopracowania. W związku z tym, technologii tej nie należy postrzegać jako potencjalnego zagrożenia dla pracy lekarza, lecz jako narzędzie wspomagające codzienną pracę kliniczną, oferujące dodatkową opinię. Podczas wyboru oprogramowania AI należy zwrócić uwagę, aby jego skuteczność była potwierdzona wiarygodnymi badaniami i certyfikatami.

3. Streszczenie w języku angielskim

Introduction: Artificial intelligence (AI) has become one of the most promising technologies in modern medicine, including dentistry. It is defined as the ability of machines to perform tasks that typically require human intelligence. AI is increasingly enhancing the fields of diagnostics, treatment, and patient care. The availability of large datasets, advancements in hardware such as high-performance processors, and more advanced algorithms have significantly improved automated analysis. In the field of dentistry, AI is being increasingly used in analyzing radiographs, allowing for the detection of various pathologies, such as dental caries, cysts, or bone fractures. One of the most common diagnostic imaging techniques in dentistry is panoramic radiography. It allows for a simultaneous evaluation of all the teeth, the mandible, the maxilla including maxillary sinuses, hard palate, and temporomandibular joints. In recent years, an increasing number of AI-driven software for analyzing dental radiographs have been introduced for commercial use. Therefore, it is important to evaluate the reliability of such tools available in Poland.

Objectives: The objective of this study was to evaluate the potential of AI in analyzing dental panoramic radiographs, with a particular emphasis on its effectiveness in identifying missing teeth, dental caries, dental fillings, root canal fillings, endodontic lesions, implants, dental and implant abutment crowns, as well as pontic crowns.

Materials and methods: In the first manuscript, an overview of systematic reviews was conducted following the PICOS methodology and the PRIOR Statement guidelines. Relevant literature was retrieved from four databases: PubMed, BASE, ACM, and Google Scholar. In the second manuscript, AI-driven software was employed to perform an automated analysis of 1025 panoramic radiographs. The algorithm assessed each tooth position and determined the presence or absence of the following diagnoses: (1) missing tooth, (2) dental caries, (3) dental filling, (4) root canal filling, (5) endodontic lesion, (6) implant, (7) implant abutment crown, (8) pontic crown, (9) dental abutment crown, (10) sound tooth. This cross-sectional study was conducted in accordance with the STROBE guidelines. Point prevalences and Pearson correlation coefficients were calculated. The diagnostic accuracy studies presented in articles 3 and 4 followed the CLAIM checklist and the STARD standard. Over 600 anonymized radiographs were individually evaluated by two dentists. To assess the AI model, performance

metrics such as sensitivity, specificity, precision, and accuracy were calculated. Receiver Operating Characteristic (ROC) curves were also generated.

Results: The overview of systematic reviews showed that AI algorithms achieve over 90% accuracy in identifying teeth, dental caries, and periodontal bone loss. Machine learning models also exhibit high sensitivity (99,95%) and specificity (92%) in detecting periapical lesions. Additionally, AI algorithms can effectively identify conditions such as osteoporosis and maxillary sinusitis, as well as recognize implant types. In the cross-sectional study, dental caries was the most commonly detected pathology, affecting 99% of patients. More than two-thirds of the study participants had at least one root canal filling, and one in five endodontically treated teeth exhibited a periapical lesion. On average, patients had 15 sound teeth with no signs of previous treatment, primarily located in the lower arch. Prosthetic bridges were used more frequently than implants to replace missing teeth. In diagnostic accuracy studies, all performance metrics were above 90% in detecting missing teeth, root canal fillings, and implant abutment crowns. Identifying periapical lesions was characterized by an average sensitivity of 74.7% and precision of 72%. Notably, the lowest precision (65%) was observed in identifying dental abutment crowns.

Conclusions: AI has significant potential to assist dentists in analyzing panoramic radiographs. Implementing this technology in dental offices can enhance the diagnostic process and minimize errors. Furthermore, AI can serve as a valuable tool in epidemiological studies. The cross-sectional study revealed an unsatisfactory oral health condition in a population of approximately one thousand patients, indicating the need for appropriate therapeutic and preventive measures. Nevertheless, the automatic identification of periapical lesions and dental abutment crowns, as well as the effectiveness of evaluating permanent dentition in the presence of primary teeth, still differs significantly from the results obtained by trained professionals. In these fields, this technology requires further refinement. Consequently, AI should not be perceived as a threat to clinicians, but rather as a valuable tool that supports dentists by providing a second opinion. It is crucial to choose appropriately certified AI-driven software that has been validated through rigorous studies.

4. Spis używanych skrótów

AI (ang. *Artificial Intelligence*) – sztuczna inteligencja

CAD (ang. *Computer-Aided Design* or *Computer-Aided Diagnosis/Detection*) – projektowanie wspomagane komputerowo lub diagnoza wspomagana komputerowo

CAM (ang. *Computer-Aided Manufacturing*) – wytwarzanie wspomagane komputerowo

CBCT (ang. *Cone Beam Computed Tomography*) – tomografia komputerowa wiązki stożkowej

CI (ang. *confidence interval*) – przedział ufności

CLAIM (ang. *Checklist for Artificial Intelligence in Medical Imaging*) – lista kontrolna dotycząca sztucznej inteligencji w obrazowaniu medycznym

CNN (ang. *Convolutional Neural Network*) – konwolucyjna sieć neuronowa

DL (ang. *Deep Learning*) – uczenie głębokie

FN (ang. *False Negative*) – fałszywie ujemny

FP (ang. *False Positive*) – fałszywie dodatni

FPR (ang. *False Positive Rate*) – wskaźnik fałszywie pozytywnych wyników

Krzywa ROC (ang. *Receiver Operating Characteristic*) – krzywa charakterystyki odbioru

ML (ang. *Machine learning*) – uczenie maszynowe

PICOS (ang. *Population, Intervention, Comparison, Outcomes, Study design*) – populacja, interwencja, porównanie, wynik, projekt badania

PRIOR statement (ang. *Reporting guideline for overviews of reviews of healthcare interventions*) – wytyczne dotyczące raportowania przeglądu przeglądów związanych z interwencjami zdrowotnymi

ROBIS (ang. *A Risk of Bias Assessment Tool for Systematic Reviews*) – narzędzie do oceny ryzyka błędu w przeglądach systematycznych

STARD (ang. *Standards for Reporting of Diagnostic Accuracy Studies*) – standardy raportowania badań dokładności diagnostycznej

STROBE (ang. *Strengthening the Reporting of Observational Studies in Epidemiology*) – wzmocnienie raportowania badań obserwacyjnych w epidemiologii

TN (ang. *True Negative*) – prawdziwie ujemny

TP (ang. *True Positive*) – prawdziwie dodatni

TPR (ang. *True Positive Rate*) – wskaźnik prawdziwie pozytywnych wyników

5. Wstęp


5.1. Wprowadzenie do sztucznej inteligencji

Termin sztuczna inteligencja (ang. *artificial intelligence*, AI) został po raz pierwszy użyty w 1956 roku przez Johna McCarthy na konferencji w Dartmouth College. Moment ten uznaje się za początek badań nad sztuczną inteligencją jako odrębną dziedziną nauki [1]. Mianem AI określa się zdolność maszyn do wykonywania zadań wymagających ludzkiej inteligencji. Uczenie maszynowe (ang. *machine learning*, ML), które stanowi podzbiór AI, umożliwia komputerom uczenie się na podstawie danych, identyfikowanie wzorców oraz dokonywanie przewidywań bez wyraźnego programowania. Uczenie głębokie (ang. *deep learning*, DL), jest podzbiorem ML, w którym wykorzystywane są sztuczne sieci neuronowe (ang. *neural networks*, NN), czyli struktury matematyczne, dzięki którym realizowane są obliczenia. Ich nazwa nawiązuje do ludzkiego mózgu, ponieważ naśladują sposób komunikowania się biologicznych neuronów [2]. Rycina 1 przedstawia zależności między wymienionymi pojęciami.




Rycina 1. Diagram Venna obrazujący relacje między AI, ML, NN i DL

Podstawowym elementem sieci neuronowej jest neuron. Pierwszy matematyczny model neuronu opisali w 1943 roku Warren McCulloch oraz Walter Pitts (Rycina 2) [3].



Rycina 2. Neuron McCullocha-Pittsa

Jest to jednostka obliczeniowa przetwarzająca informacje poprzez przyjmowanie danych wejściowych, ich analizę oraz generowanie odpowiedzi na podstawie tych danych. Neuron McCullocha-Pittsa posiada wiele wejść oraz jedno wyjście. Każdemu z wejść przyporządkowana jest pewna waga będąca liczbą rzeczywistą. W wyniku obliczenia sumy iloczynów wartości sygnałów wejściowych (x_i) oraz wag (w_i) zgodnie ze wzorem $s = w_0 + \sum_{i=1}^n x_i w_i$ i przekazaniu tej wartości tzw. funkcji aktywacji, otrzymujemy wartość na wyjściu neuronu [3]. Najprostszą siecią neuronową jest perceptron, który jest zbudowany z jednego lub wielu niezależnych neuronów McCullocha-Pittsa. Aby jednak rozwiązać bardziej skomplikowane problemy, potrzebna jest dużo większa liczba neuronów, które są połączone w warstwy. Sieci wielowarstwowe posiadają przynajmniej dwie warstwy neuronów: wejściową i wyjściową, pomiędzy którymi może znajdować się jedna lub więcej warstw ukrytych (Rycina 3) [4].



Rycina 3. Budowa sieci neuronowej

Tworzenie głębokich sieci neuronowych, czyli sieci złożonych z wielu warstw neuronów jest podstawą DL. Jednym z głównych typów sieci neuronowych używanych w DL są konwolucyjne sieci neuronowe (ang. *convolutional neural network*, CNN), które szczególnie dobrze radzą sobie z rozpoznawaniem obrazów. Posiadają one kilka typów warstw, w tym warstwę konwolucyjną (ang. *convolutional layer*), w której wykorzystywana jest operacja konwolucji do wyodrębnienia cech z obrazów takich jak tekstury, krawędzie czy wzory [5].

Algorytmy ML uczą się na podstawie danych, bez konieczności szczegółowego ich zaprogramowania do rozwiązywania każdego zadania. Poszczególne etapy procesu uczenia algorytmu zaprezentowano na Rycinie 4.



Rycina 4. Etapy uczenia algorytmu ML

Pierwszym etapem jest pozyskanie jak największej ilości danych do trenowania modelu, które będą obejmowały szeroki zakres przypadków. Następnie należy odpowiednio przygotować dane poprzez m.in. uzupełnianie brakujących wartości, usuwanie nieistotnych cech czy błędów. W kolejnym etapie model uczy się na podstawie danych treningowych, próbując tak dopasować model, aby jak najlepiej przewidywał wyniki dla nowych danych. Następnie odbywa się testowanie modelu na osobnym zbiorze testowym. Końcowym etapem jest optymalizacja modelu, jeśli nie prezentuje on satysfakcjonujących wyników [6].

5.2. Zastosowanie sztucznej inteligencji w stomatologii

AI zyskuje coraz większe znaczenie w medycynie w procesie diagnostyki i leczenia pacjentów. Z powodzeniem radzi sobie m.in. z analizą obrazów radiologicznych, gdzie wykrywa zmiany trudno dostrzegalne ludzkim okiem [7]. Współczesne algorytmy potrafią przewidywać ryzyko wystąpienia pewnych schorzeń oraz tworzyć spersonalizowane plany leczenia pacjentów analizując dane medyczne. Coraz istotniejszą rolę AI odgrywa w stomatologii.

Istnieją liczne modele ML umożliwiające wykrywanie próchnicy na zdjęciach radiologicznych [8,9]. Dokładność wykrywania tej choroby na zdjęciach pantomograficznych jest jednak niższa niż w przypadku zdjęć zębowych czy skrzydłowo-zgryzowych, zwłaszcza gdy zmiana lokalizuje się na powierzchni stycznej [10]. Niemniej, ostatnie badania pokazują, że CNN takie jak nnU-Net, wykorzystując proces segmentacji obrazu, potrafią osiągać dokładność wynoszącą nawet 98,6% w identyfikacji próchnicy na pantomogramach [11]. Bardzo szybki rozwój technologii AI potwierdzają niedawno przeprowadzone badania, w których modele oparte na sieciach neuronowych uzyskały lepsze wyniki w diagnozowaniu próchnicy na zdjęciach skrzydłowo-zgryzowych niż człowiek [12,13]. Wykrywalność próchnicy przez AI jest również bardzo wysoka na zdjęciach zębowych, gdzie czułość sięga 97,8% [8]. CNN osiągają również bardzo wysokie wartości wskaźników jakości klasyfikacji w identyfikacji zębów stałych i mlecznych, w tym również nadliczbowych, jak np. mesiodens [14,15]. W stomatologii dziecięcej algorytmy ML ułatwiają ocenę ryzyka wystąpienia próchnicy wczesnego dzieciństwa, umożliwiając szybkie podjęcie działań zapobiegawczych [16].

Endodoncja również odnosi wiele korzyści dzięki rozwiązaniom AI. Algorytmy wykrywają zmiany okołowierzchołkowe wykorzystując operacje segmentacji, klasyfikacji lub detekcji na zdjęciach radiologicznych. Ich skuteczność jest jednak zróżnicowana i według przeglądu systematycznego przeprowadzonego w 2024 roku, w przypadku pantomogramów ich czułość mieści się w przedziale 48-100%, swoistość 87-100%, natomiast precyzja 64-82% [17]. Algorytmy z powodzeniem potrafią również identyfikować pionowe złamania korzeni, zarówno na zdjęciach pantomograficznych jak i tomografii komputerowej wiązki stożkowej (CBCT) [6]. Dzięki CNN, prostsza staje się ocena morfologii kanałów korzeniowych, w tym identyfikacja kanałów typu C w drugich trzonowcach, gdzie precyzja modeli sięga 95,9% w przypadku pantomogramów [18]. AI znalazło również zastosowanie w określaniu długości roboczej kanału oraz wykrywaniu zębów taurodontycznych [6].

W dziedzinie periodontologii AI jest na wczesnym etapie i wciąż się rozwija. Technologia ta jest głównie wykorzystywana do wykrywania ubytków tkanki kostnej w przebiegu zapalenia przyzębia, gdzie dokładność modeli mieści się w przedziale 73,4-99% [19]. Wczesne zdiagnozowanie choroby przyzębia i podjęcie leczenia może przyczynić się do obniżenia markerów stanu zapalnego (w tym CRP i TNF- α), zmniejszania ryzyka udaru czy choroby Alzheimer'a [20–22]. Modele wykorzystujące głębokie sieci neuronowe, drzewa decyzyjne czy wektory nośne potrafią z powodzeniem wykrywać zmiany w gęstości kości w przebiegu osteoporozy na podstawie zdjęć pantomograficznych [7,23]. Bardzo dobre wyniki zarówno w wykrywaniu zaników kości, jak i określaniu zaawansowania zapalenia przyzębia uzyskano przy zastosowaniu połączenia architektury opartej na DL oraz diagnostyki wspomaganej komputerowo (CAD) [24]. Liu i in. wykorzystali inteligentne oprogramowanie Health-IoT bazujące na fotografiach wewnątrzustnych do identyfikowania zapalenia dziąseł uzyskując dokładność dochodzącą do 94% [25].

AI odgrywa także istotną rolę w chirurgii szczękowo-twarzowej podczas diagnostyki i planowania leczenia. Dostępne komercyjnie programy takie jak dentalXr (dentalXrai GmbH, Berlin, Niemcy) czy Dentomo (dezzai, Madryt, Hiszpania) umożliwiają automatyczne wykrywanie torbieli [26]. Dzięki głębokim CNN łatwiejsza stała się ocena relacji między zębami zatrzymanymi a otaczającymi strukturami anatomicznymi takimi jak zatoka szczękowa czy kanał żuchwy [27]. Na podstawie zdjęć pantomograficznych lub obrazów CBCT wykonują diagnostykę zatoki szczękowej, wykrywając stany zapalne, torbiele zastoinowe czy pogrubienie śluzówki [28,29]. Ponadto, wspomagają planowanie operacji ortognatycznych oraz oceniają ryzyko wystąpienia pooperacyjnej infekcji [30]. Sieci neuronowe okazały się również pomocne w wykrywaniu raka jamy ustnej na zdjęciach fotograficznych oraz obrazach z laserowych mikroskopów konfokalnych [31].

AI ma istotny wkład w rozwój protetyki stomatologicznej, w tym technologię CAD/CAM, projektowanie szablonów implantologicznych czy możliwość idealnego dopasowania odcienia odbudowy protetycznej. Modele ML ułatwiają projektowanie koron, mostów, obturatorów, protez całkowitych czy szkieletowych, osiągając bardzo wysoką dokładność. Jej zastosowanie znacznie skraca czas pracy laboratoryjnej wykonywanej przez techników dentystycznych oraz zapewnia bardziej przewidywalne wyniki leczenia [6]. AI można znacząco przyspieszyć diagnostykę, co potwierdza badanie przeprowadzone w 2022 roku, w którym model YOLOv4 z powodzeniem wykrywał korony i mosty, będąc jednocześnie zdolnym do przetworzenia 11 zdjęć pantomograficznych na sekundę [32]. Badanie pilotażowe Abdalla-Aslan i in. obejmujące 83 radiogramy wykazało 100% dokładność

algorytmu ML w identyfikowaniu koron protetycznych [33]. CNN z powodzeniem wykorzystywane są również w wykrywaniu i klasyfikacji implantów [34]. Potrafią diagnozować zapalenia okołowszczepowe z podobną skutecznością do lekarzy dentystów [35]. Połączenie technologii AI z rozszerzoną rzeczywistością (ang. *augmented reality*) okazało się pomocne podczas trójwymiarowego planowania leczenia implantologicznego [36].

AI jest także powszechnie wykorzystywana do przeprowadzania analizy cefalometrycznej w ortodoncji, automatycznie wyznaczając punkty orientacyjne i dokonując odpowiednich pomiarów. Szybkie generowanie pełnych analiz ułatwia przeprowadzanie badań na dużych grupach pacjentów [37]. Oprogramowanie może dokładnie symulować i przewidywać ruchy zębów podczas leczenia ortodontycznego, ułatwiając planowanie leczenia [38]. Jest to również przydatne rozwiązanie ułatwiające komunikację z pacjentem, ponieważ zapewnia przejrzystą demonstrację procesu leczenia oraz spodziewanych rezultatów. Obiecujące wyniki uzyskują również algorytmy wspomagające podejmowanie decyzji o konieczności ekstrakcji zębów podczas leczenia ortodontycznego [39,40].

5.3. Zdjęcia pantomograficzne w codziennej praktyce stomatologicznej

Radiografia jest metodą diagnostyczną umożliwiającą ocenę stanu uzębienia i otaczających struktur kostnych oraz identyfikowanie zmian trudno wykrywalnych w badaniu fizykalnym [41]. Jednym z najpopularniejszych badań radiologicznych w stomatologii jest zdjęcie pantomograficzne. Nazwa pochodzi od greckich słów: (1) *pan* oznaczające “wszystko”, jest związane z jednoczesnym przedstawieniem wszystkich zębów i struktur otaczających w jednej projekcji, (2) *tomos* czyli “przekrój” przez daną płaszczyznę w celu jej zobrazowania oraz (3) *gram* oznaczające “rysunek” będący obrazem wynikowym.

To warstwowe zdjęcie wykonywane jest często podczas pierwszej wizyty pacjenta w gabinecie, stanowiąc uzupełnienie wywiadu oraz badania fizykalnego. Pozwala ono na jednoczesną ocenę stanu uzębienia, żuchwy, kości szczęk wraz z dużą częścią zatok szczękowych, podniebienia twardego i stawów skroniowo-żuchwowych [39]. Umożliwia również zdiagnozowanie obecności wydłużonych wyrostków rylcowatych, zwapnień w tętnicach szyjnych, kamieni ślinowych czy migdałkowych [42].

Zdjęcie pantomograficzne posiada jednak pewne wady takie jak nakładanie się struktur, obecność artefaktów czy cieni rzekomych. Przykładowo u bezzębnych pacjentów z cienką warstwą tkanek miękkich, obraz gałęzi żuchwy może być wyraźnie widoczny w powiększonej formie nad trzonem żuchwy strony przeciwległej [12,43]. Dla uzyskania wysokiej jakości

obrazu niezbędne jest prawidłowe pozycjonowanie pacjenta np. zbyt doprzednie ustawienie głowy w aparacie może spowodować intensywny cień wtórny kręgosłupa szyjnego [44,45]. Wykonanie pantomogramu jest również trudniejsze u dzieci czy pacjentów z zaburzeniami równowagi, ze względu na możliwe wykonanie ruchu podczas trwania ekspozycji [46]. Zdjęcie pantomograficzne nie posiada wysokiej czułości w wykrywaniu próchnicy na powierzchniach stycznych (zwłaszcza w okolicy zębów przedtrzonowych) oraz nie dostarcza tak szczegółowych informacji jak CBCT [45]. Ze względu na powiększenie obrazu, nie ma również możliwości wykonania na nim dokładnych pomiarów liniowych [39]. Podobnie jak w przypadku innych zdjęć radiologicznych, interpretacja pantomogramów jest subiektywna, co oznacza, że wyniki analizy mogą różnić się w zależności od doświadczenia czy umiejętności lekarza.

Pomimo wymienionych niedoskonałości, zdjęcie pantomograficzne nadal w wielu przypadkach stanowi podstawę diagnostyki obrazowej w stomatologii. Uzyskanie szerokiego zakresu obrazowanych struktur jest możliwe przy jednoczesnej krótkiej ekspozycji (0,5-13 sekund) na niską dawkę promieniowania wynoszącą 4-30 μ Sv [40,47,48]. Dla porównania godzina lotu samolotem na wysokości 10 000 m n.p.m. dostarcza dawki 4 μ Sv [49]. Zdjęcie pantomograficzne jest bardzo pomocne we wstępnym planowaniu leczenia stomatologicznego, ocenie położenia zawiązków, zębów nadliczbowych, zatrzymanych, a także w wykrywaniu torbieli czy guzów [39]. Ponadto jego wykonanie jest stosunkowo niedrogie oraz nie wymaga obecności lekarza ze specjalizacją w dziedzinie radiologii i diagnostyki obrazowej. Zgodnie z obowiązującymi przepisami może je wykonać również lekarz dentysta lub technik elektroradiologii [50]. Ze względu na możliwość uzyskania dużej ilości informacji na temat stanu zdrowia jamy ustnej, zdjęcie pantomograficzne bywa także wykorzystywane w badaniach epidemiologicznych czy przesiewowych przeprowadzanych na dużych grupach pacjentów [51].

Rozwój AI sprawił, że możliwe stało się automatyczne analizowanie pantomogramów za pomocą sieci neuronowych. Algorytmy z wysoką skutecznością potrafią rozpoznawać poszczególne zęby, diagnozować próchnicę, zmiany okołowierzchołkowe, identyfikować wypełnienia, korony czy implanty stomatologiczne. Na rynku coraz częściej pojawiają się nowe oprogramowania oferujące automatyczne generowanie raportów na podstawie zdjęć pantomograficznych. Potrzebna wydaje się jednak obiektywna walidacja ogólnodostępnych modeli AI dokonujących analiz w celu oceny możliwości zastosowania tej technologii w codziennej diagnostyce.

6. Cel pracy

Celem pracy doktorskiej jest ocena możliwości zastosowania algorytmów sztucznej inteligencji w analizie zdjęć pantomograficznych, ze szczególnym uwzględnieniem jej skuteczności w identyfikacji braków zębowych, próchnicy, wypełnień w obrębie koron i kanałów korzeniowych, zmian okołowierzchołkowych, implantów, koron osadzonych na zębach własnych i implantach oraz przęseł mostów. Cele szczegółowe badań włączonych do cyklu publikacyjnego obejmują:

1. Ocenę aktualnych możliwości sztucznej inteligencji w analizie zdjęć pantomograficznych oraz analizę rozwoju algorytmów AI na przestrzeni czasu.
2. Zbadanie stanu zdrowia jamy ustnej oraz potrzeb leczniczych przykładowej populacji w oparciu o analizę zdjęć pantomograficznych wykonaną przez algorytm AI.
3. Walidację testowanego algorytmu AI obejmującą ocenę czułości, swoistości, dokładności i precyzji w analizie zdjęć pantomograficznych pacjentów z uzębieniem stałym.
4. Określenie efektywności testowanego algorytmu AI w analizie zdjęć pantomograficznych pacjentów z uzębieniem mieszanym.

W pracy przyjęto następującą hipotezę: Sztuczna inteligencja osiąga skuteczność diagnostyczną porównywalną do człowieka w analizie zdjęć pantomograficznych, prowadząc do przyspieszenia i zwiększenia efektywności diagnostyki, ułatwiając jednocześnie prowadzenie badań na dużych populacjach pacjentów.

7. Materiały i metody

7.1. Czas i miejsce badania

Badania odbywały się w latach 2023-2024. W czerwcu 2023 roku przeprowadzono badanie przeglądowe na podstawie piśmiennictwa anglojęzycznego. Po uzyskaniu zgody Komisji Bioetycznej w dniu 31 sierpnia 2023 roku, zgromadzono 1025 zdjęć pantomograficznych pacjentów, wykonanych w okresie od września 2022 roku do czerwca 2023 roku w jednym z zakładów diagnostyki obrazowej w Kielcach. Wszystkie zanonimizowane zdjęcia zostały automatycznie przeanalizowane przez oprogramowanie wykorzystujące AI. Następnie przez około pięć miesięcy dwóch lekarzy dentystów wykonało ponad 600 analiz pantomogramów, które stanowiły tzw. test referencyjny na etapie porównania wyników ewaluacji dokonanej przez człowieka z wynikami algorytmu AI.

7.2. Techniki badawcze

Przegląd przeglądów systematycznych został przeprowadzony zgodnie z metodologią PICOS oraz wytycznymi PRIOR Statement. Wyszukiwania przeprowadzono w czterech bazach danych (PubMed, Association for Computing Machinery, Bielefeld Academic Search Engine, Google Scholar). Do oceny ryzyka błędu systematycznego wykorzystano narzędzie ROBIS. Badanie przekrojowe zostało przeprowadzone zgodnie z wytycznymi STROBE. Artykuły oceniające skuteczność algorytmu AI zostały napisane w oparciu o standard STARD oraz wykorzystując checklistę CLAIM.

Zdjęcia pantomograficzne wysokiej rozdzielczości wykorzystane w badaniach zostały wykonane z użyciem tomografu stomatologicznego CS 9600 (Carestream Health, Rochester, New York, USA), przy warunkach ekspozycji 60–90 kV, 2–15 mA. Zanonimizowane zdjęcia zostały poddane automatycznej analizie przez moduł AI wbudowany w oprogramowanie CS Imaging v8. Algorytm został wytrenowany na ponad 250 000 zdjęć pantomograficznych wcześniej opisanych przez specjalistów radiologii. Wyniki analizy uzyskiwano w kilka sekund otrzymując informację na temat brakujących zębów, próchnicy, wypełnień w obrębie koron i kanałów korzeniowych, zmian okołowierzchołkowych oraz obecności uzupełnień protetycznych takich jak korony osadzone na zębach własnych i implantach, przęsła mostów czy implanty. Na podstawie uzyskanych danych z oceny 1025 pantomogramów obliczono chorobowość punktowe oraz współczynniki korelacji Pearsona mierzące zależności między kolejnymi zmiennymi. Następnie zdjęcia zostały poddane analizie przez lekarza dentystę z czteroletnim doświadczeniem. W przypadku wątpliwości dotyczących diagnostyki danego

zdjęcia, dodatkową analizę wykonywał lekarz specjalista chirurgii szczękowo-twarzowej z dwunastoletnim doświadczeniem. Oceniano obecność lub brak następujących diagnoz: (1) brakujący ząb, (2) wypełnienie kanałowe, (3) zmiana okołowierzchołkowa, (4) implant, (5) korona na implancie, (6) przęsło mostu, (7) korona protetyczna, (8) zdrowy ząb. Zanalizowano łącznie 600 zdjęć pantomograficznych (19 200 pozycji zębowych). Jest to wyjątkowo duża próba w porównaniu do dotychczas opublikowanych badań, gdzie liczba ta zwykle nie przekraczała 300. W literaturze światowej jest to jedna z najobszerniejszych ocen dokładności diagnostycznej algorytmu, który w Polsce jest stosowany w praktyce klinicznej. Dodatkowo poddano automatycznej i manualnej analizie 35 pantomogramów z uzębieniem mieszanym (1120 pozycji zębowych). W pracach zastosowano dwa systemy oznaczania zębów - notację FDI (fr. *Fédération Dentaire Internationale*, system ISO 3950:2016) oraz amerykańską UNS (ang. *Universal Numbering System*).

W celu oceny jakości algorytmu AI dokonano klasyfikacji wyników, wykorzystując macierz błędów (Tabela 1). Następnie obliczono wartości następujących wskaźników oceny modelu: czułość, swoistość, precyzja, dokładność oraz wyznaczono przedziały ufności (ang. *confidence interval*, CI). Czułość jest miarą zdolności algorytmu do poprawnego wykrywania choroby spośród wszystkich faktycznych jej przypadków (ang. *True Positive*, TP). Jest szczególnie istotna w przypadku wykrywania patologii o poważnych konsekwencjach, zmniejszając w ten sposób ryzyko ich niewykrycia (np. nowotwory). Z drugiej strony, swoistość mówi o prawidłowym identyfikowaniu przypadków negatywnych (ang. *True Negative*, TN), czyli osób zdrowych, które rzeczywiście nie mają choroby. Jest to ważny wskaźnik zwłaszcza w kontekście przeprowadzania interwencji leczniczych tam, gdzie nie jest to potrzebne. Precyzja jest miarą, która sprawdza jak skutecznie algorytm wykrywa dane zjawisko, unikając przypadków fałszywie pozytywnych (ang. *False Positive*, FP). Wysoka precyzja będzie oznaczała, że jeśli algorytm zdiagnozował daną chorobę, to najprawdopodobniej jest to prawda. Dokładność określa odsetek prawidłowych klasyfikacji, niezależnie od tego czy były pozytywne czy negatywne. Zastosowanie krzywych ROC pozwoliło na wizualizację jakości klasyfikacji. Ukazują one zależności pomiędzy wskaźnikami TPR (ang. *True Positive Rate*) oraz FPR (ang. *False Positive Rate*). Wszystkie wzory zastosowanych metryk znajdują się w Tabeli 2.

Tabela 1. Klasyfikacja wyników testu

		Stan faktyczny	
		Dodatni	Ujemny
Prognoza	Dodatni	Prawdziwie dodatni (TP)	Fałszywie dodatni (FP)
	Ujemny	Fałszywie ujemny (FN)	Prawdziwie ujemny (TN)

Tabela 2. Miary oceny klasyfikacji danych

Metryka	Wzór
Czułość (ang. <i>Sensitivity, Recall, True Positive Rate</i>)	$\frac{TP}{TP + FN}$
Swoistość (ang. <i>Specificity, True Negative Rate</i>)	$\frac{TN}{TN + FP}$
Precyzja (ang. <i>Precision, Positive Predictive Value</i>)	$\frac{TP}{TP + FP}$
Dokładność (ang. <i>Accuracy</i>)	$\frac{TP + TN}{TP + TN + FP + FN}$
Wskaźnik fałszywie pozytywnych wyników (ang. <i>False Positive Rate</i>)	$\frac{FP}{FP + TN}$

8. Wyniki

8.1. Ocena aktualnych możliwości AI w analizie zdjęć pantomograficznych

W ciągu ostatnich kilkadziesiąt lat nastąpił znaczący rozwój AI i możliwości jej wykorzystania w analizie zdjęć pantomograficznych. Na podstawie zanalizowanych prac można stwierdzić, że skuteczność algorytmów ML ma tendencję wzrostową. Najlepsze modele osiągają bardzo wysoką czułość, swoistość, precyzję i dokładność w identyfikacji i numerowaniu zębów wynoszącą powyżej 98,7%. Opublikowano badania, w których skuteczność wypełniania diagramów zębowych przez algorytm była porównywalna z poziomem ekspertów. CNN z powodzeniem mogą być wykorzystywane w periodontologii, identyfikując utratę kości w przebiegu zapalenia przyzębia z dokładnością 93,09%. Istotny rozwój zaobserwowano również w przypadku algorytmów AI wykrywających osteoporozę, gdzie w ciągu niecałej dekady dokładność wzrosła z 62% do 97,45%. Wskaźnik ten, w przypadku wykrywania próchnicy, mieścił się w przedziale 86-96%. Podobnie wysoką czułością (99,95%) i swoistością (92%) wykazały się najnowsze modele wykorzystujące CNN w detekcji zmian okołowierzchołkowych. W ciągu trzech lat zaobserwowano kilkunastoprocentowy wzrost dokładności i swoistości algorytmów wykrywających zapalenie zatok szczękowych, których wartości wyniosły odpowiednio 87,5% oraz 88,3%. Modele ML osiągnęły również obiecujące wyniki w wykrywaniu pionowego złamania korzenia, klasyfikacji torbieli i guzów oraz wykrywaniu i klasyfikacji implantów. Szczegółowe wartości danych uzyskanych w wyniku przeprowadzonej syntezy przeglądów systematycznych przedstawiono w Tabeli 3.

Tabela 3. Skuteczność modeli AI w wykrywaniu poszczególnych patologii i struktur

Parametry oceny Funkcjonalność AI	Czułość	Swoistość	Precyzja	Dokładność	Lata publikacji badań
Identyfikacja i numerowanie zębów	96-98,7%	97-99,94%	85-99,45%	89-99,89%	2017-2021
Wykrywanie utraty kości w przebiegu zapalenia przyzębia	76-84%	81-93,75%	b.d.	81-94,18%	2019-2020
Wykrywanie próchnicy	b.d.	86%	78,5-89,4%	86-96%	2017-2021

Parametry oceny Funkcjonalność AI	Czułość	Swoistość	Precyzja	Dokładność	Lata publikacji badań
Wykrywanie zmian okołowierzchołkowych	48-92%	87-99,95%	49-84%	b.d.	2019-2022
Wykrywanie zapalenia zatok szczękowych	77,6-86,7%	69,4-88,3%	b.d.	73,5-87,5%	2016-2019
Wykrywanie osteoporozy	76,8-99,1%	43,8-98,4%	b.d.	62-98,9%	2007-2020
Wykrywanie choroby zwyrodnieniowej stawu skroniowo- żuchwowego	39-94%	77-91%	78%	77-88%	2020-2021
Wykrywanie implantów	b.d.	b.d.	b.d.	93,8-98%	2015-2020
Klasyfikacja implantów	b.d.	b.d.	b.d.	70,9-98,2%	2020-2022
Przewidywanie powodzenia osteointegracji	b.d.	b.d.	b.d.	62,4-80,5%	2005-2020
Klasyfikacja torbieli i guzów	b.d.	b.d.	b.d.	81,8-88,9%	2013
Wykrywanie pionowego złamania korzenia	b.d.	b.d.	93%	b.d.	2019

b.d. – brak danych

8.2. Ocena stanu zdrowia jamy ustnej i potrzeb leczniczych przykładowej populacji w oparciu o wyniki automatycznej analizy zdjęć pantomograficznych przez oprogramowanie wykorzystujące AI

Automatyczna analiza 980 zdjęć pantomograficznych pacjentów z uzębieniem stałym w wieku 11-81 lat wykazała występowanie próchnicy u prawie wszystkich uczestników badania. Najczęściej diagnozowana była w zębie 16, a najrzadziej w zębach dolnych przednich. Tylko 18% pacjentów nie posiadało braków zębowych. Najczęstszymi brakującymi zębami były trzecie trzonowce. Zęby w łuku górnym były częściej diagnozowane jako zdrowe (bez oznak wcześniejszego leczenia) niż w łuku dolnym. Ponad dwie trzecie uczestników badania posiadało przynajmniej jedno wypełnienie kanałowe. Najczęściej były to pierwsze trzonowce po lewej stronie. Przy co piątym przeleczonym endodontycznie zębie obecna była zmiana okołowierzchołkowa. Patologia ta najczęściej lokalizowała się przy zębie 46. Ponad 20% zębów leczonych kanałowo posiadało koronę protetyczną. Ten rodzaj odbudowy pojawiał się najczęściej w odcinku przednim szczęki. Implanty posiadało jedynie 2% pacjentów. Braki zębowe były częściej odbudowywane za pomocą mostów. Obliczone wartości chorobowości punktowej dla poszczególnych diagnoz przedstawiono na wykresach w załączonej publikacji nr 2. W Tabeli 4 i 5 przedstawiono pozostałe szczegółowe wyniki badania. Czas wykonania analizy zdjęcia pantomograficznego przez oprogramowanie AI wynosił kilka sekund, podczas gdy wykonanie równie szczegółowej analizy przez lekarza dentystę zajmowało około 4 minuty.

Tabela 4. Wyniki analizy przeprowadzonej przez oprogramowanie AI obejmujące liczbę zidentyfikowanych diagnoz, ich średnią przypadającą na jednego pacjenta oraz odchylenie standardowe

Parametry liczbowe Diagnoza	Całkowita liczba	Średnia na pacjenta	Odchylenie standardowe	Liczba w łuku górnym	Liczba w łuku dolnym
Zdrowy ząb	14533	14,83	6,99	6141	8392
Wypełnienie w obrębie korony	8882	9,06	4,80	4942	3940
Próchnica	5975	6,10	3,11	3526	2449
Brakujący ząb	5066	5,17	5,68	2714	2352
Wypełnienie kanałowe	1918	1,96	2,18	1227	691
Zmiana okołowierzchołkowa	882	0,90	1,19	447	435
Korona osadzona na zębie własnym	806	0,82	1,76	596	210
Przęsło mostu	217	0,22	0,89	171	46
Implant	46	0,05	0,38	39	7
Korona osadzona na implancie	28	0,03	0,32	24	4

Tabela 5. Maksymalna i minimalna liczba wystąpień każdej diagnozy wśród uczestników badania

Diagnoza \ Częstość występowania	Najczęstszy ząb	Najrzadszy ząb
Próchnica	16 (432 razy)	31 (7 razy)
Brakujący ząb	28 (385 razy)	33 (8 razy)
Wypełnienie w obrębie korony	16 (538 razy)	31 (51 razy)
Wypełnienie kanałowe	26 (141 razy)	28, 42 (8 razy)
Zmiana okołowierzchołkowa	46 (89 razy)	31 (3 razy)
Korona osadzona na zębie własnym	21 (62 razy)	18 (2 razy)
Przęsło mostu	14, 24 (27 razy)	18, 17, 28, 33, 32, 41-44 (0 razy)
Korona osadzona na implancie	12, 21 (4 razy)	18, 17, 27-44, 47, 48 (0 razy)
Implant	14 (6 razy)	18, 17, 28-37, 34-44, 47, 48 (0 razy)
Zdrowy ząb	42 (892 razy)	46 (53 razy)

8.3. Ocena skuteczności algorytmu AI w analizie zdjęć pantomograficznych pacjentów z uzębieniem stałym

Wykorzystany w badaniu algorytm AI wykazał się bardzo wysoką dokładnością oraz swoistością wynoszącą ponad 98% w identyfikacji braków zębowych. Podobnie czułość i precyzja osiągnęły wartość 95%. Błędne diagnozy pojawiały się m.in. w przypadku uzębienia resztkowego, kiedy z powodu braku zęba, ząb sąsiadujący migrował w stronę luki (objaw Godona). Trudności interpretacyjnych dostarczały algorytmowi również stłoczenia czy obecność zębów zatrzymanych, gdy na zdjęciu pantomograficznym zęby nachodziły na siebie. Wszystkie obliczone miary oceny klasyfikacji, w przypadku identyfikacji wypełnień kanałowych, osiągnęły wartość powyżej 94%. Niższe wartości czułości (74,74%) i precyzji (72,47%) pojawiły się przy rozpoznawaniu zmian okołowierzchołkowych. Jedną z przyczyn takiego wyniku może być rzutowanie się struktur anatomicznych np. otworu bródkowego na wierzchołki korzeni. Zdarzyło się, że algorytm przypisał zmianę do zęba sąsiedniego. Badany model osiągnął bardzo wysoką swoistość (99%) w identyfikowaniu przęseł mostów oraz koron osadzonych na implantach i zębach własnych. Jedynie wartość precyzji (65,30%) była średnia w przypadku wykrywania koron protetycznych. Pojawiły się przypadki, kiedy model błędnie klasyfikował rozległe wypełnienia jako korony. Identyfikowanie przęseł mostów odznaczało się czułością o wartości 80,92% oraz bardzo wysoką dokładnością – 99,8%. Zdarzało się, że algorytm błędnie zidentyfikował ząb jako przęsło. Algorytm bardzo dobrze sprawdził się w identyfikacji implantów, osiągając niemal 100% swoistość i dokładność. Częstość ich występowania wśród wszystkich zbadanych pozycji zębowych była jednak niska (0,19%). Niemniej, wyznaczając średnią harmoniczną uzyskanej precyzji i czułości można stwierdzić, że jakość modelu w tym zakresie jest dobra, lecz z pewnym polem do poprawy. Pojawiły się pojedyncze przypadki, kiedy algorytm błędnie zidentyfikował wkład koronowo-korzeniowy jako implant. Szczegółowe wyniki badania przedstawiono w Tabeli 6.

Tabela 6. Wskaźniki oceny jakości oprogramowania AI wykorzystanego do analizy zdjęć OPG z uzębieniem stałym

Diagnoza Parametry oceny	Brakujący zęb	Wypełnienie kanałowe	Zmiana okołowierzchołkowa	Implant	Korona na implantach	Przęsło mostu	Korona protetyczna na zębie własnym	Zęb zdrowy
Czułość (95% CI)	95,84% (95,05–96,53%)	94,57% (93,15–95,78%)	74,75% (70,74–78,48%)	88,89% (73,94–96,89%)	92,59% (75,71–99,09%)	80,92% (73,76–86,83%)	96,26% (93,70–98,00%)	97,97% (97,73–98,19%)
Swoistość (95% CI)	99,11% (98,95–99,25%)	99,61% (99,51–99,70%)	99,23% (99,09–99,35%)	99,97% (99,93–99,99%)	100% (99,98–100%)	99,95% (99,91–99,98%)	99,06% (98,91–99,19%)	96,89% (96,39–97,34%)
Precyzja (95% CI)	95,13% (94,32–95,83%)	94,26% (92,86–95,41%)	72,47% (68,94–75,73%)	84,21% (70,38–92,29%)	100% (86,28–100%)	93,18% (87,62–96,35%)	65,30% (61,89–68,57%)	98,83% (98,65–98,99%)
Dokładność (95% CI)	98,60% (98,43–98,77%)	99,29% (99,16–99,41%)	98,58% (98,41–98,75%)	99,95% (99,90–99,98%)	99,99% (99,96–100%)	99,80% (99,73–99,86%)	99,01% (98,86–99,14%)	97,68% (97,46–97,88%)

8.4. Ocena skuteczności algorytmu AI w analizie zdjęć pantomograficznych pacjentów z uzębieniem mieszanym

Skuteczność testowanego algorytmu AI w analizie zębów stałych na zdjęciu pantomograficznym jest niższa u pacjentów pediatrycznych z uzębieniem mieszanym niż u pacjentów dorosłych. Mimo, że model przeznaczony był jedynie do oceny pełnego uzębienia stałego, uzyskał on ponad 90% swoistość i dokładność w wykrywaniu próchnicy i wypełnień w obrębie koron zębowych. Identyfikowanie brakujących zębów również charakteryzowała bardzo wysoka swoistość (91,9%) oraz dokładność na poziomie 85%. Precyzja modelu okazała się niska dla wszystkich analizowanych zmiennych, nie przekraczając 38,16%. Przykładowo, algorytm wykrył próchnicę w 129 zębach, podczas gdy badacze stwierdzili ją jedynie w 45 zębach. Gorsze wskaźniki jakości klasyfikacji mogą wynikać z obecności zębów mlecznych, które w niektórych przypadkach były błędnie identyfikowane jako zęby stałe. Oprogramowanie przeważnie dostrzegało zawiązki zębów stałych, oznaczając je jako obecne zęby stałe na diagramie. Zdarzało się, zwłaszcza w przypadku zawiązków trzecich trzonowców, że mimo ich obecności, model oznaczał daną pozycję jako brak zębów. Problemy niekiedy sprawiał stały aparat ortodontyczny, który razem z pierścieniami

ortodontycznymi był identyfikowany jako wypełnienie. Liczba przypadków wypełnień kanałowych i zmian okołowierzchołkowych w badanej próbie była zbyt mała, aby w pełni rozważyć uzyskane wyniki. Warto jednak zwrócić uwagę na nadmierną detekcję zmian okołowierzchołkowych przez AI, która prawdopodobnie wynika z obecności zębów stałych z niezakończonym rozwojem korzenia, kiedy otwór wierzchołkowy jest szeroki. Szczegółowe wyniki badania przedstawiono w Tabeli 7.

Tabela 7. Wskaźniki oceny jakości oprogramowania AI wykorzystanego do analizy zębów stałych na zdjęciach OPG z uzębieniem mieszanym

Diagnoza Parametry oceny	Próchnica	Brakujący ząb	Wypełnienie w obrębie korony	Wypełnienie kanałowe	Zmiana okołowierzchołkowa
Czułość (95% CI)	75,56% (60,46–87,12%)	14,94% (8,20–24,20%)	87,88% (71,80–96,60%)	100% (2,50–100%)	40% (5,27–85,34%)
Swoistość (95% CI)	91,16% (89,30–92,79%)	91,97% (90,14–93,55%)	95,68% (71,80–96,60%)	99,82% (99,36–99,98%)	97,49% (96,39–98,32%)
Precyzja (95% CI)	26,36% (21,73–31,57%)	13,54% (8,35–21,22%)	38,16% (31,22–45,62%)	33,33% (11,13–66,63%)	6,67% (2,25–18,17%)
Dokładność (95% CI)	90,54% (88,67–92,19%)	85,98% (83,81–87,96%)	95,45% (94,06–96,59%)	99,82% (99,36–99,98%)	97,23% (96,09–98,11%)

9. Wnioski

Na podstawie przeprowadzonych badań wyciągnięto następujące wnioski końcowe:

1. Wyraźny wzrost efektywności algorytmów wykorzystujących ML w ostatnich latach sprawił, że obecnie AI może z powodzeniem wspierać lekarzy dentystów w analizie zdjęć pantomograficznych, osiągając skuteczność zbliżoną do ekspertów w danej dziedzinie, zwłaszcza w identyfikacji i numerowaniu zębów oraz wykrywaniu utraty kości w przebiegu zapalenia przyzębia.
2. Wykonana przez oprogramowanie AI analiza 980 zdjęć pantomograficznych polskich pacjentów ujawniła niezadowalający stan zdrowia jamy ustnej badanej populacji, co sugeruje konieczność podjęcia odpowiednich działań zarówno leczniczych, jak i profilaktycznych.
3. Możliwość szybkiego generowania raportów oraz wysoka dokładność algorytmów sprawiają, że AI może znacząco ułatwić prowadzenie badań przekrojowych dotyczących stanu zdrowia jamy ustnej na bardzo dużych populacjach.
4. Testowany algorytm osiągnął bardzo dobre wyniki w identyfikacji brakujących zębów, wypełnień kanałowych, przęseł mostów, implantów oraz osadzonych na nich koron, jednak niższa precyzja w rozpoznawaniu zmian okołowierchołkowych i koron protetycznych na zębach własnych wskazuje na potrzebę dokładnego kontrolowania tych oznaczeń.
5. Większe ryzyko uzyskania błędnej analizy występuje w przypadku uzębienia mieszanego, gdzie obecność zębów mlecznych może utrudniać AI prawidłowe rozpoznanie. W związku z tym istotny jest dalszy rozwój modeli AI, zwłaszcza tych skierowanych do pacjentów pediatrycznych.

10. Podsumowanie

Przeprowadzone badania w znacznym stopniu potwierdzają hipotezę, że AI osiąga skuteczność diagnostyczną porównywalną do człowieka w analizie zdjęć pantomograficznych. Na rynku dostępnych jest coraz więcej modeli ML wykrywających różnego rodzaju patologie czy struktury na radiogramach, których parametry oceny potrafią się istotnie różnić. Skuteczność niektórych z nich jest równa lub nawet większa od doświadczonych lekarzy. Testowany algorytm osiągnął bardzo wysokie wyniki w identyfikacji brakujących zębów, wypełnień kanałowych, przeseł mostów, implantów oraz osadzonych na nich koron. Diagnoza algorytmu obejmująca zmiany okołowierzchołkowe i korony protetyczne na zębach własnych wymaga jednak dodatkowej weryfikacji przez lekarza. Model gorzej poradził sobie z analizą uzębienia stałego w przypadku obecności zębów mlecznych, niemniej nie był wcześniej trenowany do oceny uzębienia mieszanego. Mimo to, uzyskano wysokie wartości dokładności i swoistości algorytmu. Możliwość przeprowadzenia analizy zdjęcia pantomograficznego w znacznie krótszym czasie niż w przypadku człowieka znacząco ułatwia prowadzenie badań epidemiologicznych.

Wprowadzenie oprogramowania AI do codziennej praktyki stomatologicznej może przynieść wiele korzyści. Zautomatyzowanie zadań, takich jak wypełnianie diagramów zębowych podczas pierwszej wizyty w gabinecie, zmniejszy obciążenie lekarzy pozwalając im przeznaczyć więcej czasu na leczenie pacjentów. Ponadto, wygenerowana automatycznie analiza może stanowić drugą opinię dla stomatologa, zmniejszając ryzyko popełnienia błędu czy przeoczenia stanów patologicznych. AI może stanowić również cenne wsparcie dla młodych, mniej doświadczonych dentystów, redukując stres związany z początkiem pracy klinicznej. Oprogramowania AI obecne na rynku w atrakcyjny wizualnie sposób oznaczają miejsca wymagające leczenia, co ułatwia kontakt lekarza z pacjentem. Możliwość uzyskania przez pacjenta obiektywnej informacji na temat aktualnego stanu zdrowia jamy ustnej, zwiększa jego poczucie bezpieczeństwa oraz motywuje do podjęcia leczenia.

Mimo wielu zalet, AI posiada również pewne ograniczenia, takie jak trudność w interpretacji nietypowych przypadków czy brak uwzględniania kontekstu klinicznego, który może być istotny dla postawienia prawidłowej diagnozy. W związku z tym, technologia ta nie powinna być postrzegana jako potencjalne zagrożenie dla pracy lekarzy, ale jako narzędzie wspomagające ich pracę, ułatwiające podejmowanie decyzji i redukujące możliwość popełnienia błędu. Podczas wprowadzania AI do codziennej praktyki istotny jest wybór

oprogramowania, którego skuteczność została potwierdzona wiarygodnymi badaniami i certyfikatami.

11. Piśmiennictwo

1. Cordeschi R. AI Turns Fifty: Revisiting Its Origins. *Applied Artificial Intelligence*. 25 kwiecień 2007;21(4–5):259–79.
2. What Is Artificial Intelligence (AI)? | IBM [Internet]. 2024 [cytowane 2 kwiecień 2025]. Dostępne na: <https://www.ibm.com/think/topics/artificial-intelligence>
3. Marsland S. *Machine Learning - An Algorithmic Perspective (Second Edition)*. CRC Press; 2015.
4. Torres-Velázquez M, Chen WJ, Li X, McMillan AB. Application and Construction of Deep Learning Networks in Medical Imaging. *IEEE Transactions on Radiation and Plasma Medical Sciences*. marzec 2021;5(2):137–59.
5. Podręcznik: Sieć konwolucyjna CNN | Ośrodek Kształcenia na Odległość Politechniki Warszawskiej [Internet]. [cytowane 2 kwiecień 2025]. Dostępne na: <https://esezam.okno.pw.edu.pl/mod/book/view.php?id=2218&chapterid=3259>
6. Orhan K, Jagtap R. *Artificial Intelligence in Dentistry*. Szwajcaria: Springer Nature; 2023.
7. Khanagar SB, Al-ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, i in. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dental Sciences*. 1 stycznia 2021;16(1):508–22.
8. Albano D, Galiano V, Basile M, Di Luca F, Gitto S, Messina C, i in. Artificial intelligence for radiographic imaging detection of caries lesions: a systematic review. *BMC Oral Health*. 24 lutego 2024;24(1):274.
9. Esmaeilifard R, Bonyadifard H, Paknahad M. Dental Caries Detection and Classification in CBCT Images Using Deep Learning. *International Dental Journal*. 1 kwiecień 2024;74(2):328–34.
10. Akarslan ZZ, Akdevelioğlu M, Güngör K, Erten H. A comparison of the diagnostic accuracy of bitewing, periapical, unfiltered and filtered digital panoramic images for approximal caries detection in posterior teeth. *Dentomaxillofac Radiol*. grudzień 2008;37(8):458–63.
11. Lian L, Zhu T, Zhu F, Zhu H. Deep Learning for Caries Detection and Classification. *Diagnostics*. wrzesień 2021;11(9):1672.
12. Perschbacher S. Interpretation of panoramic radiographs. *Australian Dental Journal*. 2012;57(s1):40–5.
13. Jańczuk Z, Arabska-Przedpełska B, Lipski M, Kaczmarek U. *Stomatologia zachowawcza z endodoncją - Zarys kliniczny*. 4. wyd. PZWL; 2014.

14. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, i in. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol.* 2 marzec 2019;48(4):20180051.
15. Ha EG, Jeon KJ, Kim YH, Kim JY, Han SS. Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Sci Rep.* 29 listopad 2021;11:23061.
16. Vishwanathaiah S, Fageeh HN, Khanagar SB, Maganur PC. Artificial Intelligence Its Uses and Application in Pediatric Dentistry: A Review. *Biomedicines.* 5 marzec 2023;11(3):788.
17. Pul U, Schwendicke F. Artificial intelligence for detecting periapical radiolucencies: A systematic review and meta-analysis. *Journal of Dentistry.* 1 sierpień 2024;147:105104.
18. Jeon SJ, Yun JP, Yeom HG, Shin WS, Lee JH, Jeong SH, i in. Deep-learning for predicting C-shaped canals in mandibular second molars on panoramic radiographs. *Dentomaxillofac Radiol.* 1 lipiec 2021;50(5):20200513.
19. Revilla-León M, Gómez-Polo M, Barmak AB, Inam W, Kan JYK, Kois JC, i in. Artificial intelligence models for diagnosing gingivitis and periodontal disease: A systematic review. *The Journal of Prosthetic Dentistry.* marzec 2022;S0022391322000750.
20. Artese HPC, Foz AM, Rabelo M de S, Gomes GH, Orlandi M, Suvan J, i in. Periodontal Therapy and Systemic Inflammation in Type 2 Diabetes Mellitus: A Meta-Analysis. *PLOS ONE.* 26 maj 2015;10(5):e0128344.
21. Zheng X, Li X, Zhen J, Xue D, Hu J, Cao Q, i in. Periodontitis is associated with stroke. *Journal of Translational Medicine.* 6 październik 2023;21(1):697.
22. Bouziane A, Lattaf S, Abdallaoui Maan L. Effect of Periodontal Disease on Alzheimer's Disease: A Systematic Review. *Cureus.* 15(10):e46311.
23. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofacial Radiology.* 1 styczeń 2020;49(1):20190107.
24. Chang HJ, Lee SJ, Yong TH, Shin NY, Jang BG, Kim JE, i in. Deep Learning Hybrid Method to Automatically Diagnose Periodontal Bone Loss and Stage Periodontitis. *Sci Rep.* 5 maj 2020;10(1):7531.
25. Liu L, Xu J, Huan Y, Zou Z, Yeh SC, Zheng LR. A Smart Dental Health-IoT Platform Based on Intelligent Hardware, Deep Learning, and Mobile Terminal. *IEEE J Biomed Health Inform.* marzec 2020;24(3):898–906.

26. Miragall MF, Knoedler S, Kauke-Navarro M, Saadoun R, Grabenhorst A, Grill FD, i in. Face the Future—Artificial Intelligence in Oral and Maxillofacial Surgery. *Journal of Clinical Medicine*. 30 październik 2023;12(21):6843.
27. Choi E, Lee S, Jeong E, Shin S, Park H, Youm S, i in. Artificial intelligence in positioning between mandibular third molar and inferior alveolar nerve on panoramic radiography. *Sci Rep*. 14 luty 2022;12(1):2456.
28. Hung KF, Ai QYH, King AD, Bornstein MM, Wong LM, Leung YY. Automatic detection and segmentation of morphological changes of the maxillary sinus mucosa on cone-beam computed tomography images using a three-dimensional convolutional neural network. *Clin Oral Investig*. maj 2022;26(5):3987–98.
29. Kuwana R, Ariji Y, Fukuda M, Kise Y, Nozawa M, Kuwada C, i in. Performance of deep learning object detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs. *Dentomaxillofac Radiol*. 1 styczeń 2021;50(1):20200171.
30. Rokhshad R, Keyhan SO, Yousefi P. Artificial intelligence applications and ethical challenges in oral and maxillo-facial cosmetic surgery: a narrative review. *Maxillofacial Plastic and Reconstructive Surgery*. 13 marzec 2023;45(1):14.
31. Patil S, Albogami S, Hosmani J, Mujoo S, Kamil MA, Mansour MA, i in. Artificial Intelligence in the Diagnosis of Oral Diseases: Applications and Pitfalls. *Diagnostics*. maj 2022;12(5):1029.
32. Altan B, Gunec HG, Cinar S, Kutal S, Gulum S, Aydin KC. Detecting Prosthetic Restorations Using Artificial Intelligence on Panoramic Radiographs. *Scientific Programming*. 2022;2022(1):6384905.
33. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surg Oral Med Oral Pathol Oral Radiol*. listopad 2020;130(5):593–602.
34. Bonfanti-Gris M, Ruales E, Salido M, Martinez-Rus F, Özcan M, Pradies G. Artificial intelligence for dental implant classification and peri-implant pathology identification in 2D radiographs: A systematic review. *Journal of Dentistry*. 1 luty 2025;153:105533.
35. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *J Clin Med*. 2 marzec 2021;10(5):1009.

36. Mangano FG, Admakin O, Lerner H, Mangano C. Artificial intelligence and augmented reality for guided implant surgery planning: A proof of concept. *J Dent.* czerwiec 2023;133:104485.
37. Subramanian AK, Chen Y, Almalki A, Sivamurthy G, Kafle D. Cephalometric Analysis in Orthodontics Using Artificial Intelligence—A Comprehensive Review. *Biomed Res Int.* 16 czerwiec 2022;2022:1880113.
38. Thakur SM, Shenoy U, Hazare A, Karia H, Khorgade P, Nandeshwar N, i in. Transforming orthodontics with artificial intelligence: A comprehensive review. *J Adv Dental Pract Res.* 2024;0(0):1–9.
39. Różyło-Kalinowska I. Panoramic radiography in dentistry. *Clin Dent Rev.* 7 grudzień 2021;5(1):26.
40. Martins LAC, Brasil DM, Forner LA, Viccari C, Haiter-Neto F, Freitas DQ, i in. Does dose optimisation in digital panoramic radiography affect diagnostic performance? *Clin Oral Investig.* luty 2021;25(2):637–43.
41. Kweon HHI, Lee JH, Youk T mi, Lee BA, Kim YT. Panoramic radiography can be an effective diagnostic tool adjunctive to oral examinations in the national health checkup program. *J Periodontal Implant Sci.* 2018;48(5):317.
42. Ghassemzadeh S, Sbricoli L, Frigo AC, Bacci C. Incidental findings detected with panoramic radiography: prevalence calculated on a sample of 2017 cases treated at a major Italian trauma and cancer centre. *Oral Radiol.* 2021;37(3):507–17.
43. Farman AG. Panoramic Radiology. *Seminars on Maxillofacial Imaging and Interpretation.* Springer Berlin Heidelberg New York; 2007.
44. Różyło TK, Różyło-Kalinowska I. *Radiologia stomatologiczna. I-3 dodruk.* Warszawa: Wydawnictwo Lekarskie PZWL; 2011.
45. Izzetti R, Nisi M, Aringhieri G, Crocetti L, Graziani F, Nardi C. Basic Knowledge and New Advances in Panoramic Radiography Imaging Techniques: A Narrative Review on What Dentists and Radiologists Should Know. *Applied Sciences.* styczeń 2021;11(17):7858.
46. Gościak E, Kułak P. *Wybrane aspekty radiodiagnostyki dziecięcej - Tom 1.* 2016.
47. Radiation doses in dental radiology [Internet]. IAEA; 2017 [cytowane 17 luty 2025]. Dostępne na: <https://www.iaea.org/resources/rpop/health-professionals/dentistry/radiation-doses>

48. CS 9600 Technical Specifications [Internet]. [cytowane 17 luty 2025]. Dostępne na: https://help.carestreamdental.com/rh/web/server/CS9600/projects_responsive/SMA17/CS_9600_Technical_Specifications.htm
49. Stahmer U. Flight-Time Equivalent Dose – A Concept to Contextualize Radiological Dose. 2016;
50. Czy asystentki i higienistki stomatologiczne mogą robić zdjęcia RTG? [Internet]. MCP Kancelaria. 2024 [cytowane 3 kwiecień 2025]. Dostępne na: <https://mcp-kancelaria.pl/czy-asystentki-i-higienistki-stomatologiczne-moga-robic-zdjecia-rtg/>
51. Choi JW. Assessment of panoramic radiography as a national oral examination tool: review of the literature. *Imaging Sci Dent.* marzec 2011;41(1):1–6.

12. Załączniki

1. Treść publikacji będących podstawą pracy doktorskiej
2. Oświadczenia współautorów
3. Opinia Komisji Bioetycznej
4. Biogram doktoranta
5. Analiza bibliometryczna
6. Oświadczenie kandydata o oryginalności pracy doktorskiej

SYSTEMATIC REVIEW

Applications of artificial intelligence in the analysis of dental panoramic radiographs: an overview of systematic reviews

¹Natalia Turosz, ²Kamila Chęcińska, ³Maciej Chęciński, ⁴Anita Brzozowska, ⁵Zuzanna Nowak and ^{6,7}Maciej Sikora

¹Institute of Public Health, Jagiellonian University Medical College, Skawińska, Poland; ²Department of Glass Technology and Amorphous Coatings, Faculty of Materials Science and Ceramics, AGH University of Science and Technology, Mickiewicza, Poland; ³Department of Oral Surgery, Preventive Medicine Center, Komorowskiego, Poland; ⁴Preventive Medicine Center, Komorowskiego, Poland; ⁵Department of Temporomandibular Disorders, Medical University of Silesia in Katowice, Katowice, Poland; ⁶Department of Maxillofacial Surgery, Hospital of the Ministry of Interior, Wojska Polskiego, Poland; ⁷Department of Biochemistry and Medical Chemistry, Pomeranian Medical University, Powstańców Wielkopolskich, Poland

Objectives: This overview of systematic reviews aimed to establish the current state of knowledge on the suitability of artificial intelligence (AI) in dental panoramic radiograph analysis and illustrate its changes over time.

Methods: Medical databases covered by the Association for Computing Machinery, Bielefeld Academic Search Engine, Google Scholar, and PubMed engines were searched. The risk of bias was assessed using ROBIS tool. Ultimately, 12 articles were qualified for the qualitative synthesis. The results were visualized with timelines, tables, and charts.

Results: In the years 1988–2023, a significant development of information technologies for the analysis of DPRs was observed. The latest analyzed AI models achieve high accuracy in detecting caries (91.5%), osteoporosis (89.29%), maxillary sinusitis (87.5%), periodontal bone loss (93.09%), and teeth identification and numbering (93.67%). The detection of periapical lesions is also characterized by high sensitivity (99.95%) and specificity (92%). However, due to the small number of heterogeneous source studies synthesized in systematic reviews, the results of this overview should be interpreted with caution.

Conclusion: Currently, AI applications can significantly support dentists in dental panoramic radiograph analysis. As systematic reviews on AI become outdated quickly, their regular updating is recommended. PROSPERO registration number: CRD42023416048.

Dentomaxillofacial Radiology (2023) 52, 20230284. doi: [10.1259/dmfr.20230284](https://doi.org/10.1259/dmfr.20230284)

Cite this article as: Turosz N, Chęcińska K, Chęciński M, Brzozowska A, Nowak Z, Sikora M. Applications of artificial intelligence in the analysis of dental panoramic radiographs: an overview of systematic reviews. *Dentomaxillofac Radiol* (2023) 10.1259/dmfr.20230284.

Keywords: Artificial Intelligence; Deep learning; Dental radiography; Panoramic radiographs; Overview of reviews

Introduction

Background

Artificial intelligence (AI), introduced in 1956, has become a hot topic in contemporary radiology and an area of interest for many researchers.¹ Its integration into healthcare has expanded significantly in the

past decade.² AI is defined as the ability of a machine to perform complex tasks imitating specific human activities, such as solving problems, and making plans or decisions.³ The main technology used in dentistry is known as image processing. These algorithms achieve high-accuracy classification and segmentation in radiographs, including panoramic ones. Modern analytical algorithms, including those used in medical analysis, can self-learn based on successive portions of data

Correspondence to: Natalia Turosz, E-mail: natalia.turosz@gmail.com

Received 25 June 2023; revised 07 August 2023; accepted 08 August 2023; published online 04 September 2023




Figure 1 The major aspects of artificial intelligence.

provided, which is referred to as machine learning (ML).⁴ It is a part of AI that provides machines to learn from experience without explicit programming for a single task.⁵ Neural networks are the heart of deep learning (DL) algorithms, which allow computers to learn by observing patterns in the data (Figure 1).⁶ A type of neural network used mainly for image recognition and processing is called a convolutional neural network (CNN). It is crucial to provide a large data set of images to begin the training process and obtain a high-performance deep learning model.

According to Thurzo *et al* from 2011, publications on the use of AI in dentistry mainly concerned

radiology (26.36%), orthodontics (18.31%), general scope (17.10%), restorative dentistry (12.09%), surgery (11.87%), and education (5.63%) (Figure 2).² The applications of automated diagnostic and prognostic systems precisely identifying pathologies, cysts, tumors, periapical lesions, fractures, and other diseases are particularly promising in dental radiology. Most ML algorithms were developed using 2D diagnostic images such as cephalometric, periapical, and panoramic radiographs.

Dental panoramic radiographs (DPRs) are widely accepted as a primary source of information about oral health as they visualize all teeth and surrounding structures in one image, allowing for a basic assessment of dentition, periodontal bone loss, and lesions within the jaw bones.⁷ Non-dental random findings on DPRs include pathological conditions such as maxillary sinusitis, sialoliths, tonsilloliths, elongated stylohyoid processes, and calcifications in the carotid arteries.⁸ Besides the screening purpose, properly analyzed DPRs help to make therapeutic decisions. Their comprehensive analysis is time-consuming but desirable due to the identification of possible comorbidities.

Rationale

AI is considered useful in the detection of dental caries, vertical root fractures, apical lesions, periodontal bone loss, tumors and maxillary sinusitis on panoramic radiography, as well as in determining the proximity of the inferior alveolar nerve to the roots of lower third molars.^{9,10} The number of systematic reviews of various possibilities of using AI in analyzing panoramic images encourages a comprehensive summary of the current state of knowledge.




Figure 2 Main AI focus in dentistry from 2011 to 2021. AI, artificial intelligence.

Table 1 Eligibility criteria

	<i>Inclusion</i>	<i>Exclusion</i>
Population	Panoramic radiograms obtained from human subjects	Panoramic reconstructions from CT images
Intervention	Diagnostics conducted by artificial intelligence algorithms	Analyses of no medical relevance
Comparison	Human-based diagnoses	Mixed human-algorithmic diagnoses
Outcomes	Qualitative (exclusion or confirmation) or quantitative (measurements against reference points) AI efficiency	No quantified results
Study design	Systematic reviews without time frame limits	Publication language other than English

Objectives

The purpose of this overview of reviews was to establish the current state of knowledge on the suitability of artificial intelligence in DPR analysis and illustrate its changes over time. This research question belongs to the second type of research question according to the guidelines of Pollock *et al* for overviews of reviews.¹¹

Methods

Eligibility criteria

The overview of reviews followed Preferred Reporting Items for Overviews of Reviews guidelines.¹² The eligibility criteria were established following the PICOS methodology (Table 1).¹³ A systematic review was considered to be one that contained the “systematic review” term in the title and/or abstract, had specific inclusion criteria and sources, and contained a description or visualization of the selection process. No supplemental primary studies were included.

Information sources

Bielefeld Academic Search Engine (BASE) and Google Scholar search engines were used as the ones with the greatest medical coverage according to Gusenbauer.^{14–16} Additionally, Association for Computing Machinery: Guide to Computing Literature (ACM) and National Library of Medicine: PubMed databases were searched.^{17,18}

Search strategy

The search of medical databases was carried out on June 1, 2023, according to the following strategy: (“panoramic” OR “dpr” OR “dpt” OR “pantomogram” OR “orthopantomogram” OR “opg”) AND (“ai” OR “intelligence” OR “intelligent” OR “neural” OR “cnn” OR “machine” OR “deep” OR “automated” OR “learning”) AND “systematic” AND “review”. Due to Google Scholar search engine retrieving the most accurate results related to the given query initially, with their relevance gradually decreasing, only the first 200 out of over 100,000 items were retrieved.

Selection process

Deduplication and screening according to the Population and Intervention criteria were performed using

the Rayyan tool (Qatar Computing Research Institute, Doha, Qatar and Rayyan Systems, Cambridge, MA).¹⁹ Titles and abstracts were blindly assessed by three authors (NT, MC, and AB). The inclusion decision by at least one of the judges promoted the report for full-text evaluation (NT and MC). The entire selection process was visualized using a flow diagram. The overlapping issue was omitted at this stage and was addressed in the following steps.

Data collection process

Data from reports were independently extracted by two authors (NT and MC) without the use of automation tools. In cases of inconsistency, the third investigator (KC) had the deciding vote. The data were divided according to the problem assessed by the AI: (1) teeth identification and numbering; (2) detection of periapical lesions; (3) periodontal bone loss; (4) osteoporosis; (5) maxillary sinusitis; (6) dental caries; and (7) other tasks. The overlapping of primary studies was visualized on a timeline created in Microsoft PowerPoint (Microsoft Corporation, Redmond, WA).

Data items

From included systematic reviews, we extracted manually the following variables: (a) sensitivity; (b) specificity; (c) precision; and (d) accuracy of AI models used in the analysis of DPRs, omitting data not available. Data presented in decimal form were converted to percentages. The ranges of the above variables were presented consecutively from smallest to largest in the relevant tables. The arithmetic mean of each variable was shown in parentheses. The average value of individual variables in subsequent years was also calculated and included in the relevant figures.

Mean values of individual variables evaluating the performance of AI algorithms were extracted from each systematic review, if available. In the absence of data, an attempt was made to calculate individual means based on the data contained in the systematic review. Where necessary, the content of source studies was also used. Calculations of average performances were made on the basis of data from studies that met the quality criteria of a given systematic review (satisfactory sample size, low risk of bias).

Risk of bias assessment

In the course of this overview of reviews, the qualification of source studies for individual systematic reviews




Figure 3 PRIOR flow diagram. PRIOR, Preferred Reporting Items for Overviews of Reviews.

was not questioned, but only the risk of bias in systematic reviews was assessed. “ROBIS: Tool to assess risk of bias in systematic reviews” was used to evaluate eligible reports.²⁰ Systematic reviews with a high risk of bias were rejected.

Synthesis methods

The efficiencies of AI in individual tasks were presented in tables and visualized in graphs using Microsoft Office (Microsoft Corporation, Redmond, WA).

Results

Systematic review

A systematic literature review yielded a total of 1021 entries, of which 983 remained after auto-deduplication. Manual deduplication resulted in the deletion of further items, which limited the selection to 933 unique entries. Blind screening by three authors resulted in the removal of 864 items unanimously indicated as non-compliant with the adopted criteria. Thus, 69 articles identified by at least one of the researchers as potentially eligible were evaluated in full text. Of these, 57 were rejected, with reasons given (Table A1). The concordance of decisions at this stage, expressed by Cohen’s κ coefficient, was 0.85, which means an almost perfect agreement. Ultimately, 12 articles were qualified for the synthesis (Figure 3).^{21–32}

Characteristics of systematic reviews

12 eligible articles were published between 2019 and 2023. Data characterizing qualified systematic reviews are presented in Table 2. ‘Coverage dates’ include the years in which articles were searched for inclusion in a given systematic review. Some authors did not specify a time frame or did not introduce restrictions on the publication period (Figure 4). ‘Included dates’ cover the full years in which research papers qualified for a given systematic review were published. The oldest analyzed article was from 1988, while the latest was from 2022. AI has often been used to identify teeth and detect caries, osteoporosis, periapical lesions, and periodontal disease.

Primary study overlap

Eligible systematic reviews included articles published between 1988 and 2022 (Figure 5 illustrates the full years covered by each systematic review). Regardless of the wide search date ranges, most authors included only reports published after 2016. The oldest research paper dealt with the use of AI in the detection of periodontal disease.³³ Over time, this technology began to be used also in the detection of periapical lesions, dental caries, osteoporosis, and tooth numbering.

Risk of bias in systematic reviews

The results of the assessment of the risk of bias are presented in Table 3. The distribution of the assessment

Table 2 Characteristics of systematic reviews

<i>First author</i>	<i>Publication date</i>	<i>Coverage dates</i>	<i>Dental field</i>
		<i>(Inclusion dates)</i>	
Almāšan	2023	To 2022 (2020–2021)	Diagnosis of temporomandiubular joint osteoarthritis
Chaurasia	2023	2011–2022 (2020–2022)	Identifying and classifying dental implant systems
Mohammad-Rahimi	2022	2010–2021 (2017–2021)	Dental caries detection
Revilla-León	2022	N/S, presumably to 2022 (1988–2020)	Diagnosis of alveolar bone loss
Sadr	2022	2010–2022 (2019–2022)	Detecting periapical lesions
Singh	2022	2016–2020 (2016–2020)	Tooth detection and numbering Dental caries detection Periodontal disease detection Osteoporosis detection Oral lesion detection Forensic dentistry Teeth identification
Umer	2022	To 2021 (2018–2021)	Implant type recognition Osteointegration success or implant success prediction Implant design optimization
Revilla-León	2021	To 2021 (2005–2020)	Staging the development of lower third molar Detecting osteoporosis Detection of VRF Teeth detection and numbering Detecting apical lesions Detection of maxillary sinusitis Detecting and segmenting the approximate of inferior Alveolar nerve to the roots of lower third molars Detecting periodontal bone loss Gender determination
Khanagar	2020	2000–2020 (2008–2020)	Dental caries detection and diagnosis
Prados-Privado	2020	To 2020 (2008–2020)	Detecting osteoporosis Classification of cysts and tumors Tooth detection and numbering Detection of maxillary sinusitis Automatic teeth segmentation Tooth detection Detecting osteoporosis Staging lower third molar development for age estimation
Hung	2019	To 2019 (1998–2019)	
Hwang	2019	To 2018 (2016–2018)	

N/S, not specified; VRF, vertical root fracture.

results in individual domains is illustrated in [Figure 6](#). One systematic review was disqualified from the quantitative syntheses due to the high risk of bias.

Synthesis of results

After assessing the risk of bias, 11 systematic reviews were qualified for the quantitative syntheses. The




Figure 4 Overlap of periods searched for systematic reviews (* - not specified, presumed time range visualized).

syntheses were carried out in seven domains: (1) detection of dental caries; (2) osteoporosis; (3) periapical lesions; (4) periodontal bone loss; (5) maxillary sinusitis; (6) teeth identification and numbering; and (7) other tasks.

Teeth identification and numbering: Four systematic reviews analyzed the use of AI in teeth identification and numbering on DPRs. 10 included articles published between 2017 and 2021 were qualified for synthesis (Table 4, Figure 7).

Detection of periapical lesions: Two systematic reviews analyzed the use of AI in the detection of periapical lesions on DPRs. Five included articles, published

between 2019 and 2022, were qualified for the synthesis (Table 5, Figure 8).

Detection of periodontal bone loss: Six articles from two systematic reviews published between 2019 and 2020 analyzed the use of AI in the detection of periodontal bone loss on DPRs (Table 6, Figure 9).

Detection of osteoporosis: Osteoporosis detection on DPRs with AI models was analyzed in 13 reports from three systematic reviews. The articles were published between 2007 and 2020 (Table 7, Figure 10).

Detection of maxillary sinusitis: Two systematic reviews analyzed the use of AI in the detection of




Figure 5 Overlap of primary studies included in systematic reviews.

Table 3 Risk of bias in systematic reviews

<i>First author</i>	<i>Domain 1: study eligibility criteria</i>	<i>Domain 2: identification and selection of studies</i>	<i>Domain 3: data collection and study appraisal</i>	<i>Domain 4: synthesis and findings</i>	<i>Risk of bias in the review</i>
Almășan					
Chaurasia					
Mohammad-Rahimi					
Revilla-León (2022)					
Sadr					
Singh					
Umer					
Revilla-León (2021)					
Khanagar					
Prados-Privado					
Hung					
Hwang					

“+”, low; “?”, unclear; “X”, high.

maxillary sinusitis on DPRs. Two included articles published between 2016 and 2019 were qualified for the synthesis (Table 8, Figure 11).

Detection of dental caries: The use of AI in dental caries detection on DPRs was analyzed in two systematic reviews. Four included articles were published between 2017 and 2021 (Table 9, Figure 12).

Other tasks: In addition to the above-mentioned problems solved by AI algorithms, the analyzed systematic reviews also included others, such as classifying cysts and tumors, detecting vertical root fractures, temporomandibular joint (TMJ) osteoarthritis and the use of AI in implant dentistry and forensic dentistry (Table 10). In case of the systematic review of Almășan et al, results

excluding indeterminate TMJ osteoarthritis diagnosis and without fine-tuning were analyzed.³¹

Discussion

General interpretation of the results

In recent years, the number of publications on AI rose notably. Most articles on the use of this technology in the analysis of DPRs were published in 2019 and beyond. Various outcome metrics were used to assess the effectiveness of AI systems. The most common ones were accuracy, sensitivity, specificity, and precision, which definitions are in Table 11.^{23,34}




Figure 6 Risk of bias distribution (Domain 1—study eligibility criteria; Domain 2—identification and selection of studies; Domain 3—data collection and study appraisal; Domain 4—synthesis and findings).

The lowest reported sensitivity (48%) of the AI algorithm was noted in the review of Sadr *et al*, where segmentation with the data set size of 1300 DPRs was used to detect periapical lesions. However, its specificity was the highest (99.95%) among all studies in analyzed systematic reviews.²³ The highest reported sensitivity (99.1%) occurs in the review of Hung *et al*, where a neural network developed on 141 DPRs from normal and osteoporotic female subjects was used to detect osteoporosis.²⁹ The lowest specificity (43.8%) was also noted in the review of Hung *et al*. This outcome comes from the article from 2008, where the discriminant technique was used to detect osteoporosis. The data set used to develop this AI model consisted of 100 images from normal, low body mass density, and osteoporotic female subjects.²⁹

The lowest reported precision (49%) appeared in the review of Sadr *et al*, where a 7-layer CNN based on a synthesized data set of more than 2000 tooth segments from panoramic radiographs was used to detect periapical lesions.²³ The highest reported precision (99.45%) and accuracy (99.87%) occur in the review of Hung *et al*, where a data set of 1352 DPRs of adults was used to train the deep CNN.²⁹

The lowest accuracy (51%) was noted in an article included in two systematic reviews (Khanagar *et al* and Hwang *et al*). In the paper, the use of CNN to stage lower third molar development on DPRs for age estimation was

assessed. 200 images were used for testing; however, the results were similar to those of the trained examiners.^{27,30}

In general, outcome metrics of AI algorithms improved over time.

The results concerning teeth identification and numbering seem surprising. In 2020, there was a decrease in sensitivity by 2.84%, specificity by 2.94%, precision by 5.82%, and accuracy by 6.2%. Nevertheless, all these values were still very high, above 93%. The following year, there was an increase in sensitivity to 98% and specificity to 99%, but this result is based on only one study from 2021.

The specificity of detection of periapical lesions increased by 12.95% within 2 years. The sensitivity initially decreased from 65 to 48% for two consecutive years but then increased to 92% in 1 year. Nevertheless, only five studies were qualified for this domain, two from 2019 and one each from 2020, 2021, 2022. In both studies, from 2021 and 2022, U-Net type deep CNNs were trained to detect periapical lesions, but there was a difference in dataset size—1300 radiographs (2021) and 470 radiographs (2022).

Six studies covered the detection of periodontal bone loss, three each from 2019 and 2020. In 1 year, there was an increase in accuracy by 12.09%, sensitivity by 5.5%, and specificity by only 0.62%.

The accuracy of detecting osteoporosis continued to grow until 2016, reaching 97.45%. In the next 2 years,

Table 4 Outcome metrics of AI algorithms in teeth identification and numbering

First author	Years of publications	Sensitivity (mean)	Specificity (mean)	Precision (mean)	Accuracy (mean)
Hung	2019	98.7% (98.7%)	99.94% (99.94%)	N/S	99.87% (99.87%)
Hwang	2017	NS	N/S	N/S	91.74% (91.74%)
Khanagar	2019	98.7% (98.7%)	N/S	99.45% (99.45%)	N/S
Umer	2020–2021	96–98% (97%)	97% (97%)	85–99% (95.17%)	89–96% (94.83%)

AI, artificial intelligence; N/S, not specified.




Figure 7 The number of reports on teeth identification and numbering and outcome metrics of AI algorithms by years. AI, artificial intelligence.

Table 5 Outcome metrics of AI algorithms in detecting periapical lesions

First author	Years of publications	Sensitivity (mean)	Specificity (mean)	Precision (mean)	Accuracy (mean)
Khanagar	2019	65% (65%)	87% (87%)	N/S	N/S
Sadr	2019–2022	48–92% (64%)	87–99.95% (93.48%)	49–84% (66%)	N/S

AI, artificial intelligence; N/S, not specified.




Figure 8 The number of reports on detection of periapical lesions and outcome metrics of AI algorithms by years. AI, artificial intelligence.

Table 6 Outcome metrics of AI algorithms in detecting periodontal bone loss

First author	Years of publications	Sensitivity (mean)	Specificity (mean)	Precision (mean)	Accuracy (mean)
Khanagar	2019	N/S	N/S	N/S	81% (81%)
Revilla-León (2022)	2019–2020	76–84% (80.33%)	81–93.75% (87.58%)	N/S	81–94.18% (89.06%)

AI, artificial intelligence; N/S, not specified.




Figure 9 The number of reports on detection of periodontal bone loss and outcome metrics of AI algorithms by years. AI, artificial intelligence.

Table 7 Outcome metrics of AI algorithms in detecting osteoporosis

First author	Years of publications	Sensitivity (mean)	Specificity (mean)	Precision (mean)	Accuracy (mean)
Hung	2007–2017	76.8–99.1% (93.06%)	43.8–98.4% (82.86%)	N/S	62–98.9% (87.31%)
Hwang	2018	N/S	N/S	N/S	89.29% (89.29%)
Khanagar	2018–2020	N/S	N/S	N/S	N/S

AI, artificial intelligence.




Figure 10 The number of reports on detection of osteoporosis and outcome metrics of AI algorithms by years. AI, artificial intelligence.

Table 8 Outcome metrics of AI algorithms in detecting maxillary sinusitis

First author	Years of publications	Sensitivity (mean)	Specificity (mean)	Precision (mean)	Accuracy (mean)
Hung	2016	77.6% (77.6%)	69.4% (69.4%)	N/S	73.5% (73.5%)
Khanagar	2019	86.7% (86.7%)	88.3% (88.3%)	N/S	87.5% (87.5%)

AI, artificial intelligence; N/S, not specified.

there was a decrease of 8.16%, but generally, in 10 years, the accuracy rose by 27.29%.

In case of maxillary sinusitis detection, between 2016 and 2019, there was an increase in accuracy by 14%, sensitivity by 9.1%, and specificity by 18.9%. However, these differences were calculated based on only two studies concerning this domain.

For dental caries detection, the average accuracy did not change between 2017 and 2020 reaching 86%, but then increased by 5.5% in 1 year.

Teeth identification and numbering: Filling digital data charts may be time-consuming for many clinicians. Teeth identification refers to the detection of teeth in DPR. It facilitates dentists' jobs as they do not have to manually enter the details, which can result in higher efficiency. However, teeth identification may be challenging for AI models due to overlapping anatomical boundaries. Hwang *et al* included in the review the study from 2017, where the conventional CNN approach was used for tooth detection. The method was tested on a dataset containing 100 DPRs, achieving 91.74% average accuracy.³⁰ Khanagar *et al* and Hung *et al* included the same study from 2019, where CNN-based AI system was used for teeth detection and numbering. The performance of

this system was comparable to the level of experts.^{27,29} The results presented by Umer show that using CNN in teeth identification is promising. Nevertheless, there are some limitations, such as a high risk of bias and heterogeneity.²⁵

Detecting periapical lesions: The most common radiographic findings associated with teeth are periapical lesions, the usual symptom of bacterial infection of the root canal system.³⁵ As many of them are asymptomatic, frequently, they are incidentally diagnosed on radiographs taken routinely in the dental office. Their early detection is crucial, especially in patients with comorbidities. Khanagar *et al* included in the review the study where a system based on deep CNN turned out to be a successful tool for detecting apical lesions.²⁷ Sadr *et al* included four studies using classification and segmentation methods, which showed relatively high specificity and sensitivity in detecting these radiolucent pathologies. However, the level of accuracy decreases due to superimposition and lack of homogeneity of two-dimensional radiographs. Ill-defined borders and the small size of lesions can influence the process of the detection of pathologies as well.²³


**Figure 11** The number of reports on detection of maxillary sinusitis and outcome metrics of AI algorithms by years. AI, artificial intelligence.

Table 9 Outcome metrics of AI algorithms in detecting dental caries

First author	Years of publications	Sensitivity (mean)	Specificity (mean)	Precision (mean)	Accuracy (mean)
Mohammad-Rahimi	2020–2021	N/S	86% (86%)	78.5–89.4% (84.97%)	86–96% (89.67%)
Prados-Privado	2017	N/S	N/S	N/S	86% (86%)

AI, artificial intelligence; N/S, not specified.

Detecting periodontal bone loss: Periodontal diseases are highly prevalent and can affect up to 90% of the population all over the world.³⁶ They are mainly a result of inflammation of the gums and surrounding bone, which can lead to early loss of teeth. Currently, many AI software can measure bone loss which helps clinicians reduce their diagnostic efforts. Khanagar et al included in systematic review a report from 2019, where a system based on CNN demonstrated similar results to six experienced dentists in detecting periodontal bone loss.²⁷ Revilla-León et al included 11 studies that evaluated AI models for detecting periodontal bone loss from radiographic images, but only five analyzed panoramic radiographs. The average accuracy, sensitivity, and specificity suggest that AI models may be a powerful tool for diagnosing periodontal diseases.²² Observing the effectiveness of currently used algorithms, differentiating extraction socket from medication-related osteonecrosis of the jaw also seems possible with the use of AI models, allowing their faster treatment.³⁷

Detecting osteoporosis: Osteoporosis is a bone disease that occurs when mineral bone density decreases or the structure of bone changes.³⁸ Orthopantomographic indices are considered tools for early screening of this

condition. Hung et al included in his review nine studies that were published between 2007 and 2017. The lowest sensitivity, specificity, and accuracy occurred in the study from 2008, whereas the highest values of these metrics were noted in the study from 2016.²⁹ Hwang et al included two studies from 2018 where deep CNN and Octuplet Siamese Network were used to detect osteoporosis with high accuracy.³⁰ Khanagar et al also included two studies from 2018 and 2020, where deep CNN turned out to be a reliable tool for automated osteoporosis screening.²⁷

Diagnosis of maxillary sinusitis: Maxillary sinusitis is the inflammation of the paranasal sinuses, which can be a result of bacterial, viral, or fungal infection.³⁹ Undiagnosed and untreated sinusitis can lead to potentially life-threatening conditions like meningitis, vision changes, or olfactory dysfunction.⁴⁰ Khanagar et al included in the review the study where the deep learning system showed higher diagnostic performance than two experienced radiologists.²⁷ Hung et al described a study in which an AI technique called asymmetry analysis was used to support inexperienced dentists in diagnosing maxillary sinusitis. The diagnostic performance increased with the support of this computer-aided detection system.²⁹




Figure 12 The number of reports on detection of dental caries detection and outcome metrics of AI algorithms by years. AI, artificial intelligence.

Table 10 Outcome metrics of AI algorithms in other analyzed tasks

<i>First author</i>	<i>Dental field</i>	<i>Years of publications</i>	<i>Sensitivity (mean)</i>	<i>Specificity (mean)</i>	<i>Precision (mean)</i>	<i>Accuracy (mean)</i>
Almāšan	Diagnosis of temporomandibular joint osteoarthritis	2020–2021	39–94% (62%)	77–91% (83%)	78% (78%)	77–88% (81%)
Chaurasia	Identifying and classifying dental implant systems	2020–2022	N/S	N/S	N/S	70.8–98.2% (86.11%)
Hung	Classification of cysts and tumors	2013	N/S	N/S	N/S	81.8–88.9% (85.72%)
Hwang	Automatic teeth segmentation	2018	N/S	N/S	79% (79%)	N/S
	Staging the development of lower third molar for age estimation	2017	N/S	N/S	N/S	51% (51%)
Khanagar	Staging the development of lower third molar for age estimation	2017	N/S	N/S	N/S	51% (51%)
	Detection of vertical root fracture	2019	N/S	N/S	93% (93%)	N/S
	Detecting and segmenting the approximate of inferior alveolar nerve to the roots of lower third molars	2019	N/S	N/S	N/S	N/S
Revilla- León (2021)	Implant type recognition	2015–2020	N/S	N/S	N/S	93.8–98%
	Osteointegration success or implant success prediction	2005–2020	N/S	N/S	N/S	62.4–80.5%
	Implant design optimization	2009–2019	N/S	N/S	N/S	N/S

AI, artificial intelligence; N/S, not specified.

Above results lead to the statement that deep learning systems may be valuable diagnostic support, especially for inexperienced clinicians.

Dental caries detection: Dental caries involves the majority of the population. Dentists usually diagnose caries lesions on panoramic radiographs relying only on their visual inspection. Detection of early lesions is vital in maintaining oral health but sometimes may be challenging.⁴¹ It is frequently difficult to identify caries lesions due to low image quality. Deep learning models may improve accuracy and support dentists in detecting them. All included studies in the systematic review of Mohammad-Rahimi *et al* were based on CNN, but different model structures were applied—PaXNet, MobileNet V2, and AlexNet. They showed relatively high mean accuracy, specificity, and sensitivity above

80%.²¹ Prados-Privado *et al* included only one study using DPRs from 2017, in which a system based on Radon Transformation and Discrete Cosine Transformation was used to detect caries lesions.²⁸

Other tasks: AI models can also be used in detecting TMJ osteoarthritis, a chronic degeneration of hard and soft tissues around the joint, in which early diagnosis is vital to effective treatment planning.⁴² Almāšan *et al* included in the review three studies where authors used Residual Neural Network, a CNN VGG16, Inception V3, and Efficient Net-B to detect this disease on panoramic radiographs. The accuracies of methods varied between moderate to good and were higher when primary indeterminate diagnoses of TMJ osteoarthritis were excluded.³¹

Table 11 Definitions of outcome metric of evaluated AI models

<i>Metric</i>	<i>Formula</i>	<i>Definition</i>
Sensitivity = TP rate	$\frac{TP}{TP+FN}$	Probability of correct positive predictions in actual positives
Specificity = TN rate	$\frac{TN}{TN+FP}$	Probability of correct negative predictions in actual negatives
Precision	$\frac{TP}{TP+FP}$	Probability of correct positive predictions in positive results
Accuracy	$\frac{TP+TN}{AS}$	Probability of correct predictions in total number of predictions

AS, all samples; FN, false-negatives; FP, false-positives; TN, true-negatives; TP, true-positives.

Khanagar et al included in the review studies that use CNN in forensic odontology. DPR can be used in this field to estimate a person's age based on the development of the lower third molar. The results of the studies are promising, which indicates that AI can be helpful in forensic dentistry. CNN was also successfully used to detect vertical root fractures on DPR, showing the high precision of the AI model and gaining a comparable level of performance as the experts. Deep learning can help with the segmentation of anatomical structures as well, for instance, in detecting the proximity of the inferior alveolar nerve to the roots of lower third molars, which is a risk factor for the occurrence of nerve damage. The results of the study were promising. However, further improvement of the system is advised.²⁷ Hung et al included two studies where a support vector machine was used to detect cysts and tumors. The average accuracy of 85.72% indicates that cysts and tumors can be effectively diagnosed using AI techniques.²⁹

Revilla-León et al included 17 studies where AI was applied in implant dentistry. This technology supports clinicians in implant type recognition, predicting osseointegration success, as well as helps to optimize implant designs, minimizing the stress at the implant–bone interface by 36.6% compared with the finite element analysis calculations.²⁶ Chaurasia et al also analyzed the performance of DL models in identifying and classifying dental implant systems (DISs), which may be helpful to avoid unintended iatrogenic complications in case of, e.g. screw loosening or PI. In this systematic review, five studies used only panoramic images in recognizing up to 12 different DISs. The accuracy of these architectures was between 70.8 and 98.2%. Therefore, these DL models can be potentially used to facilitate the decision-making process for dentists.³²

Limitations

Limitations of the evidence: Studies included in the analyzed systematic reviews used different neural networks and performance measurements. Because of this heterogeneity and limited quality of reporting in the studies, comparison of the outcomes was difficult and did not allow the meta-analysis to be performed. It would be recommended for future studies to apply standards like CLAIM—a checklist for AI in medical imaging, or STARD-AI for diagnostic studies using AI models.^{43,44}

There was also a significant variety in the size of training data sets—from dozens to more than a thousand. Theoretically, the larger the data set, the more precise the AI algorithm will be.⁴⁵ Comparing algorithms that differ in such a large amount of training data as well as applying different model structures are another limitations when comparing their effectiveness.

Prados-Privado et al drew attention to the importance of the definition of caries in analyzed studies.

Depending on whether caries was diagnosed according to ICDAS II or defined as a loss of mineralization, the accuracy differed by up to 17%.^{28,46} Unfortunately, most studies did not specify how they described caries lesions.

There was no information in the analyzed systematic reviews about the dental X-ray machines' vendors used in included studies. Various models have different technical specifications, which affect image quality. Optimal selection of image resolution has the potential for increasing NN performance.⁴⁷

The review of Singh et al was disqualified from the quantitative syntheses due to the high risk of bias.²⁴ It turned out to be not systematic, which was manifested by imperfections primarily in the domains identification and selection of studies and data collection and study appraisal. The search was performed using only one database when it is advised to explore multiple databases for a systematic review to identify available literature concerning the analyzed problem adequately.⁴⁸ There is no information if the process of screening titles, abstracts, and full texts of manuscripts was performed independently by at least two reviewers, which minimizes errors in the selection of the studies. The authors did not assess the risk of bias of included articles that could establish transparency of findings and is an essential component of any review.⁴⁹

Limitations of the review process: In this overview of reviews, non-English articles were rejected. Search queries were only in English as well.

Conclusions

According to the results of this overview of reviews, in the years 1988–2023, there was a significant development of information technologies for the analysis of DPRs. The effectiveness of AI algorithms has an upward trend. The latest analyzed AI models achieve high accuracy in detecting caries—91.5%, osteoporosis—89.29%, maxillary sinusitis—87.5%, periodontal bone loss—93.09%, and teeth identification and numbering—93.67%. The detection of periapical lesions is also characterized by high sensitivity (99.95%) and specificity (92%). The above results indicate that AI applications can significantly support dentists. However, due to the small number of heterogeneous source studies synthesized in systematic reviews, the results of this overview should be interpreted with caution. As systematic reviews in AI become outdated quickly, their regular updating is recommended.

Contributors

N.T. Conceptualization; Study design; Provision of study materials and analysis tools; Formal analysis;

Conducting research and investigation processes; Data curation; Writing – original draft preparation; Writing – review & editing; Data presentation K.C. Provision of study materials and analysis tools; Writing – Original Draft Preparation M.C. Study design; Validation; Writing – Original Draft Preparation; Writing – Review & Editing A.B. Conducting research and investigation processes; Data Curation; Writing – Original Draft Preparation Z.N. Validation; Provision of study materials and analysis tools; Writing – Review & Editing

M.S. Conceptualization; Writing – Review & Editing; Supervision; Project Administration.

Data Availability Statement

The protocol of this overview of systematic reviews is available in the Prospective Register of Systematic Reviews (PROSPERO) under number CRD42023416048. All collected and generated data are included in the content of this article.

REFERENCES

1. SITNFlash. The History of Artificial Intelligence. *Science in the News* 2017. Available from: <https://sitn.hms.harvard.edu/flash/2017/history-artificial-intelligence/> (accessed 18 May 2023)
2. Thurzo A, Urbanová W, Novák B, Czako L, Siebert T, Stano P, et al. Where is the artificial intelligence applied in dentistry? *Health Care (Don Mills)* 2022; **10**(7): 1269. <https://doi.org/10.3390/healthcare10071269>
3. IBM. What is Artificial Intelligence (AI)? Available from: <https://www.ibm.com/topics/artificial-intelligence> (accessed 18 May 2023)
4. May M. Eight ways machine learning is assisting medicine. *Nat Med* 2021; **27**: 2–3. <https://doi.org/10.1038/s41591-020-01197-2>
5. Mohammad-Rahimi H, Nadimi M, Rohban MH, Shamsoddin E, Lee VY, Motamedian SR. Machine learning and orthodontics, current trends and the future opportunities: A Scoping review. *Am J Orthod Dentofacial Orthop* 2021; **160**: 170–92. <https://doi.org/10.1016/j.ajodo.2021.02.013>
6. Schmidhuber J. Deep learning in neural networks: an overview. *Neural Netw* 2015; **61**: 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
7. AlmeidaGonçalves M de, Gonçalves A, Capote TS deAM, et al. Panoramic Radiography — Diagnosis of Relevant Structures That Might Compromise Oral and General Health of the Patient. In: *Emerging Trends in Oral Health Sciences and Dentistry [Internet]*. 18 May 2023; Available from: <https://www.intechopen.com/chapters/47895> (accessed 18 May 2023)
8. Ghassemzadeh S, Sbricoli L, Frigo AC, Bacci C. Incidental findings detected with panoramic radiography: prevalence calculated on a sample of 2017 cases treated at a major Italian trauma and cancer centre. *Oral Radiol* 2021; **37**: 507–17. <https://doi.org/10.1007/s11282-020-00488-1>
9. Ding H, Wu J, Zhao W, Matinlinna JP, Burrow MF, Tsoi JKH. Artificial intelligence in dentistry—A review. *Front Dent Med* 2023; **4**. <https://doi.org/10.3389/fdmed.2023.1085251>
10. Choi E, Lee S, Jeong E, Shin S, Park H, Youm S, et al. Artificial intelligence in positioning between Mandibular third molar and inferior alveolar nerve on panoramic radiography. *Sci Rep* 2022; **12**(1): 2456. <https://doi.org/10.1038/s41598-022-06483-2>
11. Pollock M, Fernandes RM, Pieper D, Tricco AC, Gates M, Gates A, et al. Preferred reporting items for Overviews of reviews (PRIOR): a protocol for development of a reporting guideline for Overviews of reviews of Healthcare interventions. *Syst Rev* 2019; **8**(1): 335. <https://doi.org/10.1186/s13643-019-1252-9>
12. Gates M, Gates A, Pieper D, Fernandes RM, Tricco AC, Moher D, et al. Reporting guideline for Overviews of reviews of Healthcare interventions: development of the PRIOR statement. *BMJ* 2022; **378**: e070849. <https://doi.org/10.1136/bmj-2022-070849>
13. Amir-Behghadami M, Janati A. Population, intervention, comparison, outcomes and study (PICOS) design as a framework to formulate eligibility criteria in systematic reviews. *Emerg Med J* 2020; **37**: 387. <https://doi.org/10.1136/emered-2020-209567>
14. BASE. Bielefeld Academic Search Engine | What is BASE? Available from: <https://www.base-search.net/about/en/index.php> (accessed 4 May 2023)
15. Google Scholar. Available from: <https://scholar.google.com/> (accessed 18 May 2023)
16. Gusenbauer M. Search where you will find most: comparing the disciplinary coverage of 56 Bibliographic databases. *Scientometrics* 2022; **127**: 2683–2745. <https://doi.org/10.1007/s11192-022-04289-7>
17. ACM. The ACM Guide to Computing Literature. Internet. Available from: <https://libraries.acm.org/digital-library/acm-guide-to-computing-literature> (accessed 4 May 2023)
18. NCBI. About. Available from: <https://pubmed.ncbi.nlm.nih.gov/about/> (accessed 4 May 2023)
19. Ouzzani M, Hammady H, Fedorowicz Z, Elmagarmid A. Rayyan—a web and mobile App for systematic reviews. *Syst Rev* 2016; **5**(1): 210. <https://doi.org/10.1186/s13643-016-0384-4>
20. Bristol U of ROBIS tool. University of Bristol. Available from: <https://www.bristol.ac.uk/population-health-sciences/projects/robis/robis-tool/> (accessed 18 May 2023)
21. Mohammad-Rahimi H, Motamedian SR, Rohban MH, Krois J, Uribe SE, Mahmoudinia E, et al. Deep learning for Caries detection: A systematic review. *J Dent* 2022; **122**: 104115. <https://doi.org/10.1016/j.jdent.2022.104115>
22. Revilla-León M, Gómez-Polo M, Barmak AB, Inam W, Kan JYK, Kois JC, et al. Artificial intelligence models for diagnosing Gingivitis and Periodontal disease: A systematic review. *J Prosthet Dent* 2022. <https://doi.org/10.1016/j.prosdent.2022.01.026>
23. Sadr S, Mohammad-Rahimi H, Motamedian SR, Zahedrozezar S, Motie P, Vinayahalingam S, et al. Deep learning for detection of periapical Radiolucent lesions: A systematic review and meta-analysis of diagnostic test accuracy. *J Endod* 2023; **49**: 248–61. <https://doi.org/10.1016/j.joen.2022.12.007>
24. Singh NK, Raza K. Progress in deep learning-based dental and Maxillofacial image analysis: A systematic review. *Expert Systems with Applications* 2022; **199**: 116968. <https://doi.org/10.1016/j.eswa.2022.116968>
25. Umer F, Habib S, Adnan N. Application of deep learning in teeth identification tasks on panoramic Radiographs. *Dentomaxillofac Radiol* 2022; **51**(5): 20210504. <https://doi.org/10.1259/dmfr.20210504>
26. Revilla-León M, Gómez-Polo M, Vyas S, Barmak BA, Galluci GO, Att W, et al. Artificial intelligence applications in implant dentistry: A systematic review. *The Journal of Prosthetic Dentistry* 2023; **129**: 293–300. <https://doi.org/10.1016/j.prosdent.2021.05.008>
27. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *J Dent Sci* 2021; **16**: 508–22. <https://doi.org/10.1016/j.jds.2020.06.019>
28. Prados-Privado M, García Villalón J, Martínez-Martínez CH, Ivorra C, Prados-Frutos JC. Dental Caries diagnosis and detection using neural networks: A systematic review. *J Clin Med* 2020; **9**(11): 3579. <https://doi.org/10.3390/jcm9113579>

29. Hung K, Montalvo C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and Maxillofacial Radiology: A systematic review. *Dentomaxillofacial Radiology* 2020; **49**: 20190107. <https://doi.org/10.1259/dmfr.20190107>
30. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent* 2019; **49**: 1–7. <https://doi.org/10.5624/isd.2019.49.1.1>
31. Almășan O, Kui A, Duncea I, Manea A, Buduru S. Temporomandibular joint disk Displacements in class II malocclusion and Cervical spine alterations: systematic review and report of a Hypodivergent case with MRI bone and soft tissue changes. *Life (Basel)* 2022; **12**(6): 908. <https://doi.org/10.3390/life12060908>
32. Chaurasia A, Namachivayam A, Koca-Ünsal RB, Lee JH. Deep-learning performance in identifying and classifying dental implant systems from dental imaging: a systematic review and meta-analysis. *J Periodontal Implant Sci* 2023. <https://doi.org/10.5051/jpis.2300160008>
33. Hildebolt CF, Vannier MW. Automated classification of Periodontal disease using Bitewing Radiographs. *J Periodontol* 1988; **59**: 87–94. <https://doi.org/10.1902/jop.1988.59.2.87>
34. Sensitivity and Specificity of Machine learning. Internet. *Deepchecks* Available from: <https://deepchecks.com/glossary/sensitivity-and-specificity-of-machine-learning/>
35. Karamifar K, Tondari A, Saghir MA. Endodontic periapical lesion: an overview on the etiology, diagnosis and current treatment modalities. *Eur Endod J* 2020; **5**: 54–67. <https://doi.org/10.14744/eej.2020.42714>
36. Pihlstrom BL, Michalowicz BS, Johnson NW. Periodontal diseases. *The Lancet* 2005; **366**: 1809–20. [https://doi.org/10.1016/S0140-6736\(05\)67728-8](https://doi.org/10.1016/S0140-6736(05)67728-8)
37. Wróbel K, Sikora M, Chęciński M, Jas M, Chlubek D. Medication-related Osteonecrosis of the jaw—A continuing issue. *Applied Sciences* 2021; **11**: 7781. <https://doi.org/10.3390/app11177781>
38. Branch NSC, Osteoporosis O. National Institute of Arthritis and Musculoskeletal and Skin Diseases. *NIAMS* 2017. Available from: <https://www.niams.nih.gov/health-topics/osteoporosis> (accessed 18 May 2023)
39. Tassoker M. What are the risk factors for Maxillary sinus Pathologies? A CBCT study. *Oral Radiol* 2020; **36**: 80–84. <https://doi.org/10.1007/s11282-019-00382-5>
40. Southern California Sinus Institute. The Dangers Of Sinusitis And Sinus Infections For Untreated Patients. Internet. 2021. Available from: <https://www.socalsinus.com/the-dangers-of-sinusitis-and-sinus-infections/> (accessed 20 May 2023)
41. Schwendicke F, Tzschoppe M, Paris S. Radiographic Caries detection: A systematic review and meta-analysis. *J Dent* 2015; **43**: 924–33. <https://doi.org/10.1016/j.jdent.2015.02.009>
42. Kalladka M, Quek S, Heir G, Eliav E, Mupparapu M, Viswanath A. Temporomandibular joint osteoarthritis: diagnosis and long-term conservative management: A topic review. *J Indian Prosthodont Soc* 2014; **14**: 6–15. <https://doi.org/10.1007/s13191-013-0321-3>
43. Mongan J, Moy L, Kahn CE. Checklist for artificial intelligence in medical imaging (CLAIM): A guide for authors and reviewers. *Radiology: Artificial Intelligence* 2020; **2**: e200029. <https://doi.org/10.1148/ryai.2020200029>
44. Sounderajah V, Ashrafian H, Golub RM, Shetty S, De Fauw J, Hooft L, et al. Developing a reporting guideline for artificial intelligence-centred diagnostic test accuracy studies: the STARD-AI protocol. *BMJ Open* 2021; **11**(6): e047709. <https://doi.org/10.1136/bmjopen-2020-047709>
45. Brownlee J. Impact of Dataset Size on Deep Learning Model Skill And Performance Estimates. *MachineLearningMastery.com* 2019. Available from: <https://machinelearningmastery.com/impact-of-dataset-size-on-deep-learning-model-skill-and-performance-estimates/> (accessed 22 Jun 2023)
46. Dikmen B. Icdas II criteria (International Caries detection and assessment system). *J Istanbul Univ Fac Dent* 2015; **49**: 63–72. <https://doi.org/10.17096/jiufd.38691>
47. Sabottke CF, Spieler BM. The effect of image resolution on deep learning in radiography. *Radiol Artif Intell* 2020; **2**(1): e190015. <https://doi.org/10.1148/ryai.2019190015>
48. Bramer WM, Rethlefsen ML, Kleijnen J, Franco OH. Optimal database combinations for literature searches in systematic reviews: a prospective exploratory study. *Syst Rev* 2017; **6**(1): 245. <https://doi.org/10.1186/s13643-017-0644-y>
49. Whiting P, Savović J, Higgins JPT, Caldwell DM, Reeves BC, Shea B, et al. ROBIS: A new tool to assess risk of bias in systematic reviews was developed. *J Clin Epidemiol* 2016; **69**: 225–34. <https://doi.org/10.1016/j.jclinepi.2015.06.005>



Article

Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study

Natalia Turosz ^{1,*} , Kamila Chęcińska ² , Maciej Chęciński ^{3,*} , Iwo Rutański ⁴ , Marcin Sielski ¹
and Maciej Sikora ^{1,5}

¹ Department of Maxillofacial Surgery, Hospital of the Ministry of Interior, Wojska Polskiego 51, 25-375 Kielce, Poland; marcinsielski@gazeta.pl (M.S.); sikora-maciej@wp.pl (M.S.)

² Department of Glass Technology and Amorphous Coatings, Faculty of Materials Science and Ceramics, AGH University of Science and Technology, Mickiewicza 30, 30-059 Cracow, Poland; checinska@agh.edu.pl

³ Department of Oral Surgery, Preventive Medicine Center, Komorowskiego 12, 30-106 Cracow, Poland

⁴ Optident sp. z o.o., ul. Eugeniusza Kwiatkowskiego 4, 52-326 Wrocław, Poland; iworutanski@gmail.com

⁵ Department of Biochemistry and Medical Chemistry, Pomeranian Medical University, Powstańców Wielkopolskich 72, 70-111 Szczecin, Poland

* Correspondence: natalia.turosz@gmail.com (N.T.); maciej@checinscy.pl (M.C.)

Abstract: Background: The application of artificial intelligence (AI) is gaining popularity in modern dentistry. AI has been successfully used to interpret dental panoramic radiographs (DPRs) and quickly screen large groups of patients. This cross-sectional study aimed to perform a population-based assessment of the oral health status and treatment needs of the residents of Kielce, Poland, and the surrounding area based on DPR analysis performed by a high-accuracy AI algorithm trained with over 250,000 radiographs. **Methods:** This study included adults who had a panoramic radiograph performed, regardless of indications. The following diagnoses were used for analysis: (1) dental caries, (2) missing tooth, (3) dental filling, (4) root canal filling, (5) endodontic lesion, (6) implant, (7) implant abutment crown, (8) pontic crown, (9) dental abutment crown, and (10) sound tooth. The study sample included 980 subjects. **Results:** The patients had an average of 15 sound teeth, with the domination of the lower dental arch over the upper one. The most commonly identified pathology was dental caries, which affected 99% of participants. A total of 67% of patients underwent root canal treatment. Every fifth endodontically treated tooth presented a periapical lesion. Of study group members, 82% lost at least one tooth. Pontics were identified more often (9%) than implants (2%) in replacing missing teeth. **Conclusions:** DPR assessment by AI has proven to be an efficient method for population analysis. Despite recent improvements in the oral health status of Polish residents, its level is still unsatisfactory and suggests the need to improve oral health. However, due to some limitations of this study, the results should be interpreted with caution.

Keywords: artificial intelligence; dental radiography; panoramic radiography; public health dentistry; DMF Index



Citation: Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. *J. Clin. Med.* **2024**, *13*, 3686. <https://doi.org/10.3390/jcm13133686>

Academic Editors: Antonella Polimeni and Iole Volza

Received: 30 May 2024

Revised: 20 June 2024

Accepted: 21 June 2024

Published: 25 June 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Background

Dental panoramic radiography (DPR), also called orthopantomography, is the most prevalent extraoral technique of dental imaging, enabling the detection of numerous physiological and pathological conditions. It provides a two-dimensional representation of all teeth, the mandible, the maxilla including maxillary sinuses, and temporomandibular joints [1,2]. Many structures imaged simultaneously allow lower radiation doses to detect different disorders. Panoramic radiography is the gold standard in radiological diagnostics. However, it also has limitations. It does not provide detailed information about each tooth but gives an initial oral health assessment. Moreover, a comprehensive analysis is

time-consuming and vulnerable to bias due to the varying experiences of the evaluators [3]. High-quality radiographs are essential for accurate human diagnoses and for developing machine learning models that can assist dentists in their practice [4].

Artificial intelligence (AI) has revolutionized healthcare in recent years through early pathology detection and personalized treatments. AI-driven tools are increasingly used in dentistry as they present high performance in detecting and segmenting teeth [5]. Their effectiveness in DPR analysis has seen an upward trend, achieving an accuracy of around 90% [6]. Data-driven AI can assist medical professionals in making time-sensitive decisions [7]. The average time for a dentist to analyze a DPR is over 8 min [8]. For AI models, the exact time depends on the type of software used, and in the case of 2D images, the report is generated up to 10 s [9,10]. Automated methods also eliminate errors associated with clinicians' mental and eye fatigue, providing superior healthcare quality [5,7]. They can efficiently detect features almost invisible to the human eye. Studies show that AI-based software provides good performance in detecting root canal fillings, crowns, and implants, as well as in predicting prognosis and planning patient-specific treatment [7,11]. This technology can be very useful in population-wide surveillance to perform screening tests, especially in rural communities with a shortage of medical professionals [7]. Despite the great potential of AI applications, their further development and human supervision are still needed [12,13]. Clinicians play a crucial role in ensuring data protection and the ethical use of AI while being able to refine the technology [14].

Screening for oral health needs is commonly performed [15,16]. However, no publications were found where the DMF index score was used to measure a total caries experience in Kielce or the Świętokrzyskie Voivodeship, and no study was identified where AI was used to analyze X-rays and calculate DMF scores. Population screening based on physical examination is expensive and time-consuming. Some pathological changes, such as caries on the proximal surface or periapical lesions, can be difficult to detect only by visual examination. A panoramic radiograph, which supplements a physical exam, could serve as a valuable alternative for gathering information about patients' oral health.

Artificial intelligence allows the automatic evaluation of DPRs, achieving a high accuracy of about 90% in detecting caries, periodontal bone loss, osteoporosis, maxillary sinusitis, and teeth identification and numbering. The detection of periapical lesions is also characterized by high specificity and sensitivity above 90% [6]. AI algorithms can be used in population-wide surveillance as they perform analyses several times faster than specialists [7,8]. Therefore, it seems reasonable to use AI-based software to perform DPR analyses and assess the oral health status of a larger group of patients.

This cross-sectional study aims to perform a population-based assessment of the oral health status and treatment needs of the inhabitants of Kielce, Poland, and the surrounding area based on an AI-driven DPR analysis. The prevalence and location of decay, dental fillings, root canal fillings, endodontic lesions, implants, implant and dental abutment crowns, pontic crowns, and missing teeth will be investigated.

2. Methods

2.1. Study Design

This research was designed as a single-arm cross-sectional study following the STROBE Statement: guidelines for reporting observational studies (Strengthening the Reporting of Observational Studies in Epidemiology) and the principles of the Declaration of Helsinki and was approved by the Bioethics Committee in Kielce at the Świętokrzyska Chamber of Physicians (approval number: 2.3/2023). The study protocol was developed based on the STROBE checklist. Characteristics of the study design are presented in Table 1 [17].

Table 1. Study design.

Study Design Feature	Applied Study Design
Direction of data collection	Retrospective
Number of gates (sets of eligibility criteria)	Double gate (AI, human)
Participant sampling method	Consecutive
Method of allocating participants to index tests	Each participant received all index tests
Number of reference standards	Single test standard
Limited verification	Full verification (not limited)

2.2. Setting

The patients included in this study were admitted between September 2022 and June 2023 to the radiology department located in Kielce, a city in southern Poland. The department is located near communication hubs serving public transport within Kielce County, a unit of territorial administration that includes the city of Kielce and surrounding villages, with approximately 207,000 inhabitants. The radiology department performs both insurance-covered and commercial medical procedures. This allows for a versatile range of services that meet the diverse needs of all patients. High-resolution panoramic radiographs were taken using the device Carestream CS9600 with adjustable exposure conditions set to 60–90 kV and 2–15 mA. Then, AI Insights software (version CSI8 server ver. 3.12; Carestream Health, Rochester, NY, USA) analyzed panoramic X-ray images in June 2023 after anonymizing the data. The algorithm is integrated with CS Imaging v8 software, thanks to which we could quickly retrieve an automated dental chart for each DPR we had. The algorithm was trained with over 250,000 panoramic radiographs previously described by professional radiologists. The proven accuracy of AI in image classification is 99%, and the accuracy in detecting periapical lesions on panoramic radiographs is up to 95% [18,19]. AI Insights assesses the digital image with one click in seconds, displaying the findings and highlighting them in color directly on the image (Figure 1). The user can modify the description, e.g., by selecting caries that the program did not recognize. It is also possible to generate a report in PDF format with basic information about the patient and radiation doses used.




Figure 1. The view of DPR analysis performed by AI.

2.3. Participants

The eligibility criteria are presented in Table 2. All patients had an X-ray taken on the day of admission to the radiology department. Only DPRs that met appropriate quality standards, such as clearly visible teeth and outlines of the jawbone, horizontal or slightly raised upwards occlusal plane, were qualified for analysis. DPRs with artifacts and positioning imperfections were excluded.

Table 2. Inclusion and exclusion criteria.

Domain	Criteria for Inclusion	Criteria for Exclusion
Indications	Typical indications for DPR imaging confirmed by a written referral from the dentist or physician (both screening tests and tests performed for treatment purposes were allowed)	Not applicable
Dentition	Not applicable	Patients with mixed or primary dentition
Age	Patients of any age	No age restrictions applied due to the limitation in the dentition category
Sex	All genders	No gender restrictions
Quality of DPRs	Correctly performed DPR in accordance with the criteria of the Polish Ministry of Health [20]	AI error resulting in no results or partial results

2.4. Variables

The variables presented in Table 3 were used for analysis, taking into account their positions. To describe the results of this study, two dental notation systems were applied: FDI World Dental Federation (FDI) notation and the Universal Numbering System (UNS), also called the “American system”. The adopted methodology classified teeth with pathologies not listed in Table 3 as sound, e.g., teeth with dental developmental anomalies or marginal periodontal loss.

Table 3. Variables.

Abbreviation	Name of the Variable	Description
D	Dental caries	Presence of at least one cavity (cariou or non-cariou) in a given tooth
M	Missing tooth	Absence of any tooth remnants in a given location
F	Dental filling	Presence of at least one filling in a given tooth
R	Root canal filling	Presence of at least one filled root canal (completely or partially)
E	Endodontic lesion	Periapical radiological radiolucency primarily suggesting periapical inflammation
I	Implant	Radiological shading in the shape of an intraosseous dental implant
A	Implant abutment crown	Prosthetic crown based on an implant

Table 3. *Cont.*

Abbreviation	Name of the Variable	Description
P	Pontic crown	Prosthetic bridge span (prosthetic crown without direct support)
C	Dental abutment crown	A prosthetic crown supported on a tooth
S	Sound tooth	A tooth without signs of the above-mentioned pathologies or signs of the above-mentioned treatment methods

2.5. Data Sources/Measurement

The source of the data was a series of panoramic X-ray images taken using Carestream CS9600. For the automatic analysis, we used a dedicated AI algorithm, available since 2022, which was trained with over 250,000 DPRs analyzed by medical professionals to detect dental caries, endodontic lesions, fillings, different types of prosthetic restorations, and implants.

2.6. Bias

The sample was selected from consecutive patients, which resulted in a random pattern of values of the evaluated variables. An evaluation in an AI-driven program was performed by a single investigator and was always conducted in the same mode. Apart from sampling, there was no other risk of bias in the AI evaluation.

2.7. Study Size

According to the WHO sample size calculator for a 1.96 level of confidence (a 95% confidence interval), 0.05 margin of error, unknown baseline levels of indicators, simple random sample (design effect = 1), and lack of subgroups, the appropriate sample size should be 384.16 subjects. We determined a sample size of 1025 participants due to the research budget.

2.8. Quantitative Variables

The values of the variables (1) dental caries, (2) missing tooth, (3) dental filling, (4) root canal filling, (5) endodontic lesion, (6) implant, (7) implant abutment crown, (8) pontic crown, (9) dental abutment crown, and (10) sound tooth were grouped depending on the tooth number, according to the FDI World Dental Federation notation and the Universal Numbering System.

2.9. Statistical Methods

The acquired data were assessed in the Excel program (Microsoft Corporation, Redmond, WA, USA). Point prevalence was used to measure the frequency of studied variables in the randomly selected sample from the population of Kielce County. It is the proportion of subjects that have the characteristic at a given moment in time [21,22]. The Pearson correlation coefficients, which give the strength of the linear relationship between two variables, were also calculated and presented in a correlation matrix. The formula value lies between -1 and 1 , which correspond to perfect negative and perfect positive linear relationships, respectively. If the value is zero, then the variables have no correlation [23].

3. Results

3.1. Participants

This study involved 1025 patients. The radiographs were analyzed by AI Insights software (version CSI8 server ver. 3.12; Carestream Health, Rochester, NY, USA), resulting in 980 correctly performed analyses. Data on 45 patients were not obtained due to user error while using the AI program ($n = 10$) or them not meeting the inclusion criteria ($n = 35$) because the DPRs were analyzed with mixed dentition (Figure 2).




Figure 2. Flowchart of patient selection.

3.2. Descriptive Data

For DPR analysis, 980 patients (568 women and 412 men) were included in this study. Figure 3 presents the age structure of participants. The male-to-female ratio was 0.73. The average age of patients was 35.6 (SD = 15.0; median = 33). The oldest in the study sample was a man of 77 years and a woman of 81 years. The patients were grouped into 15 age ranges for demographic assessment, with 20–24, 25–29, 30–34, and 35–39 predominating. The loss of all deciduous dentition determined the lower age limit. The youngest patient in both the male and female groups was 11 years old.




Figure 3. The age structure of the included participants.

3.3. Outcome Data

Tables 4 and 5 present the results of the DPR analysis of the 980 patients. Of all the 32 teeth positions in the 980 patients (31,360 items), the most common diagnosis was a sound tooth. In the study population, sound teeth were identified 16% more often in the lower arch than in the upper arch. The upper arch was more likely to have caries, dental fillings, and root canal fillings than the lower arch, by 18%, 12%, and 8%, respectively. Periapical lesions in both arches occurred at similar levels. Tooth 16 was most often affected by dental caries and filled. First molars were also most frequently treated endodontically and had periapical lesions. Prosthetic restorations were far more common in the upper arch, with crowns almost four times more frequent than pontics. Implants occurred rarely and were located mainly in the upper arch. Patients had an average of five missing teeth.

Table 4. Total number of findings, average findings per patient, and number of findings in the upper and lower arch in the included participants of this study.

Finding	Total Number	Average per Patient	Standard Deviation	Upper Arch	Lower Arch
Sound tooth	14,533	14.83	6.99	6141	8392
Dental filling	8882	9.06	4.80	4942	3940
Dental caries	5975	6.10	3.11	3526	2449
Missing tooth	5066	5.17	5.68	2714	2352
Root canal filling	1918	1.96	2.18	1227	691
Endodontic lesion	882	0.90	1.19	447	435
Dental abutment crown	806	0.82	1.76	596	210
Pontic crown	217	0.22	0.89	171	46
Implant	46	0.05	0.38	39	7
Implant abutment crown	28	0.03	0.32	24	4

Table 5. Maximum and minimum number of occurrences of each finding in the included participants of this study.

	The Most Common Tooth (Frequency) FDI/UNS	The Least Common Tooth (Frequency) FDI/UNS
Dental caries	16/3 (432 times)	31/24 (7 times)
Missing teeth	28/16 (385 times)	33/22 (8 times)
Dental filling	16/3 (538 times)	31/24 (51 times)
Root canal filling	26/14 (141 times)	28/16, 42/26 (8 times)
Endodontic lesion	46/30 (89 times)	31/24 (3 times)
Dental abutment crown	21/9 (62 times)	18/1 (2 times)
Pontic abutment crown	14/5, 24/12 (27 times)	18/1, 17/2, 28/16, 33/22, 32/2, 41/25–44/27 (0 times)
Implant abutment crown	12/7, 21/9 (4 times)	18/1, 17/2, 27/15–44/28, 47/31, 48/32 (0 times)
Implant	14/5 (6 times)	18/1, 17/2, 28/16–37/18, 34/21–44/28, 47/31, 48/32 (0 times)
Sound tooth	42/26 (892 times)	46/30 (53 times)

3.4. Main Results

Figures 4–9 present the distribution of (1) decayed, (2) missing, and (3) filled teeth, (4) root canal fillings, (5) endodontic lesions, (6) sound teeth, (7) dental, and (8) implant abutment crowns, (9) pontic crowns, and (10) implants in the upper and lower arch. The values of point prevalence for consecutive teeth do not add up to 100% because a given tooth may have several diagnoses. The most common sound tooth in the maxillary arch was 13/6, and in the mandibular arch, teeth in the anterior segment 33/22–43/27 usually did not present any pathological conditions. Tooth 16/3 was the most frequently affected by caries and filled. The most common missing teeth were third molars. Periapical lesions occurred most often in the first molars. Dental abutment crowns mostly restored upper incisors and first premolars.




Figure 4. Distribution of decayed, missing, and filled teeth, root canal fillings, endodontic lesions, and sound teeth according to teeth positions in the upper-right quadrant.




Figure 5. Distribution of decayed, missing, and filled teeth, root canal fillings, endodontic lesions, and sound teeth according to teeth positions in the upper-left quadrant.




Figure 6. Distribution of decayed, missing, and filled teeth, root canal fillings, endodontic lesions, and sound teeth according to teeth positions in the lower-right quadrant.




Figure 7. Distribution of decayed, missing, and filled teeth, root canal fillings, endodontic lesions, and sound teeth according to teeth positions in the lower-left quadrant.




Figure 8. Distribution of dental and implant abutment crowns, pontic crowns, and implants according to teeth positions in the upper arch.




Figure 9. Distribution of dental and implant abutment crowns, pontic crowns, and implants according to teeth positions in the lower arch.

3.5. Subgroup Analyses

The analysis was also performed in four age groups: up to 18 years old, 19–40, 41–60, and over 60 years old (Figure 10). Tables 6–9 present the analysis results in consecutive age groups, considering the most common and rarest teeth with a given finding.




Figure 10. The age structure of participants in consecutive groups.

Table 6. Characteristics of participants under 18 years old.

	The Most Common Tooth (Frequency) FDI/UNS	The Least Common Tooth (Frequency) FDI/UNS	Average per Patient
Dental caries	36/19 (57 times)	13/6, 38/17, 33/22–43/27, 48/32 (0 times)	4.01
Missing teeth	18/1, 28/16, 48/32 (11 times)	15/4, 13/6, 11/8–22/10, 37/18, 33/22–43/27 (0 times)	0.79
Dental filling	16/3, 36/19 (60 times)	18/1, 28/16, 38/17 (0 times)	4.5
Root canal filling	46/30 (6 times)	18/1, 17/2, 14/5, 13/6, 11/8, 22/10, 23/11, 25/13, 28/16, 38/17, 35/20–44/28, 47/31, 48/32 (0 times)	0.27

Table 6. Cont.

	The Most Common Tooth (Frequency) FDI/UNS	The Least Common Tooth (Frequency) FDI/UNS	Average per Patient
Endodontic lesion	46/30 (7 times)	18/1, 17/2, 13/6, 24/12, 27/15, 28/16, 33/22–43/27, 48/32 (0 times)	0.44
Dental abutment crown	16/3, 26/14 (2 times)	18/1, 17/2, 14/5, 13/6, 11/8, 22/10, 23/11, 25/13, 27/15–37/18, 35/20–45/29, 47/31, 48/32 (0 times)	0.09
Pontic abutment crown	1 (1 time)	18/1–12/7, 21/9–48/32 (0 times)	0.01
Implant abutment crown	0	0	0
Implant	0	0	0
Sound tooth	13/6, 42/26 (110 times)	36/19 (27 times)	24.5

Table 7. Characteristics of participants between 19 and 40 years old.

	The Most Common Tooth (Frequency) FDI/UNS	The Least Common Tooth (Frequency) FDI/UNS	Average per Patient
Dental caries	16/3 (270 times)	41/25 (2 times)	6.6
Missing teeth	28/16, 36/19 (157 times)	42/26 (1 time)	3.2
Dental filling	16/3 (352 times)	32/23, 42/26 (19 times)	9.9
Root canal filling	36/19 (83 times)	33/22 (0 times)	1.8
Endodontic lesion	46/30 (58 times)	43/27 (0 times)	0.9
Dental abutment crown	25/13 (26 times)	38/17, 33/22, 41/25, 42/26, 48/32 (0 times)	0.4
Pontic abutment crown	24/12 (9 times)	18/1, 17/2, 13/6, 27/15–35/20, 33/22–48/32 (0 times)	0.1
Implant abutment crown	21/9 (2 times)	18/1–15/4, 13/6, 11/8, 22/10–44/28, 47/31, 48/32 (0 times)	0
Implant	14/5 (3 times)	18/1–15/4, 13/6, 11/8, 22/10, 23/11, 25/13, 27/15–37/18, 35/20–44/28, 47/31, 48/32 (0 times)	0
Sound tooth	42/26 (525 times)	46/30 (24 times)	16

Table 8. Characteristics of participants between 41 and 60 years old.

	The Most Common Tooth (Frequency) FDI/UNS	The Least Common Tooth (Frequency)	Average per Patient
Dental caries	17/2, 16/3 (91 times)	31/24 (2 times)	6.2
Missing teeth	36/19 (163 times)	33/22 (3 times)	8.9
Dental filling	17/2 (131 times)	31/24 (15 times)	9.9
Root canal filling	26/14 (44 times)	32/23, 41/25, 48/32 (3 times)	2.9
Endodontic lesion	46/30 (23 times)	31/24, 48/32 (2 times)	1
Dental abutment crown	12/7 (31 times)	18/1, 28/16 (1 time)	1.7

Table 8. Cont.

	The Most Common Tooth (Frequency) FDI/UNS	The Least Common Tooth (Frequency)	Average per Patient
Pontic abutment crown	14/5 (17 times)	18/1, 17/2, 28/16, 33/22, 32/23, 41/25–43/27 (0 times)	0.5
Implant abutment crown	14/5, 12/7, 21/9, 22/10, 46/30 (2 times)	18/1, 17/2, 13/6, 23/11, 27/15–45/29, 47/31, 48/32 (0 times)	0.1
Implant	15/4, 14/5, 12/7, 22/10, 26/14, 46/30 (3 times)	18/1, 17/2, 13/6, 28/16–36/19, 34/21–45/29, 47/31, 48/32 (0 times)	0.1
Sound tooth	42/26 (216 times)	46/30 (0 times)	9.6

Table 9. Characteristics of participants over 60 years old.

	The Most Common Tooth (Frequency) FDI/UNS	The Least Common Tooth (Frequency)	Average per Patient
Dental caries	13/6 (21 times)	38/17 (0 times)	4.9
Missing teeth	38/17 (58 times)	33/22 (2 times)	15
Dental filling	45/29 (26 times)	38/17 (3 times)	6.5
Root canal filling	35/20 (14 times)	28/16, 38/17 (0 times)	2.4
Endodontic lesion	25/13, 37/18, 47/31(5 times)	13/6, 11/8, 38/17, 32/23, 31/24 (0 times)	0.8
Dental abutment crown	15/4, 12/7 (13 times)	18/1, 28/16, 38/17, 32/23, 41/25, 42/26 (0 times)	2.4
Pontic abutment crown	24/12 (6 times)	18/1, 17/2, 28/16–37/18, 35/20, 33/22–43/27, 48/32 (0 times)	0.7
Implant abutment crown	16/3, 13/6, 12/7, 22/10, 23/11, 26/14 (1 time)	18/1, 17/2, 15/4, 14/5, 11/8, 21/9, 24/12, 25/13, 27/15–48/32 (0 times)	0.1
Implant	16/3, 13/6, 12/7, 22/10, 23/11, 26/14 (1 time)	18/1, 17/2, 15/4, 14/5, 11/8, 21/9, 24/12, 25/13, 27/15–48/32 (0 times)	0.1
Sound tooth	32/23, 43/27 (42 times)	37/18, 36/19 (0 times)	6.6

3.6. Other Analyses

An analysis of the relationship between the presence of periapical lesions and root canal treatment was also performed. The examined material included 1918 (7%) endodontically treated teeth out of all 26,294 teeth identified as present. In the group of teeth after or during root canal treatment, there were 360 (19%) cases of periapical radiological radiolucency. The correlation coefficient between endodontic treatment and the presence of periapical radiolucency was 0.23. Among the teeth with identified periapical radiolucency, 552 (59%) of 882 had no evidence of endodontic treatment.

Table 10 presents the correlation matrix of the analyzed variables. A high positive correlation (>0.7) occurred between the missing teeth and age and between the presence of implants and implant abutment crowns. In this study, 61% of the implants had dental crowns attached at the time of exposure. A moderate positive correlation (0.5–0.7) was found between pontic crowns and dental abutment crowns.

Table 10. A correlation matrix. Correlation coefficients with absolute values greater than or equal to 0.5 are marked with an asterisk.

	Age	D	M	F	R	E	I	A	P	C
Age										
D	0.01									
M	0.71 *	−0.12								
F	0.09	0.38	−0.21							
R	0.35	0.27	0.15	0.39						
E	0.12	0.37	0.08	0.01	0.23					
I	0.12	−0.06	0.06	−0.06	0.12	−0.06				
A	0.10	−0.08	0.05	−0.06	0.10	−0.05	0.88 *			
P	0.29	−0.04	0.10	−0.10	0.19	0.01	0.27	0.32		
C	0.44	0.02	0.23	−0.04	0.44	0.08	0.28	0.26	0.63 *	

D—dental caries, M—missing teeth, F—dental filling, R—root canal filling, E—endodontic lesion, I—implant, A—implant abutment crown, P—pontic crown, C—dental abutment crown.

4. Discussion

4.1. AI Software

The use of AI algorithm optimized the work of clinicians and validated their evaluation of DPRs. According to our calculations, the average time for an equally detailed analysis performed by a dentist is approximately 4 min, while the algorithm performs it in seconds. This shows that using new technologies can boost practice performance. The integration of algorithm into the existing workflow is seamless. Color-coded findings facilitate image reviews and communication with patients who better understand their treatment needs. Consequently, modern AI tools help build trust between practitioners and patients. Thanks to additional analyses, especially inexperienced dentists feel more confident, reducing undiagnosed cases and making better clinical decisions [24].

4.2. Dental Caries

Dental caries, the most prevalent disease worldwide, was detected in 973 out of 980 included patients (99%). No carious lesions were detected in only seven participants of this study. According to the latest official report from 2021, the prevalence of caries in Poland is almost 100% in the adult population [16]. A significant relationship was found between the dental caries and gender [16]. In our study, the largest number of decayed teeth (19 teeth) was detected in a 35-year-old woman. The most common caries location was tooth FDI 16/UNS 3 (432 teeth) and the rarest was FDI 31/UNS 24 (7 teeth). These teeth were also filled the most frequently and least frequently, respectively. Rarely, caries appeared in the lower front teeth, FDI 34–44/UNS 21–28 (less than 100 teeth). Tooth FDI 42/UNS 26 was the most common healthy tooth, with no pathology or restoration present. This result coincides with other studies showing that the maxillary and mandibular molars are the most susceptible to caries, while the mandibular central incisors are the least susceptible [25,26]. Hassan et al. revealed the mesial surface of the maxillary permanent first molar is more prone to dental caries than the distal one [27]. Caries is also more prevalent in the upper arch than in the lower arch, which was confirmed in this research: 59% of dental caries lesions occurred in the upper arch and 41% in the lower arch [25].

4.3. Missing Teeth

In the research material, the most frequently missing teeth were (1) FDI 28/UNS 16 (385 times), (2) FDI 36/UNS 19 (379 times), (3) FDI 18/UNS 1 (375 times), (4) FDI 48/UNS 32 (360 times), and (5) FDI 38/UNS 17 (359 times). The least frequently missing tooth was FDI 33/UNS 22 (8 times). There are various causes of tooth loss, such as dental

caries, periodontal disease, trauma, failed endodontic treatment, incorrect position, or tooth agenesis (its congenital absence) [28,29]. In the study of Scheiwiller et al., the prevalence of 50.8% for third-molar agenesis occurred in the group of patients with agenesis of teeth other than the third molar, which suggests that third molars are more vulnerable to genetic factors associated with tooth agenesis. An evolutionary trend toward reduced molar number is probable [29]. Some orthodontists and oral surgeons recommend extracting third molars to prevent the crowding of teeth upon their eruption [30]. However, recent studies do not present sufficient evidence to advocate the preventive removal of wisdom teeth to obtain occlusal stability [31,32]. The study of Dosumu et al. showed poor knowledge of the consequences of missing teeth among patients with partial edentulism [28]. In the study, 177 patients (18%) did not lose any teeth, and 803 patients (82%) had at least one lost tooth. Only one patient was edentulous. According to a study from 2021, the percentage of Polish people who have at least 20 teeth, preserving chewing function, has increased over recent years. In 2017, 97% of patients aged 35–44 had 20 teeth, while in our study, this percentage was similar at 94.8% [16].

4.4. Endodontic Lesions and Treatment

In this study, 656 patients (66.9%) underwent root canal treatment (RCT). The most frequently endodontically treated teeth were FDI 26/UNS 14 (141 times) and FDI 36/UNS 19 (118 times). The least frequent teeth with filling in the root canals were FDI 28, 42/UNS 16, 26 (8 times). According to the systematic review of León-López et al., considering the prevalence of RCT treatment worldwide, more than half of the studied population has at least one root-filled tooth [33]. Inflammation of the periapical periodontium, called apical periodontitis, occurs due to untreated irreversible pulpitis and pulp necrosis. It is commonly accompanied by periapical bone resorption [34]. In this study, periapical lesions were most frequently located at tooth FDI 46/UNS 30 (89 times) and least frequently at tooth FDI 31/UNS 24 (3 times). They can also be the effect of RCT performed incorrectly. In the study of Özbaş et al. on a Turkish subpopulation, 40% of endodontically treated teeth had periapical lesions, which indicated the necessity of improving the technical quality of root canal filling by dentists [35]. According to a report by Alnowailaty et al., most identified untreated canals occurred in maxillary and mandibular first molars, resulting in apical periodontitis [36]. In our study, every fifth endodontically treated tooth had a periapical lesion (19%). Some teeth could be treated properly, but the lesion had not yet healed. It has been reported that 50% of cases exhibit signs of healing after 6 months, whereas after 12 months, 88% of these lesions are completely healed [37]. Moreover, a longer healing process occurs in older patients and when the area of the bone loss is more advanced. Sometimes, the treatment observation period is up to 18 months [38].

Almost 60% of periapical radiolucencies, known as “endodontic lesions”, were identified in teeth without evidence of root canal treatment. Despite the similar radiological picture, this group of diagnoses requires differentiation by physical examination. These may include, among others, true periapical inflammatory lesions, root tips during natural development, bone dysplasia, natural anatomical structures (mainly mental foramina), natural arrangement of bone trabeculae imitating pathology, and radiological imaging of the consequences of orthodontic tooth displacement and tumors [39–41].

4.5. Restoring Missing Teeth with Dental Implants and Bridges

In the analyzed material, implants appeared relatively rarely (2% of participants). According to a recent study from 2023, Polish patients show limited knowledge of dental implants [42]. Their major concern about this treatment option is the high cost and the need for surgery. [42] Implants were often inserted around tooth FDI 26/UNS 14 (6 times). In the study group, implants were not placed in the place of teeth FDI 18, 17, 28, 38, 37, 34–44, 47, 48/UNS 1, 2, 16, 17, 18, 21–28, 31, 32. According to a report concerning trends in dental implants in the US in 1999–2016, most were placed in posterior sites, almost equally in the maxilla and mandible [43]. The anterior maxillary region, being an aesthetic zone,

requires special attention in the treatment plan to eliminate the risk of positioning errors, considering gingival phenotype, the width of the edentulous space, and bone anatomy at the alveolar crest [44]. A detailed assessment of the distribution of dental implants based on the study material may not be reliable, as only 2% of participants (23 people) underwent this treatment method. Bridge pontics were present more often to replace missing teeth (8.78%). This cross-sectional study shows current oral statuses. Therefore, it cannot be concluded that patients prefer bridges over implants, as many restorations were placed when the latter were less available.

4.6. Dental Crowns

The most common restored tooth with a crown was FDI 21/UNS 9 (62 times). The anterior region is an important area for oral aesthetics; therefore, it requires high-quality reconstruction. Chairside restoration is not always possible due to the significant destruction of the hard tissues of the tooth. In this study, 21.4% of teeth with root canal fillings were restored with a crown. Tikku et al. show that the coronal coverage significantly improves the success rate of endodontic treatment [45].

4.7. Limitations

Caries lesions confined to the enamel may not be visible on radiographs until the demineralization of the tooth structure is approximately 30–60% [46]. For this reason, incipient lesions can be difficult to detect not only by the dentist but also by the AI algorithm. Moreover, despite the significant diagnostic value of DPRs, intraoral bitewing radiography is superior to panoramic radiography in detecting proximal caries of premolars and molars [47]. The sensitivity of caries detection in DPRs is about 60% [48], which means that there may be more analyzed teeth with caries. Sometimes dental crowding can also make it difficult to detect caries, especially in the incisor region, where superimposition of the cervical spine appears as an anatomical ghost shadow [49].

Panoramic radiography has some disadvantages. It provides less accurate information about dental diseases than intraoral radiographs. Imaging errors such as significantly overlapped structures, shadows of soft tissues or anatomical air spaces, and distortion may often be seen [50]. Such low-quality images may decrease algorithm performance if they are used in building machine learning models [4].

In Poland, DPRs can be taken only in patients with indications confirmed by a written referral from the dentist or physician. This is due to legal regulations regarding radiological protection [51]. Therefore, radiographs do not exist for patients without any suspected pathologies.

Another limitation is the assessment of only hard tissue pathologies detectable on radiographs. It should be emphasized that analyzing a DPR will not replace a medical interview and physical examination. Nevertheless, we believe that a cross-sectional study based on DPRs assessed by AI, conducted on a large sample, provides basic knowledge about the dental needs of the population and will help to plan further, more detailed research and preventive programs.

In this study, we used an algorithm, which does not have an accuracy of 100%; therefore, some diagnoses may have been incorrect. However, according to a recent systematic review, AI models achieve an accuracy above 90% in detecting caries and teeth identification and numbering [6]. Detecting periapical lesions is characterized by high sensitivity (99.75%) and specificity (92%) as well [6]. AI models can also be effectively used in periodontics, providing accuracy above 81% in detecting periodontal bone loss [52,53]. Very high accuracy, between 94 and 98%, also occurred in implant type recognition [54].

AI models appear to be powerful diagnostic tools, as the DPR analyses performed by AI models are similar to those made by humans. Although the difference seems subtle, it should be taken into account, and its value should be updated with technological progress. Therefore, there is a pressing need for current clinical research on this topic.

5. Conclusions

Despite improvement in the oral health of Polish people observed in recent years, its level is still unsatisfactory. Our automatic analysis of 980 DPRs of patients with permanent teeth aged 11–81 years showed that dental caries occurred in almost all the participants. The findings also suggest the vital role of preventive oral healthcare programs, developing new oral health policies, allocating dedicated funds for oral health at the Ministry of Health, and increasing access to affordable essential oral health care. AI-driven tools can be very useful in quickly screening a large group of patients and addressing their needs. Early detection and identification of pathologic conditions are key for timely treatment. By incorporating AI software as a second opinion, dentists can reduce untreated cases, offering enhanced protection for patients. However, due to some limitations of this study, the results should be interpreted with caution.

Author Contributions: Conceptualization, N.T. and M.S. (Maciej Sikora); methodology, N.T.; software, N.T. and I.R.; validation, M.S. (Maciej Sikora); formal analysis, N.T. and K.C.; investigation, N.T. and M.C.; resources, I.R. and M.S. (Marcin Sielski); data curation, N.T. and M.S. (Marcin Sielski); writing—original draft preparation, N.T., K.C. and M.C.; writing—review and editing, N.T., M.C. and M.S. (Maciej Sikora); visualization, N.T.; supervision, M.S. (Maciej Sikora); project administration, M.S. (Maciej Sikora) All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: This study was conducted in accordance with the Declaration of Helsinki and approved by the Bioethics Committee in Kielce at the Świętokrzyska Chamber of Physicians (approval number: 2.3/2023; 31 August 2023). The study protocol was registered in the [ClinicalTrials.gov](https://clinicaltrials.gov) database: NCT06258798.

Informed Consent Statement: Patient consent was waived due to the inclusion in the research material only of dental panoramic radiographs previously performed following therapeutic needs and then anonymized. No further radiographs or other interventions were performed for this study.

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors on request.

Conflicts of Interest: One of the authors, Iwo Rutański, is a service manager and the head of training at a company that offers X-ray equipment and software, which we used in this population-based study. The other authors declare no conflicts of interest.

References

1. Różyło-Kalinowska, I. Panoramic Radiography in Dentistry. *Clin. Dent. Rev.* **2021**, *5*, 26. [[CrossRef](#)]
2. Iannucci, J.; Howerton, L.J. *Dental Radiography—Principles and Techniques*, 6th ed.; Elsevier: Amsterdam, The Netherlands, 2021.
3. Lee, J.-H.; Han, S.-S.; Kim, Y.H.; Lee, C.; Kim, I. Application of a Fully Deep Convolutional Neural Network to the Automation of Tooth Segmentation on Panoramic Radiographs. *Oral Surg. Oral Med. Oral Pathol. Oral Radiol.* **2020**, *129*, 635–642. [[CrossRef](#)] [[PubMed](#)]
4. Delamare, E.; Fu, X.; Huang, Z.; Kim, J. Panoramic Imaging Errors in Machine Learning Model Development: A Systematic Review. *Dentomaxillofacial Radiol.* **2024**, *53*, 165–172. [[CrossRef](#)] [[PubMed](#)]
5. Leite, A.F.; Gerven, A.V.; Willems, H.; Beznik, T.; Lahoud, P.; Gaëta-Araujo, H.; Vranckx, M.; Jacobs, R. Artificial Intelligence-Driven Novel Tool for Tooth Detection and Segmentation on Panoramic Radiographs. *Clin. Oral Investig.* **2021**, *25*, 2257–2267. [[CrossRef](#)] [[PubMed](#)]
6. Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of Artificial Intelligence in the Analysis of Dental Panoramic Radiographs: An Overview of Systematic Reviews. *Dentomaxillofacial Radiol.* **2023**, *52*, 20230284. [[CrossRef](#)] [[PubMed](#)]
7. Patil, S.; Albogami, S.; Hosmani, J.; Mujoo, S.; Kamil, M.A.; Mansour, M.A.; Abdul, H.N.; Bhandi, S.; Ahmed, S.S.S.J. Artificial Intelligence in the Diagnosis of Oral Diseases: Applications and Pitfalls. *Diagnostics* **2022**, *12*, 1029. [[CrossRef](#)] [[PubMed](#)]
8. Zadrożny, Ł.; Regulski, P.; Brus-Sawczuk, K.; Czajkowska, M.; Parkanyi, L.; Ganz, S.; Mijiritsky, E. Artificial Intelligence Application in Assessment of Panoramic Radiographs. *Diagnostics* **2022**, *12*, 224. [[CrossRef](#)] [[PubMed](#)]
9. The Digital Landscape of Dentistry: Dental AI Software—Diagnocat. Available online: <https://diagnocat.com/eu/blog/the-digital-landscape-of-dentistry-dental-ai-software/> (accessed on 10 April 2024).

10. PRESS RELEASE: Artificial Intelligence Takes Root—AI Insights Delivers Automatic Panoramic Image Analysis and Reporting in Seconds. Available online: <https://www.carestreamdental.com/en-emea/training-resources/emea-newsroom/english/posts/2022/press-release-artificial-intelligence-takes-root--ai-insights-delivers-automatic-panoramic-image-analysis-and-reporting-in-seconds/> (accessed on 30 May 2024).
11. Bonfanti-Gris, M.; Garcia-Cañas, A.; Alonso-Calvo, R.; Salido Rodriguez-Manzanque, M.P.; Pradies Ramiro, G. Evaluation of an Artificial Intelligence Web-Based Software to Detect and Classify Dental Structures and Treatments in Panoramic Radiographs. *J. Dent.* **2022**, *126*, 104301. [\[CrossRef\]](#) [\[PubMed\]](#)
12. Putra, R.H.; Doi, C.; Yoda, N.; Astuti, E.R.; Sasaki, K. Current Applications and Development of Artificial Intelligence for Digital Dental Radiography. *Dento Maxillo Facial Radiol.* **2022**, *51*, 20210197. [\[CrossRef\]](#)
13. Pesapane, F.; Codari, M.; Sardanelli, F. Artificial Intelligence in Medical Imaging: Threat or Opportunity? Radiologists Again at the Forefront of Innovation in Medicine. *Eur. Radiol. Exp.* **2018**, *2*, 35. [\[CrossRef\]](#)
14. Shafi, I.; Fatima, A.; Afzal, H.; Díez, I.d.l.T.; Lipari, V.; Breñosa, J.; Ashraf, I. A Comprehensive Review of Recent Advances in Artificial Intelligence for Dentistry E-Health. *Diagnostics* **2023**, *13*, 2196. [\[CrossRef\]](#) [\[PubMed\]](#)
15. Chan, A.K.Y.; Tamrakar, M.; Jiang, C.M.; Lo, E.C.M.; Leung, K.C.M.; Chu, C.H. A Systematic Review on Caries Status of Older Adults. *Int. J. Environ. Res. Public Health* **2021**, *18*, 10662. [\[CrossRef\]](#) [\[PubMed\]](#)
16. Olczak-Kowalczyk, D. Monitorowanie Stanu Zdrowia Populacji Polskiej w Latach 2016–2020. Choroba Próchnicowa i Stan Tkanek Przyzębia Populacji Polskiej. Podsumowanie Wyników Badań z Lat 2016–2019. Sekcja Druków Uczelnianych Warszawskiego Uniwersytetu Medycznego Warszawa, Poland, 2021. Available online: <https://www.gov.pl/attachment/e837445b-41ef-4b49-b261-d21d869e0018/> (accessed on 30 March 2024).
17. Yang, B.; Olsen, M.; Vali, Y.; Langendam, M.W.; Takwoingi, Y.; Hyde, C.J.; Bossuyt, P.M.M.; Leeflang, M.M.G. Study Designs for Comparative Diagnostic Test Accuracy: A Methodological Review and Classification Scheme. *J. Clin. Epidemiol.* **2021**, *138*, 128–138. [\[CrossRef\]](#) [\[PubMed\]](#)
18. Cejudo, J.E.; Chaurasia, A.; Feldberg, B.; Krois, J.; Schwendicke, F. Classification of Dental Radiographs Using Deep Learning. *J. Clin. Med.* **2021**, *10*, 1496. [\[CrossRef\]](#)
19. Ekert, T.; Krois, J.; Meinhold, L.; Elhennawy, K.; Emara, R.; Golla, T.; Schwendicke, F. Deep Learning for the Radiographic Detection of Apical Lesions. *J. Endod.* **2019**, *45*, 917–922.e5. [\[CrossRef\]](#) [\[PubMed\]](#)
20. Dziennik Urzędowy Ministra Zdrowia Obwieszczenie Ministra Zdrowia z Dnia 10 Listopada 2015 r. w Sprawie Ogłoszenia Wykazu Wzorcowych Procedur Radiologicznych z Zakresu Radiologii—Diagnostyki Obrazowej i Radiologii Zabiegowej. 2015; p. 43. Available online: https://dziennikmz.gov.pl/DUM_MZ/2015/78/akt.pdf (accessed on 18 March 2024).
21. González-Ramírez, A.R.; Rivas-Ruiz, F. Measures of Frequency, Magnitude of Association and Impact in Epidemiology. *Allergol. Immunopathol.* **2010**, *38*, 147–152. [\[CrossRef\]](#) [\[PubMed\]](#)
22. What Is Prevalence?—National Institute of Mental Health (NIMH). Available online: <https://www.nimh.nih.gov/health/statistics/what-is-prevalence> (accessed on 7 February 2024).
23. Correlation Coefficient—An Overview | ScienceDirect Topics. Available online: <https://www.sciencedirect.com/topics/earth-and-planetary-sciences/correlation-coefficient> (accessed on 7 February 2024).
24. Carestream Dental | AI Insights. Available online: <https://www.carestreamdental.com/en-gb/csd-products/software/imaging-software/ai-insights/> (accessed on 18 June 2024).
25. Demirci, M.; Tuncer, S.; Yuceokur, A.A. Prevalence of Caries on Individual Tooth Surfaces and Its Distribution by Age and Gender in University Clinic Patients. *Eur. J. Dent.* **2010**, *4*, 270–279. [\[CrossRef\]](#) [\[PubMed\]](#)
26. Luan, W.; Baelum, V.; Fejerskov, O.; Chen, X. Ten-Year Incidence of Dental Caries in Adult and Elderly Chinese. *Caries Res.* **2000**, *34*, 205–213. [\[CrossRef\]](#) [\[PubMed\]](#)
27. Hassan, A.; Khan, J.A.; Ali, S.A. Caries Susceptibility of Proximal Surfaces in Permanent First Molars: A Cross Sectional Survey. *J. Islam. Int. Med. Coll. JIIMC* **2019**, *14*, 38–42.
28. Dosumu, O.O.; Ogunrinde, J.T.; Bamigboye, S.A. Knowledge of Consequences of Missing Teeth in Patients Attending Prosthetic Clinic in U.C.H. Ibadan. *Ann. Ib. Postgrad. Med.* **2014**, *12*, 42–48.
29. Scheiwiller, M.; Oeschger, E.S.; Gkantidis, N. Third Molar Agensis in Modern Humans with and without Agensis of Other Teeth. *PeerJ* **2020**, *8*, e10367. [\[CrossRef\]](#) [\[PubMed\]](#)
30. Lindauer, S.J.; Laskin, D.M.; Tüfekçi, E.; Taylor, R.S.; Cushing, B.J.; Best, A.M. Orthodontists' and Surgeons' Opinions on the Role of Third Molars as a Cause of DENTAL crowding. *Am. J. Orthod. Dentofac. Orthop.* **2007**, *132*, 43–48. [\[CrossRef\]](#) [\[PubMed\]](#)
31. Lyros, I.; Vasoglou, G.; Lykogeorgos, T.; Tsolakis, I.A.; Maroulakos, M.P.; Fora, E.; Tsolakis, A.I. The Effect of Third Molars on the Mandibular Anterior Crowding Relapse—A Systematic Review. *Dent. J.* **2023**, *11*, 131. [\[CrossRef\]](#) [\[PubMed\]](#)
32. Assali, A.; Oualalou, Y.; Zaoui, F. The Evolution of Third Molars in Orthodontics: What about Anterior Dental Crowding?—A Systematic Review. *Integr. J. Med. Sci.* **2022**, *9*, 1–4. [\[CrossRef\]](#)
33. León-López, M.; Cabanillas-Balsera, D.; Martín-González, J.; Montero-Mirallas, P.; Saúco-Márquez, J.J.; Segura-Egea, J.J. Prevalence of Root Canal Treatment Worldwide: A Systematic Review and Meta-Analysis. *Int. Endod. J.* **2022**, *55*, 1105–1127. [\[CrossRef\]](#) [\[PubMed\]](#)
34. American Association of Endodontists. *Glossary of Endodontic Terms*; American Association of Endodontists: Chicago, IL, USA, 2020; p. 33.

35. Özbaş, H.; Aşçı, S.; Aydın, Y. Examination of the Prevalence of Periapical Lesions and Technical Quality of Endodontic Treatment in a Turkish Subpopulation. *Oral Surg. Oral Med. Oral Pathol. Oral Radiol. Endod.* **2011**, *112*, 136–142. [\[CrossRef\]](#) [\[PubMed\]](#)
36. Alnowailaty, Y.; Alghamdi, F. Prevalence of Endodontically Treated Premolars and Molars With Untreated Canals and Their Association With Apical Periodontitis Using Cone-Beam Computed Tomography. *Cureus* **2022**, *14*, e25619. [\[CrossRef\]](#)
37. Orstavik, D. Time-Course and Risk Analyses of the Development and Healing of Chronic Apical Periodontitis in Man. *Int. Endod. J.* **1996**, *29*, 150–155. [\[CrossRef\]](#) [\[PubMed\]](#)
38. Mosquera-Barreiro, C.; Ruiz-Piñón, M.; Sans, F.A.; Nagendrababu, V.; Vinothkumar, T.S.; Martín-González, J.; Martín-Biedma, B.; Castelo-Baz, P. Predictors of Periapical Bone Healing Associated with Teeth Having Large Periapical Lesions Following Nonsurgical Root Canal Treatment or Retreatment: A Cone Beam Computed Tomography-Based Retrospective Study. *Int. Endod. J.* **2024**, *57*, 23–36. [\[CrossRef\]](#)
39. Daviet-Noual, V.; Ejeil, A.-L.; Gossioime, C.; Moreau, N.; Salmon, B. Differentiating Early Stage Florid Osseous Dysplasia from Periapical Endodontic Lesions: A Radiological-Based Diagnostic Algorithm. *BMC Oral Health* **2017**, *17*, 161. [\[CrossRef\]](#)
40. Mupparapu, M.; Shi, K.J.; Ko, E. Differential Diagnosis of Periapical Radiopacities and Radiolucencies. *Dent. Clin. N. Am.* **2020**, *64*, 163–189. [\[CrossRef\]](#) [\[PubMed\]](#)
41. Ghafoor, R. Conservative Management of Progressive External Inflammatory Root Resorption after Traumatic Tooth Intrusion. *J. Conserv. Dent.* **2013**, *16*, 265–268. [\[CrossRef\]](#) [\[PubMed\]](#)
42. Krupińska, A.M.; Bogucki, Z. Evaluation of Patients' Awareness and Knowledge Regarding Dental Implants among Patients of the Department of Prosthetic Dentistry at Wrocław Medical University in Poland. *Adv. Clin. Exp. Med.* **2023**, *32*, 1319–1325. [\[CrossRef\]](#) [\[PubMed\]](#)
43. Elani, H.W.; Starr, J.R.; Da Silva, J.D.; Gallucci, G.O. Trends in Dental Implant Use in the U.S., 1999–2016, and Projections to 2026. *J. Dent. Res.* **2018**, *97*, 1424–1430. [\[CrossRef\]](#) [\[PubMed\]](#)
44. Chen, S.T.; Buser, D.; Sculean, A.; Belser, U.C. Complications and Treatment Errors in Implant Positioning in the Aesthetic Zone: Diagnosis and Possible Solutions. *Periodontology 2000* **2023**, *92*, 220–234. [\[CrossRef\]](#) [\[PubMed\]](#)
45. Tikku, A.P.; Chandra, A.; Bharti, R. Are Full Cast Crowns Mandatory after Endodontic Treatment in Posterior Teeth? *J. Conserv. Dent.* **2010**, *13*, 246–248. [\[CrossRef\]](#) [\[PubMed\]](#)
46. White, S.C.; Pharoah, M.J. *Oral Radiology—Principles and Interpretation*, 6th ed.; MOSBY Elsevier: Amsterdam, The Netherlands, 2009.
47. Kamburoğlu, K.; Kolsuz, E.; Murat, S.; Yüksel, S.; Özen, T. Proximal Caries Detection Accuracy Using Intraoral Bitewing Radiography, Extraoral Bitewing Radiography and PANORAMIC radiography. *Dentomaxillofacial Radiol.* **2012**, *41*, 450–459. [\[CrossRef\]](#)
48. Kweon, H.H.-I.; Lee, J.-H.; Youk, T.; Lee, B.-A.; Kim, Y.-T. Panoramic Radiography Can Be an Effective Diagnostic Tool Adjunctive to Oral Examinations in the National Health Checkup Program. *J. Periodontal Implant. Sci.* **2018**, *48*, 317. [\[CrossRef\]](#) [\[PubMed\]](#)
49. Suomalainen, A.; Pakbaznejad Esmaeili, E.; Robinson, S. Dentomaxillofacial Imaging with Panoramic Views and Cone Beam CT. *Insights Imaging* **2015**, *6*, 1–16. [\[CrossRef\]](#)
50. Peretz, B.; Gotler, M.; Kaffe, I. Common Errors in Digital Panoramic Radiographs of Patients with Mixed Dentition and Patients with Permanent Dentition. *Int. J. Dent.* **2012**, *2012*, 584138. [\[CrossRef\]](#)
51. Dziennik Ustaw Rzeczypospolitej Polskiej, Rozporządzenie Ministra Zdrowia z Dnia 8 Grudnia 2017 r. Available online: <https://isap.sejm.gov.pl/isap.nsf/download.xsp/WDU20170002397/O/D20172397.pdf> (accessed on 19 May 2024).
52. Krois, J.; Ekert, T.; Meinhold, L.; Golla, T.; Kharbot, B.; Wittemeier, A.; Dörfer, C.; Schwendicke, F. Deep Learning for the Radiographic Detection of Periodontal Bone Loss. *Sci. Rep.* **2019**, *9*, 8495. [\[CrossRef\]](#) [\[PubMed\]](#)
53. Revilla-León, M.; Gómez-Polo, M.; Barmak, A.B.; Inam, W.; Kan, J.Y.K.; Kois, J.C.; Akal, O. Artificial Intelligence Models for Diagnosing Gingivitis and Periodontal Disease: A Systematic Review. *J. Prosthet. Dent.* **2022**, *130*, 816–824. [\[CrossRef\]](#) [\[PubMed\]](#)
54. Revilla-León, M.; Gómez-Polo, M.; Vyas, S.; Barmak, B.A.; Galluci, G.O.; Att, W.; Krishnamurthy, V.R. Artificial Intelligence Applications in Implant Dentistry: A Systematic Review. *J. Prosthet. Dent.* **2023**, *129*, 293–300. [\[CrossRef\]](#) [\[PubMed\]](#)

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.



Article

Evaluation of Dental Panoramic Radiographs by Artificial Intelligence Compared to Human Reference: A Diagnostic Accuracy Study

Natalia Turosz ^{1,2,*} , Kamila Chęcińska ^{3,4,5} , Maciej Chęciński ^{1,2,6} , Marcin Sielski ^{1,2} and Maciej Sikora ^{1,2,7,*}

- ¹ National Medical Institute of the Ministry of Interior and Administration, Wołoska 137 Str., 02-507 Warsaw, Poland; maciej@checinscy.pl (M.C.); marcinsielski@gazeta.pl (M.S.)
 - ² Department of Maxillofacial Surgery, Hospital of the Ministry of Interior, Wojska Polskiego 51, 25-375 Kielce, Poland
 - ³ Department of Glass Technology and Amorphous Coatings, Faculty of Materials Science and Ceramics, AGH University of Science and Technology, Mickiewicza 30, 30-059 Kraków, Poland; checinska@agh.edu.pl
 - ⁴ Faculty of Applied Sciences, WSB Academy, Ciepłaka 1C Str., 41-300 Dąbrowa Górnicza, Poland
 - ⁵ Institute of Applied Sciences, WSB Merito University in Poznań, Sportowa 29 Str., 41-506 Chorzów, Poland
 - ⁶ Department of Oral Surgery, Preventive Medicine Center, Komorowskiego 12, 30-106 Kraków, Poland
 - ⁷ Department of Biochemistry and Medical Chemistry, Pomeranian Medical University, Powstańców Wielkopolskich 72, 70-111 Szczecin, Poland
- * Correspondence: natalia.turosz@gmail.com (N.T.); sikora-maciej@wp.pl (M.S.)

Abstract: Background/Objectives: The role of artificial intelligence (AI) in dentistry is becoming increasingly significant, particularly in diagnosis and treatment planning. This study aimed to assess the sensitivity, specificity, accuracy, and precision of AI-driven software in analyzing dental panoramic radiographs (DPRs) in patients with permanent dentition. **Methods:** Out of 638 DPRs, 600 fulfilled the inclusion criteria. The radiographs were analyzed by AI software and two researchers. The following variables were assessed: (1) missing tooth, (2) root canal filling, (3) endodontic lesion, (4) implant, (5) abutment, (6) pontic, (7) crown, (8) and sound tooth. **Results:** The study revealed very high performance metrics for the AI algorithm in detecting missing teeth, root canal fillings, and implant abutment crowns, all greater than 90%. However, it demonstrated moderate sensitivity and precision in identifying endodontic lesions and the lowest precision (65.30%) in detecting crowns. **Conclusions:** AI software can be a valuable tool in clinical practice for diagnosis and treatment planning but may require additional verification by clinicians, especially for identifying endodontic lesions and crowns. Due to some limitations of the study, further research is recommended.

Keywords: artificial intelligence; panoramic radiograph; automatic detection; diagnosis



Citation: Turosz, N.; Chęcińska, K.; Chęciński, M.; Sielski, M.; Sikora, M. Evaluation of Dental Panoramic Radiographs by Artificial Intelligence Compared to Human Reference: A Diagnostic Accuracy Study. *J. Clin. Med.* **2024**, *13*, 6859. <https://doi.org/10.3390/jcm13226859>

Academic Editor: Eitan Mijiritsky

Received: 10 October 2024

Revised: 6 November 2024

Accepted: 12 November 2024

Published: 14 November 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Radiography plays an important role in diagnostics and treatment planning in modern dentistry. It provides information on anatomy, pathologies, and treatment outcomes. One of the most widely used is a dental panoramic radiograph (DPR). This extraoral technique produces a comprehensive view of dental arches, maxilla, mandible, temporomandibular joints, and partially maxillary sinuses [1]. It is used in many fields of dentistry. In orthodontics, it allows the detection of dental anomalies, evaluation of general dental health, and observation of treatment. DPR also supports maxillofacial surgery in diagnosing dental impactions, dental and mandibular fractures, cysts, and tumors [2]. It involves a small dose of ionizing radiation compared to a dose of cone beam computed tomography (CBCT), which, depending on the scan mode, is about three to six times higher than for DPRs [3,4]. Panoramic radiographs are widely used in epidemiological and screening studies, providing information on the general oral health of large groups of patients [5]. However, they

have limitations such as superimposition, distortions, and ghost images [6,7]. Superimposition is the overlapping of structures in the X-ray path and can be caused by tongue rings or developing permanent teeth in the primary dentition [2]. The level of distortion depends on the machine type and the distance between the film and the patient [8]. Ghost images may result from anatomical structures like the cervical spine reflecting over the lower incisor. These artifacts can also be caused by jewelry, including earrings [2]. DPRs lack fine details compared to intraoral radiographs [9]. Therefore, it is not sufficient for examining, for example, proximal dental caries [10]. Similar to other radiographic examinations, DPRs have limited inter- and intra-examiner reliability [11]. Inter-examiner reliability describes the level of agreement among independent examiners when applying a test to the same patient [12]. Intra-examiner reliability is the consistency of an examiner in documenting the same conditions over time [13].

In addition to radiographic imaging, visual-tactile examination, caries detection dye, transillumination, pulp vitality testing, and probing pocket depths are also valuable diagnostic tests in dentistry, crucial for obtaining an accurate diagnosis [14,15]. Early detection of pathological conditions allows for timely interventions and effective dental prevention. Diagnostic tests are also important for monitoring oral health, evaluating treatment outcomes, and assessing risks for dental diseases. They can also be used to screen populations, providing data that inform about the need to implement certain actions and strategies [16].

Artificial intelligence (AI) is the ability of machines to perform tasks traditionally associated with human intelligence, such as learning and problem-solving [17]. It is increasingly applied in dentistry and, according to Thurzo et al., is implemented mainly in radiology and orthodontics [18]. This technology can also be used in detecting root fractures, analyzing the anatomy of the root canal system, and aiding clinicians with working length determination [19]. Machine learning in CAD/CAM software can help manufacture well-made fixed and removable dental restorations [18]. Dental radiography such as CBCT, intraoral, panoramic, and cephalometric radiographs provides large data sets for developing AI-based software [20]. When evaluating DPRs, these algorithms achieve an accuracy of about 90% in detecting caries, osteoporosis, maxillary sinusitis, periodontal bone loss, and teeth identification and numbering on DPRs. Detection of periapical lesions is also characterized by high specificity and sensitivity above 90% [21].

According to the study by Gunec et al., AI can generate faster, more accurate diagnoses than junior dentists with one or two years of experience in detecting periapical lesions [22]. Early detection of pathologies allows rapid implementation of appropriate treatment. AI is also a promising tool in medical screening, as it provides accurate and cost-effective results in less time than traditional methods [23]. Its ability to analyze large data sets facilitates population oral health surveillance [24]. This technology also reduces the risk of human errors resulting from, for example, examiner fatigue [25]. By obtaining a second opinion from the program, dentists can validate their radiograph evaluation and better explain the rationale of the planned treatment.

In the overview of reviews from 2023, twelve systematic reviews regarding the application of AI in the automatic evaluation of DPRs were analyzed [21]. Comparing different algorithms was challenging due to the heterogeneity of the studies, with differences in performance metrics reaching 55%. Possible causes include applying different AI on sample sizes ranging from fifty-five to over a thousand DPRs. The algorithms were used to identify periapical lesions; root canal fillings; and metal- and resin-based restorations, crowns, or implants [26–29]. Currently, there are very few studies with large sample sizes that assess multiple parameters. This deficiency became the basis for designing and implementing the study reported in this paper.

This study aims to validate AI software as a diagnostic tool and evaluate its sensitivity, specificity, precision, and accuracy in assessing permanent teeth on DPRs. The null hypothesis is stated as follows: “The accuracy of AI software in detecting dental conditions on DPRs is equal to that of human analysis”.

2. Materials and Methods

2.1. Study Design

This prospective, double-gate study on diagnostic accuracy followed the Standards for Reporting of Diagnostic Accuracy Studies (STARD) and the Checklist for Artificial Intelligence in Medical Imaging (CLAIM) checklists. The research was approved by the Bioethics Committee in Kielce at the Świętokrzyska Chamber of Physicians (approval number: 2.3/2023) and was conducted according to the principles of the Declaration of Helsinki. The National Clinical Trial number assigned to this study is NCT06258798. Patients fulfilling specific eligibility criteria were included. Data was collected in real-time, after the study had begun. The research established two gates with distinct eligibility criteria for AI and human, essential for accurately comparing their diagnostic performances.

2.2. Study Population

Patients included in the study were admitted to the radiology department in Kielce, a central European city with about 200,000 inhabitants, and the capital of Świętokrzyskie province in Poland. The eligibility criteria are presented in Table 1. The participant sampling was consecutive. A single reference standard was used for all patients.

Table 1. Inclusion and exclusion criteria.

Domain	Criteria for Inclusion	Criteria for Exclusion
Population	Patients of the diagnostic imaging facility in Kielce, Poland	Primary or mixed dentition
Study sample	DPR performed irrespective of the specific indication and assessed by AI	Error resulting in no results or partial results
Control sample	The same DPR assessed by medical professionals	Not applicable
Outcomes	Differences in individual assessments by AI and medical professionals	Not applicable

2.3. Setting

DPRs were taken with the device Carestream CS 9600 (Carestream Health, Rochester, New York, NY, USA) with adjustable exposure conditions set to 60–90 kV and 2–15 mA. Only appropriate quality X-rays, which were performed according to the criteria of the Polish Ministry of Health, were analyzed. The AI algorithm used in the study was integrated with CS Imaging software (version 8, Carestream Dental LLC, Atlanta, GA, USA). After DPRs had been anonymized, the software analyzed the uploaded X-rays (index test). The report included the location of missing teeth, root canal fillings, endodontic lesions, dental crowns, pontics, implants, and implant abutment crowns. Then, radiographs were analyzed by two independent clinical evaluators (N.T. and M.C.) with 4 and 12 years of experience, respectively (reference test). Human analysis was considered the gold reference standard.

2.4. Study Size

The required sample size was calculated using the Sample Size Estimation for Diagnostic Accuracy Studies tool [30]. The highest sensitivity or specificity values from the latest publications were considered [21,26,27,29]. The sensitivity value was preferred, and if not available, specificity was chosen. In the recent overview of reviews, the highest sensitivity of detecting missing teeth was 98.1%, while the specificity of identifying endodontic lesions reached 90.24% [21]. According to Kazimierczak et al., the sensitivity of automatic detection of root canal fillings on DPRs achieved 90.7% [26]. Identifying crowns presented a specificity of 95.73% [27]. In the study of Başaran et al., the sensitivity of detecting implants, implant abutment crowns, and pontics was 96.15%, 89.47%, and 77.38%, respectively [29]. We assumed a 5% type I error and a marginal error of 5%.

The actual sample size was 600 DPRs due to the capabilities of researchers—19,200 tests were performed by AI and investigators for each variable. This size was significantly larger than the estimated size for variables: missing (186), root canal filling (2048), endodontic treatment (139), and crown (3470). However, it might be insufficient for the following variables: implant (29,937), implant abutment crown (103,403), and pontic (34,045).

2.5. Variables

Table 2 presents the analyzed variables and abbreviations used. The values of variables (1) missing teeth, (2) root canal filling, (3) endodontic lesion, (4) implant, (5) implant abutment crown, (6) pontic crown, (7) dental abutment crown, and (8) sound teeth for analysis performed by AI and investigators were grouped depending on the location of the tooth according to World Dental Federation (FDI) notation, ISO 3950. In this system, each tooth is given a unique two-digit number. The first digit indicates the quadrant of the mouth (the number 1 represents the upper right quadrant, 2—the upper left quadrant, 3—the lower left quadrant, and 4—the lower right quadrant). The second digit indicates the position of the tooth within that quadrant (the number 1,2—incisors, 3—canines, 4,5—premolars, 6,7,8—molars) [31].

Table 2. Variables.

Abbreviation	Name of Variable	Description
M	Missing	Absence of a natural tooth in a given position of the dental arch
R	Root canal filling	The presence of a filling in at least one root canal
E	Endodontic lesion	Periapical radiological radiolucency suggesting periapical inflammation
I	Implant	Any type of dental implant
A	Abutment	Any superstructure attached to an implant
P	Pontic	A prosthetic crown that replaces a missing tooth in a bridge
C	Crown	A prosthetic crown supported on a tooth
S	Sound	A tooth without the above-mentioned diagnoses

2.6. Analysis

The acquired data were analyzed in the Microsoft Office program (Microsoft Corporation, Redmond, WA, USA), Google Workspace (version 2024.05.31, Google LLC, Mountain View, CA, USA), and MedCalc software (version 23.0.1; MedCalc Software Ltd., Ostend, Belgium). Based on the analyses performed by AI and investigators, the number of true positive, true negative, false positive, and false negative values were calculated and then used to assess the sensitivity = $\frac{TP}{TP+FN}$, specificity = $\frac{TN}{TN+FP}$, precision = $\frac{TP}{TP+FP}$, and accuracy = $\frac{TP+TN}{TP+FP+TN+FN}$ of the AI program. TP, TN, FP, and FN denote true positives, true negatives, false positives, and false negatives, respectively. To evaluate the results, guideline definitions of “very high”, “high”, “moderate”, and “low” were used (Table A1) [32].

3. Results

3.1. Participants

The study involved 638 patients. Data on 38 participants were not obtained due to user error (n = 5) or not meeting the eligibility criteria (n = 33). Finally, 600 patients were included in the study—337 females and 263 males (Figure 1). The youngest patient was 11 years old, and the oldest was 81. The average age was 34.78 (SD = 14.48) years.




Figure 1. Flow diagram.

3.2. Test Results

In total, both the principal investigator and the AI made 153,600 binary decisions for eight variables and 32 oral positions in 600 DPRs. The researcher had concerns assessing 281 (1.46%) of 19,200 oral locations. The second investigator verified these cases. Table 3 presents the raw results for individual variables and values of sensitivity, specificity, precision, and accuracy. The numbers of teeth with each diagnosis identified by AI and investigators are presented in Figures 2–4. Figure 2 illustrates frequency of missing teeth according to their position in both dental arches. The distributions of teeth with endodontic lesions or root canal fillings are presented in Figure 3. Figure 4 provides a comprehensive overview of prosthetic restorations detected on DPRs, showing the comparison in the number of given diagnoses between humans and AI. The receiver operating characteristic curve (ROC) for each variable is presented in Figure 5.

Table 3. Outcomes.

	Missing	Root Canal Filling	Endodontic Lesion	Implant	Abutment	Pontic	Crown	Sound
Test outcome negative (index test)	16,223	17,980	18,677	19,162	19,175	19,068	18,687	4890
Actual condition negative (human reference)	16,245	17,984	18,693	19,164	19,173	19,048	18,852	4764
Test outcome positive (index test)	2977	1220	523	38	25	132	513	14310
Actual condition positive (human reference)	2955	1216	507	36	27	152	348	14436
Prevalence in the sample	15.39%	6.33%	2.64%	0.19%	0.14%	0.79%	1.81%	75.19%
True positive results—correctly identified	2832 (14.75%)	1150 (5.99%)	379 (1.97%)	32 (0.17%)	25 (0.13%)	123 (0.64%)	335 (1.74%)	14,143 (73.66%)

Table 3. Cont.

	Missing	Root Canal Filling	Endodontic Lesion	Implant	Abutment	Pontic	Crown	Sound
True negative results—correctly excluded	16,100 (83.85%)	17,914 (93.30%)	18,549 (96.61%)	19,158 (99.78%)	19,173 (99.86%)	19,039 (99.16%)	18,674 (97.26%)	5197 (27.07%)
False positive results—over diagnosed	145 (0.76%)	70 (0.36%)	144 (0.75%)	6 (0.03%)	0 (0%)	9 (0.05%)	178 (0.93%)	167 (0.87%)
False negative results—misdiagnosed	123 (0.64%)	66 (0.34%)	128 (0.67%)	4 (0.02%)	2 (0.01%)	29 (0.15%)	13 (0.07%)	293 (1.53%)
True positive rate—sensitivity (95% confidence interval in parentheses)	95.84% (95.05–96.53%)	94.57% (93.15–95.78%)	74.75% (70.74–78.48%)	88.89% (73.94–96.89%)	92.59% (75.71–99.09%)	80.92% (73.76–86.83%)	96.26% (93.70–98.00%)	97.97% (97.73–98.19%)
True negative rate—specificity (95% confidence interval in parentheses)	99.11% (98.95–99.25%)	99.61% (99.51–99.70%)	99.23% (99.09–99.35%)	99.97% (99.93–99.99%)	100% (99.98–100.00%)	99.95% (99.91–99.98%)	99.06% (98.91–99.19%)	96.89% (96.39–97.34%)
Positive predictive value—precision (95% confidence interval in parentheses)	95.13% (94.32–95.83%)	94.26% (92.86–95.41%)	72.47% (68.94–75.73%)	84.21% (70.38–92.29%)	100% (86.28–100.00%)	93.18% (87.62–96.35%)	65.30% (61.89–68.57%)	98.83% (98.65–98.99%)
Accuracy (95% confidence interval in parentheses)	98.60% (98.43–98.77%)	99.29% (99.16–99.41%)	98.58% (98.41–98.75%)	99.95% (99.90–99.98%)	99.99% (99.96–100.00%)	99.80% (99.73–99.86%)	99.01% (98.86–99.14%)	97.68% (97.46–97.88%)




Figure 2. Number of missing teeth detected by AI algorithm and human examiner, with positional detail in upper (18–28) and lower (38–48) dental arch. Position numbering according to ISO 3950:2016 FDI notation (version 2022, FDI World Dental Federation, Geneva, Switzerland) [31].




Figure 3. Number of root canal fillings and endodontic lesions detected by AI algorithm and human examiner, with positional detail in upper (18–28) and lower (38–48) dental arch. Position numbering according to ISO 3950:2016 FDI notation (version 2022, FDI World Dental Federation, Geneva, Switzerland) [31].




Figure 4. Cont.




Figure 4. Number of implants, implant abutment crowns, pontic crowns, and dental abutment crowns detected by AI algorithm and human examiner, with positional detail in upper (18–28) and lower (38–48) dental arch. Position numbering according to ISO 3950:2016 FDI notation (version 2022, FDI World Dental Federation, Geneva, Switzerland) [31].




Figure 5. ROC curve representations for the studied variables. The random classifier (diagonal line) is orange, and the ROC curve for the classifier is blue.

4. Discussion

4.1. Missing Teeth

Research in recent years has shown a very high effectiveness in identifying missing teeth using AI on panoramic X-rays [33–35]. According to Tuzoff et al., the performance of tested CNN-based architecture was comparable to that of experts, which can simplify the filling in of digital dental charts [36]. Vinayahalingam et al., after testing 200 DPRs by the Mask R-CNN architecture, achieved a precision of 99.7% [37]. The results of the present study are also promising. The algorithm detected missing teeth, achieving all analyzed performance metrics above 95%. The sensitivity and specificity were similar to the study from 2024, where CNNs were used for automatic evaluation [38]. The algorithm in the present study marked 22 more teeth as missing than the researchers did. The most common diagnosis differences between AI and clinicians occurred in teeth 24, 25, and 26, while no differences were observed in teeth 21, 22, 33, and 48. Problems with the correct identification of missing teeth for both AI and dentists may occur in the residual dentition when the remaining teeth move toward the edentulous space, leading to their displacement from the proper position (Popov–Godon phenomenon). The algorithm also did not correctly identify teeth when one tooth covered the other, which occurred in the case of crowding or the presence of an impacted tooth. Sometimes, the developing wisdom tooth buds were not detected by the software, either.

4.2. Endodontic Lesions and Root Canal Fillings

All analyzed performance metrics for detecting root canal fillings (RCFs) were very high, with values above 94%. These metrics indicate significantly good reliability in making accurate predictions. Other studies also present good results in identifying endodontically treated teeth [26,27]. In a study from 2024, another popular cloud-based AI software, Diagnocat, achieved high accuracy (90.72%) in detecting the probability of fillings [26]. Bonfanti Gris et al., using web-based software Denti.AI, achieved accuracy, specificity, and sensitivity above 90% as well [26,27]. The most common tooth with a RCF was 26. The first molars are the most susceptible to caries because of their early eruption and morphology [39]. Endodontic treatment was least frequently performed in the lower incisors. They are least likely to experience caries because of the large amount of saliva produced by the submandibular salivary glands [40].

Lower values of sensitivity (74.75%) and precision (72.47%) were observed in detecting periapical lesions. However, these values are higher than those obtained in other studies,

where they achieved 39% and 56%, respectively [11,38]. The reason for the lower value of the indicators may be due to the use of DPR instead of CBCT. Many studies confirmed the higher accuracy of CBCT in detecting periapical lesions, identifying about one-third more periapical lesions [41,42]. A recent study by Kazimierczak et al. has shown that the sensitivity and precision of identifying this pathology were 44.45% and 59.19% higher in the case of AI software analyzing CBCT rather than in DPRs. The specificity and accuracy were high in the case of both these images (above 97%) [43]. There was also a study from 2023 where a model consisting of two convolutional neural networks (CNNs) performed well and detected periapical lesions with accuracy, sensitivity, and specificity above 81% [28]. In the present study, the algorithm sometimes incorrectly identified artifacts, teeth with an undeveloped root apex, and anatomical structures such as the mental foramen or the mandibular canal as periapical lesions (Figure 6). A few times, the software indicated the presence of a lesion in a tooth adjacent to the actual one.




Figure 6. Examples of teeth misdiagnosed by AI software. (A) Tooth 26 with an orthodontic band, mistakenly identified as a tooth with a crown. (B) Tooth 36, not treated endodontically, incorrectly diagnosed as a tooth with root canal filling. (C) Teeth 44 and 45 with extensive, highly radiopaque dental fillings, wrongly identified as teeth with crowns. (D) Tooth 44 with incomplete root development, misdiagnosed as a tooth with a periapical lesion.

4.3. *Prosthetics (Crowns, Pontics, Implants, and Implant Abutment Crowns)*

The tested algorithm generally performed well in detecting prosthetic elements. All of them achieved very high specificity, above 99%. Moderate precision was observed in

identifying crowns. The common problem for the AI was identifying extensive dental fillings, direct veneers, and molar bands as crowns (Figure 6). Nevertheless, the sensitivity, specificity, and accuracy were very high (above 99%). Similar good results in detecting crowns were also obtained in another study where a pre-trained CNN, available online from 2017, was used to analyze 300 DPRs. The sensitivity and precision were 89.53%, while specificity achieved almost 96% [27]. The precision in the study by Altan, where the YOLOv4 model was used, was moderate and reached 74%. However, detecting bridges became more successful, resulting in a precision of 84% [44]. In the present study, all performance metrics for detecting pontics were high, reaching up to 99.95%. A few times the algorithm wrongly indicated teeth as pontics. Another study from 2022 used the AI Model CranioCatch based on the deep CNN method to analyze 1084 DPRs. The detection of pontics was characterized by moderate sensitivity at 77.38% but high precision at 87.83% [29].

The prevalence of implants and implant abutment crowns in the study was low, 0.19% and 0.14%, respectively. Analyzed performance metrics achieved high and very high values. Various studies have also obtained good results for detecting implants. Vinayahalingam et al. achieved a precision of 97.9% [37]. In the study by Başaran et al., the sensitivity and precision were even higher, reaching 96.15% and 92.59%, respectively. However, the algorithm showed slightly lower metrics in detecting implant abutment crowns, with about 3% and 10% decreases [29]. In the present study, all parameters regarding the identification of implant-supported crowns were very high, above 92%. Occasionally, in the present study the algorithm mistakenly identified post and core restorations as implants.

4.4. Limitations

The study only included correctly performed DPRs. Radiographs followed the criteria of the Polish Ministry of Health [45]. However, any qualitative deviation increases the risk of incorrect AI evaluation.

Radiographs of only Caucasian patients were acquired. Additionally, they were performed in one imaging diagnostics center. The lack of diversity due to analyzing a narrow population may limit the generalizability of results. Nevertheless, a typical radiology department was chosen in a medium-sized central European city.

DPRs provide valuable information about teeth and the maxillofacial skeleton. However, they lack details that can be obtained from CBCT or intraoral radiographs. For example, periapical lesions can only be detected on DPRs when the mineral loss of bone reaches 30–50% [46]. Therefore, initial lesions may have been omitted. In the periapical area, condensing osteitis can also be observed, which radiologically appears as a concentric radio-opaque area [47]. Although treatment is only advised if symptoms indicate the need, the algorithm did not include these conditions as periapical lesions. Moreover, superimposition and distortion, which may occur on DPRs, can lead to errors in analysis [2].

In the case of the variables implant, implant abutment crown, and pontic, there is a risk of obtaining an inaccurate result due to a sample size smaller than calculated with the Sample Size Estimation for Diagnostic Accuracy Studies tool [30].

The validity of a study depends on the reliability of the investigator [13]. Human evaluation may be fallible because of examiners' different experiences or individual perceptions. Fatigue, anxiety, or stress can also affect diagnostic accuracy. More examiners undergoing the same training procedure, called standardization, would objectify the results.

4.5. Strengths and Future Perspectives

The strength of this study lies in its large sample size. While most researchers evaluate the reliability of AI algorithms using usually up to 300 radiographs, this study includes more than 600 DPRs, which enhances the validity and generalizability of the findings [25,27,38]. The study delivers a comprehensive comparison of diagnostic accuracy between AI and humans. The results suggest that this technology may serve as a second opinion tool for dental professionals, improving the accuracy of diagnoses and treatments. However, it is

necessary to continuously develop the AI algorithms by training them on big data sets and improving the quality of data.

5. Conclusions

In summary, the AI algorithm performed well in automatically evaluating DPRs. It achieved very high performance metrics in detecting missing teeth, root canal fillings, and implant abutment crowns, indicating that AI-based software can be a reliable tool for analyzing panoramic radiographs. However, the moderate precision of identifying endodontic lesions and crowns suggest that clinicians should further verify these findings. Due to the limitations of the study, further research is recommended to develop AI algorithms.

Author Contributions: Conceptualization, N.T. and M.S. (Maciej Sikora); methodology, N.T. and K.C.; software, N.T. and K.C.; validation, M.C.; formal analysis, N.T. and K.C.; investigation, N.T. and M.C.; resources, M.S. (Marcin Sielski); data curation, N.T.; writing—original draft preparation, N.T.; writing—review and editing, N.T., K.C., M.C., M.S. (Marcin Sielski) and M.S. (Maciej Sikora); visualization, N.T.; supervision, M.S. (Maciej Sikora); project administration, M.S. (Maciej Sikora). All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: This study was conducted in accordance with the Declaration of Helsinki and approved by the Bioethics Committee in Kielce at the Świętokrzyska Chamber of Physicians (approval number: 2.3/2023; 31 August 2023). The study protocol was registered in the ClinicalTrials.gov database: NCT06258798.

Informed Consent Statement: Patient consent was waived due to the inclusion in the research material of only dental panoramic radiographs previously performed following therapeutic needs and then anonymized. No further radiographs or other interventions were performed for this study.

Data Availability Statement: All synthesized data are available in the article. The raw data supporting the conclusions of this article will be made available by the authors on request.

Conflicts of Interest: The authors declare no conflicts of interest.

Appendix A

Table A1. Guideline definitions of the levels of performance metrics.

Level	Estimated Performance Metrics
Very high	90–100%
High	80–90%
Moderate	65–80%
Low	below 65%

References

1. Różyło-Kalinowska, I. Panoramic radiography in dentistry. *Clin. Dent. Rev.* **2021**, *5*, 26. [\[CrossRef\]](#)
2. Farman, A.G. *Panoramic Radiology. Seminars on Maxillofacial Imaging and Interpretation*; Springer: Berlin/Heidelberg, Germany; New York, NY, USA, 2007; ISBN 978-3-540-46229-3.
3. Deman, P.; Atwal, P.; Duzenli, C.; Thakur, Y.; Ford, N.L. Dose measurements for dental cone-beam CT: A comparison with MSCT and panoramic imaging. *Phys. Med. Biol.* **2014**, *59*, 3201. [\[CrossRef\]](#)
4. Signorelli, L.; Patcas, R.; Peltomäki, T.; Schätzle, M. Radiation dose of cone-beam computed tomography compared to conventional radiographs in orthodontics. *J. Orofac. Orthop.* **2016**, *77*, 9–15. [\[CrossRef\]](#)
5. Choi, J.-W. Assessment of panoramic radiography as a national oral examination tool: Review of the literature. *Imaging Sci. Dent.* **2011**, *41*, 1–6. [\[CrossRef\]](#)
6. Kweon, H.H.-I.; Lee, J.-H.; Youk, T.; Lee, B.-A.; Kim, Y.-T. Panoramic radiography can be an effective diagnostic tool adjunctive to oral examinations in the national health checkup program. *J. Periodontal Implant. Sci.* **2018**, *48*, 317. [\[CrossRef\]](#)
7. Perschbacher, S. Interpretation of panoramic radiographs. *Aust. Dent. J.* **2012**, *57*, 40–45. [\[CrossRef\]](#) [\[PubMed\]](#)
8. Kayal, R.A. Distortion of digital panoramic radiographs used for implant site assessment. *J. Orthod. Sci.* **2016**, *5*, 117–120. [\[CrossRef\]](#) [\[PubMed\]](#)
9. Kiser, J.R. Reduce Your Panoramic Imaging Errors. *Dimens. Dent. Hyg.* **2020**, *18*, 36–39.

10. Akkaya, N.; Kansu, Ö.; Kansu, H.; Çağırkaya, L.; Arslan, U. Comparing the accuracy of panoramic and intraoral radiography in the diagnosis of proximal caries. *Dentomaxillofac. Radiol.* **2006**, *35*, 170–174. [\[CrossRef\]](#)
11. İzöz, D.; Terzioğlu, H.; Özel, M.A.; Karakurt, R. Evaluation of an Artificial Intelligence System for the Diagnosis of Apical Periodontitis on Digital Panoramic Images. *Niger. J. Clin. Pract.* **2023**, *26*, 1085. [\[CrossRef\]](#)
12. Laslett, M. Chapter 28—Evidence-based clinical testing of the lumbar spine and pelvis. In *Movement, Stability & Lumbopelvic Pain*, 2nd ed.; Vleeming, A., Mooney, V., Stoockart, R., Wilson, P., Eds.; Churchill Livingstone: Edinburgh, UK, 2007; pp. 405–425, ISBN 978-0-443-10178-6.
13. Dye, B.A. 12—Epidemiology and Research Design in Dental Public Health. In *Burt and Eklund's Dentistry, Dental Practice, and the Community*, 7th ed.; Mascarenhas, A.K., Okunseri, C., Dye, B.A., Eds.; W.B. Saunders: St. Louis, MO, USA, 2021; pp. 118–130, ISBN 978-0-323-55484-8.
14. Macey, R.; Walsh, T.; Riley, P.; Glenney, A.-M.; Worthington, H.V.; O'Malley, L.; Clarkson, J.E.; Ricketts, D. Visual or visual-tactile examination to detect and inform the diagnosis of enamel caries. *Cochrane Database Syst. Rev.* **2021**, 2021, CD014546. [\[CrossRef\]](#)
15. Heitz-Mayfield, L.J.A. Conventional diagnostic criteria for periodontal diseases (plaque-induced gingivitis and periodontitis). *Periodontol. 2000* **2024**, *95*, 10–19. [\[CrossRef\]](#) [\[PubMed\]](#)
16. Ribeiro, M.F.A.; Oliveira, M.C.M.; Leite, A.C.; Bruzinga, F.F.B.; Mendes, P.A.; Grossmann, S.d.M.C.; de Araújo, V.E.; Souto, G.R. Assessment of screening programs as a strategy for early detection of oral cancer: A systematic review. *Oral. Oncol.* **2022**, *130*, 105936. [\[CrossRef\]](#)
17. Mohd Ali, J.; Hussain, M.A.; Tade, M.O.; Zhang, J. Artificial Intelligence techniques applied as estimator in chemical process systems—A literature survey. *Expert. Syst. Appl.* **2015**, *42*, 5915–5931. [\[CrossRef\]](#)
18. Thurzo, A.; Urbanová, W.; Novák, B.; Czako, L.; Siebert, T.; Stano, P.; Mareková, S.; Fountoulaki, G.; Kosnáčová, H.; Varga, I. Where Is the Artificial Intelligence Applied in Dentistry? Systematic Review and Literature Analysis. *Healthcare* **2022**, *10*, 1269. [\[CrossRef\]](#)
19. Aminoshariae, A.; Kulild, J.; Nagendrababu, V. Artificial Intelligence in Endodontics: Current Applications and Future Directions. *J. Endod.* **2021**, *47*, 1352–1357. [\[CrossRef\]](#)
20. Putra, R.H.; Doi, C.; Yoda, N.; Astuti, E.R.; Sasaki, K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofac. Radiol.* **2022**, *51*, 20210197. [\[CrossRef\]](#)
21. Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of artificial intelligence in the analysis of dental panoramic radiographs: An overview of systematic reviews. *Dentomaxillofac. Radiol.* **2023**, *52*, 20230284. [\[CrossRef\]](#) [\[PubMed\]](#)
22. Güneç, H.G.; Ürkmez, E.Ş.; Danacı, A.; Dilmaç, E.; Onay, H.H.; Aydin, K.C. Comparison of artificial intelligence vs. junior dentists' diagnostic performance based on caries and periapical infection detection on panoramic images. *Quant. Imaging Med. Surg.* **2023**, *13*, 7494503–7497503. [\[CrossRef\]](#)
23. Alowais, S.A.; Alghamdi, S.S.; Alsuhebany, N.; Alqahtani, T.; Alshaya, A.I.; Almohareb, S.N.; Aldairem, A.; Alrashed, M.; Bin Saleh, K.; Badreldin, H.A.; et al. Revolutionizing healthcare: The role of artificial intelligence in clinical practice. *BMC Med. Educ.* **2023**, *23*, 689. [\[CrossRef\]](#)
24. Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. *J. Clin. Med.* **2024**, *13*, 3686. [\[CrossRef\]](#) [\[PubMed\]](#)
25. Leite, A.F.; Gerven, A.V.; Willems, H.; Beznik, T.; Lahoud, P.; Gaëta-Araujo, H.; Vranckx, M.; Jacobs, R. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clin. Oral. Investig.* **2021**, *25*, 2257–2267. [\[CrossRef\]](#) [\[PubMed\]](#)
26. Kazimierczak, W.; Wajer, R.; Wajer, A.; Kalka, K.; Kazimierczak, N.; Serafin, Z. Evaluating the Diagnostic Accuracy of an AI-Driven Platform for Assessing Endodontic Treatment Outcomes Using Panoramic Radiographs: A Preliminary Study. *J. Clin. Med.* **2024**, *13*, 3401. [\[CrossRef\]](#) [\[PubMed\]](#)
27. Bonfanti-Gris, M.; Garcia-Cañas, A.; Alonso-Calvo, R.; Salido Rodriguez-Manzaneque, M.P.; Pradies Ramiro, G. Evaluation of an Artificial Intelligence web-based software to detect and classify dental structures and treatments in panoramic radiographs. *J. Dent.* **2022**, *126*, 104301. [\[CrossRef\]](#) [\[PubMed\]](#)
28. Ba-Hattab, R.; Barhom, N.; Osman, S.A.A.; Naceur, I.; Odeh, A.; Asad, A.; Al-Najdi, S.A.R.N.; Ameri, E.; Daer, A.; Silva, R.L.B.D.; et al. Detection of Periapical Lesions on Panoramic Radiographs Using Deep Learning. *Appl. Sci.* **2023**, *13*, 1516. [\[CrossRef\]](#)
29. Başaran, M.; Çelik, Ö.; Bayrakdar, I.S.; Bilgir, E.; Orhan, K.; Odabaş, A.; Aslan, A.F.; Jagtap, R. Diagnostic charting of panoramic radiography using deep-learning artificial intelligence system. *Oral. Radiol.* **2022**, *38*, 363–369. [\[CrossRef\]](#)
30. Akoglu, H. User's guide to sample size estimation in diagnostic accuracy studies. *Turk. J. Emerg. Med.* **2022**, *22*, 177–185. [\[CrossRef\]](#)
31. ISO Standard No. 3950:2016; Dentistry—Designation System for Teeth and Areas of the Oral Cavity. International Organization for Standardization: Geneva, Switzerland, 2016. Available online: <https://www.iso.org/standard/68292.html> (accessed on 15 September 2024).
32. Evans, H.J.; Gibson, N.A.; Bennett, J.; Chan, S.Y.; Gavlak, J.; Harman, K.; Ismail-Koch, H.; Kingshott, R.N.; Langley, R.; Morley, A.; et al. British Thoracic Society guideline for diagnosing and monitoring paediatric sleep-disordered breathing. *Thorax* **2023**, *78*, s1–s27. [\[CrossRef\]](#)

33. Khanagar, S.B.; Al-ehaideb, A.; Maganur, P.C.; Vishwanathaiah, S.; Patil, S.; Baeshen, H.A.; Sarode, S.C.; Bhandi, S. Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *J. Dent. Sci.* **2021**, *16*, 508–522. [\[CrossRef\]](#)
34. Umer, F.; Habib, S.; Adnan, N. Application of deep learning in teeth identification tasks on panoramic radiographs. *Dentomaxillofac. Radiol.* **2022**, *51*, 20210504. [\[CrossRef\]](#)
35. Hung, K.; Montalvao, C.; Tanaka, R.; Kawai, T.; Bornstein, M.M. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac. Radiol.* **2020**, *49*, 20190107. [\[CrossRef\]](#) [\[PubMed\]](#)
36. Tuzoff, D.V.; Tuzova, L.N.; Bornstein, M.M.; Krasnov, A.S.; Kharchenko, M.A.; Nikolenko, S.I.; Sveshnikov, M.M.; Bednenko, G.B. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac. Radiol.* **2019**, *48*, 20180051. [\[CrossRef\]](#)
37. Vinayahalingam, S.; Goey, R.; Kempers, S.; Schoep, J.; Cherici, T.; Moin, D.A.; Hanisch, M. Automated chart filing on panoramic radiographs using deep learning. *J. Dent.* **2021**, *115*, 103864. [\[CrossRef\]](#) [\[PubMed\]](#)
38. Zadrożny, Ł.; Regulski, P.; Brus-Sawczuk, K.; Czajkowska, M.; Parkanyi, L.; Ganz, S.; Mijiritsky, E. Artificial Intelligence Application in Assessment of Panoramic Radiographs. *Diagnostics* **2022**, *12*, 224. [\[CrossRef\]](#)
39. Agrawal, S.K.; Bhagat, T.; Shrestha, A. Dental Caries in Permanent First Molar and Its Association with Carious Primary Second Molar among 6–11-Year-Old School Children in Sunsari, Nepal. *Int. J. Dent.* **2023**, *2023*, 9192167. [\[CrossRef\]](#)
40. Khattak, O.; Iqbal, A.; Nadeem Baig, M.; Magar, S.P.; Magar, S.S.; Mehmood Khan, A.; Osamah Molla, F.; Alhabib, S.; Alruwaili, S. Prevalence of Caries in Anterior Teeth in Adults; An Epidemiology Study. *PJMHS* **2021**, *15*, 3421–3423. [\[CrossRef\]](#)
41. Lofthag-Hansen, S.; Huuonen, S.; Gröndahl, K.; Gröndahl, H.-G. Limited cone-beam CT and intraoral radiography for the diagnosis of periapical pathology. *Oral Surg. Oral Med. Oral Pathol. Oral Radiol. Endod.* **2007**, *103*, 114–119. [\[CrossRef\]](#)
42. Ramis-Alario, A.; Tarazona-Alvarez, B.; Cervera-Ballester, J.; Soto-Peñaloza, D.; Peñarrocha-Diago, M.; Peñarrocha-Oltra, D.; Peñarrocha-Diago, M. Comparison of diagnostic accuracy between periapical and panoramic radiographs and cone beam computed tomography in measuring the periapical area of teeth scheduled for periapical surgery. A cross-sectional study. *J. Clin. Exp. Dent.* **2019**, *11*, e732–e738. [\[CrossRef\]](#)
43. Kazimierczak, W.; Wajer, R.; Wajer, A.; Kiian, V.; Kloska, A.; Kazimierczak, N.; Janiszewska-Olszowska, J.; Serafin, Z. Periapical Lesions in Panoramic Radiography and CBCT Imaging—Assessment of AI's Diagnostic Accuracy. *J. Clin. Med.* **2024**, *13*, 2709. [\[CrossRef\]](#)
44. Altan, B.; Gunec, H.G.; Cinar, S.; Kutal, S.; Gulum, S.; Aydin, K.C. Detecting Prosthetic Restorations Using Artificial Intelligence on Panoramic Radiographs. *Sci. Program.* **2022**, *2022*, 6384905. [\[CrossRef\]](#)
45. *Obwieszczenie Ministra Zdrowia z dnia 10 listopada 2015 r. w Sprawie Ogłoszenia Wykazu Wzorcowych Procedur Radiologicznych z Zakresu Radiologii—Diagnostyki Obrazowej i Radiologii Zabiegowej*; Dziennik Urzędowy Ministra Zdrowia: Warsaw, Poland, 2015; p. 43. Available online: <https://dziennikmz.mz.gov.pl/legalact/2015/78/> (accessed on 15 September 2024).
46. Johnson, M. DDS Saving Teeth with Endodontic Treatment: Lesion Size and Predictability of Healing. Available online: <https://www.perioimplantadvisory.com/periodontics/article/14178968/saving-teeth-with-endodontic-treatment-lesion-size-and-predictability-of-healing> (accessed on 13 September 2024).
47. Chapter 9—Management of pulpal and periradicular disease. In *Restorative Dentistry*, 2nd ed.; Walmsley, A.D., Walsh, T.F., Lumley, P.J., Burke, F.J.T., Shortall, A.C.C., Hayes-Hall, R., Pretty, I.A., Eds.; Churchill Livingstone: Edinburgh, UK, 2007; pp. 89–113, ISBN 978-0-443-10246-2.

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

Article

Artificial Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical Study

Natalia Turosz ^{1,*}, Kamila Chęcińska ², Maciej Chęciński ³, Karolina Lubecka ³, Filip Bliźniak ³
and Maciej Sikora ^{1,4,*}

¹ Department of Maxillofacial Surgery, Hospital of the Ministry of Interior, Wojska Polskiego 51, 25-375 Kielce, Poland

² Department of Glass Technology and Amorphous Coatings, Faculty of Materials Science and Ceramics, AGH University of Science and Technology, Mickiewicza 30, 30-059 Kraków, Poland; checinska@agh.edu.pl

³ Department of Oral Surgery, Preventive Medicine Center, Komorowskiego 12, 30-106 Kraków, Poland; maciej@checinscy.pl (M.C.); lubeckarolina@gmail.com (K.L.); fbliźniak@gmail.com (F.B.)

⁴ Department of Biochemistry and Medical Chemistry, Pomeranian Medical University, Powstańców Wielkopolskich 72, 70-111 Szczecin, Poland

* Correspondence: natalia.turosz@gmail.com (N.T.); sikora-maciej@wp.pl (M.S.)

Abstract: This clinical study aimed to evaluate the sensitivity, specificity, accuracy, and precision of artificial intelligence (AI) in assessing permanent teeth in pediatric patients. Over one thousand consecutive DPRs taken in Kielce, Poland, with the Carestream CS9600 device were screened. In the study material, 35 dental panoramic radiographs (DPRs) of patients of developmental age were identified and included. They were automatically evaluated with an AI algorithm. The DPRs were then analyzed by researchers. The status of the following dichotomous variables was assessed: (1) decay, (2) missing tooth, (3) filled tooth, (4) root canal filling, and (5) endodontic lesion. The results showed high specificity and accuracy (all above 85%) in detecting caries, dental fillings, and missing teeth but low precision. This study provided a detailed assessment of AI performance in a previously neglected age group. In conclusion, the overall accuracy of AI algorithms for evaluating permanent dentition in dental panoramic radiographs is lower for pediatric patients than adults or the entire population. Hence, identifying primary teeth should be implemented in AI-driven software, at least so as to ignore them when assessing mixed dentition (ClinicalTrials.gov registration number: NCT06258798).

Keywords: dental caries; artificial intelligence; panoramic radiography; DMF index



Citation: Turosz, N.; Chęcińska, K.; Chęciński, M.; Lubecka, K.; Bliźniak, F.; Sikora, M. Artificial Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical Study. *Pediatr. Rep.* **2024**, *16*, 794–805. <https://doi.org/10.3390/pediatric16030067>

Academic Editor: Maurizio Aricò

Received: 8 July 2024

Revised: 26 August 2024

Accepted: 4 September 2024

Published: 11 September 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

1.1. Background

Dental caries is one of the most prevalent diseases among children, caused by factors such as the frequent consumption of sugars, poor oral hygiene, and insufficient fluoride exposure [1,2]. Researchers are also looking for genetic factors predisposing to dental caries [3–5]. It develops more rapidly in deciduous teeth than in permanent ones, as their enamel is significantly thinner [6].

The decayed, missing, and filled teeth (DMF) index is an indicator used for the initial assessment of dental conditions among the population undergoing preventive dental visits or during the initial visit where dental treatment is planned. As the index can evaluate primary, mixed, and permanent teeth, it is useful for both children and adult patients [7]. For this reason, it is an important indicator for this study, as it focuses on this type of assessment of the changes in the teeth of pediatric patients. Originally, the DMF index values were determined using basic instruments during physical examination. However, if dental radiography is available, it may supplement physical examination. In this study, the classic DMF index was expanded to DMFRE to include the detection of root canal

fillings (R) and endodontic lesions (E). This step was taken to make this study even more comprehensive and additionally check the efficiency of the AI algorithm in assessing these aspects. This may determine the direction of the development of algorithms in the assessment of dental radiographs in the near future.

The diagnosis of caries relies mainly on visual–tactile examination and imaging tests, including dental panoramic radiographs (DPRs) [8]. Various indicators assessing the epidemiology of dental caries are calculated based on the above examinations. DPRs are a valuable diagnostic tool, providing information about all teeth and the maxillofacial skeleton [9]. The quality of modern panoramic radiographs allows for assessing individual teeth and the condition of the periodontium, both marginal and periapical. However, identifying early caries lesions may be difficult, as only a 30–40% loss of enamel mineral will be detectable during radiological examination [10,11].

DPR examination involves radiation and generally requires indications. While performing a control panoramic radiograph every few years in adults seems to be justified, in the case of pediatric patients, it may be controversial. However, indications for DPRs in children do exist and include, among others, diagnoses in the field of orthodontics and dental surgery such as (1) development evaluation and teeth location, (2) bone lesions, (3) identification of foreign bodies, or (4) craniofacial trauma [12]. As DPRs provide a lot of information, not every dentist has enough time to thoroughly analyze radiographs and detect pathologies outside their specialty. It is reasonable to believe that every DPR should be evaluated and described by a dentist with appropriate training or a radiologist specializing in the evaluation of dental radiographs. However, the time and cost of such work significantly limit such an approach.

1.2. Rationale

Artificial intelligence (AI) is the ability of computers and machines to perform tasks that would typically require human intelligence or intervention [13]. Its application also includes the pediatric field, helping in diagnosing, e.g., pulmonary diseases, and improving neonatal daily care or fetal urology [13–15]. This technology has also been introduced in pedodontics in the automated charting of dental status, detecting permanent tooth germs, and classifying supernumerary teeth, including mesiodens [16]. Predicting early childhood caries with an AI-driven model can be helpful in identifying high-risk groups and implementing appropriate prevention [17]. The rapid advancement of artificial intelligence (AI) gives hope for automating the screening of DPRs [18,19]. This technology can be beneficial in providing results, even if it means overestimating issues (type I error), as it would motivate dentists to verify the diagnoses and reduce the risk of omissions. However, it is difficult to determine the general sensitivity of AI algorithms in assessing DPRs. Various aspects are analyzed separately, such as teeth identification and numbering, detecting caries, periapical lesions, or periodontal bone loss. There are already systematic reviews on this topic, and recently, an overview of such reviews has also been published [18]. It shows that AI rates are increasing year by year, which indicates the promising potential of this technology in the daily assessment of DPRs. Nevertheless, these findings refer to the radiographs of adult patients. AI faces some challenges in pediatric radiography, like paucity of data, partly due to ethical concerns and stricter regulations regarding data [20,21]. Radiographs may not be of high quality because of motion artifacts. Moreover, the presence of mixed dentition and the ongoing development of permanent teeth can significantly complicate the assessment of the algorithm. Overlapping images of primary and permanent tooth tissues, as well as the resorption of primary teeth caused by erupting permanent teeth, may pose additional difficulties for the still incipient algorithm. In addition, the shape of a tooth changes during development, so the algorithm needs to be trained for each stage of the development of each type of tooth (incisor, canine, premolar, molar). However, it is crucial to assess the effectiveness of AI in evaluating mixed dentition and developmental stages. No studies were found that used this technology for comprehensive DPR analysis in pediatric patients.

1.3. Aim

The aim of this clinical study was to determine the sensitivity, specificity, accuracy, and precision of an AI algorithm in the assessment of permanent teeth with incomplete development and mixed dentition in pediatric patients.

2. Materials and Methods

2.1. Study Design

This study was designed as a prospective double-gate trial of diagnostic accuracy. It aimed to calculate the sensitivity, specificity, precision, and accuracy of the AI algorithm by evaluating the same DPR twice—first by the AI algorithm and then by researchers. The performance metrics revealed a discrepancy between the human evaluation (reference test) and the test results of the algorithm analysis (index text). The study was conducted according to the guidelines of the Declaration of Helsinki and approved by the Świętokrzyska Medical Chamber in Kielce Bioethics Committee (2.3/2023 of 31 August 2023) and ClinicalTrials.gov (NCT06258798) [22,23]. The research report was prepared under the STARD 2015 protocol [24].

2.2. Research Material

Consecutive DPRs of developmental-age patients were included in the study. The detailed study inclusion and exclusion criteria were defined following the acronym PICOS (population, intervention, comparator, outcomes, and settings). They are presented in Table 1. The inclusion condition based on the population criterion was the presence of at least one permanent tooth with unfinished development, other than a wisdom tooth, in the DPR. Unfinished development was understood as any stage of crown and root development (from C_1 to $A_{1/2}$), before root apices closure (A_c) [25].

Table 1. Criteria for inclusion and criteria for exclusion.

	Inclusion Criteria	Exclusion Criteria
Population	DPRs of patients with incomplete development of permanent dentition	Incomplete development of third molars only
Intervention	Assessment of the presence and condition of each permanent tooth by an AI algorithm	Incomplete or erroneous results due to software or human error
Comparator	Assessment of the presence and condition of each permanent tooth by researchers	Not applicable
Outcomes	Variables regarding the condition of teeth: decay, missing, filled, root canal filling, endodontic lesion	Not applicable
Settings	DPRs from 2022–2023 from a single diagnostic imaging facility in Kielce, Poland	DPRs of a quality inconsistent with local regulations

According to the current overview, AI algorithms achieve the highest accuracy for the missing teeth variable, on average 93.67% [18]. The missing teeth identification sensitivity is 97% [18]. There are no specific data for pediatric patients. We assumed a 5% type I error, a prevalence of 9% estimated based on preliminary data, and a marginal error of 10% [26]. The required sample size calculated with a Sample Size Estimation for Diagnostic Accuracy Studies tool was 124 tests [27]. Due to probable differences between the values of variables for the individual 8 positions in the oral quadrant, we increased the sample size to 1120 tests for each variable (32 oral locations on 35 DPRs).

2.3. Test Methods

In the study, the provided AI-driven software was used to analyze DPRs taken with the Carestream CS 9600 device. An automated dental chart for each radiograph was obtained. Then, human analysis was performed. The reference point was the assessment of a 4-year experienced doctor of dental surgery and engineer (N.T.). In case of doubt, a doctor of dental surgery and maxillofacial surgeon with 12 years of experience had an advisory vote (M.C.). To ensure inter-rater reliability, rater training, standardization of procedures, pilot tests, and calibration sessions were undertaken. Both investigators completed the same dedicated radiograph assessment training organized by the Polish Supreme Medical Chamber. Then, they conducted pilot radiograph assessments using the AI algorithm discussed in this study. Based on a detailed analysis of the algorithmic assessment results, they standardized the human assessment procedures. Then, pilot tests were performed, and several calibration sessions (including the use of external reference images) were performed to eliminate differences in the interpretation of the same radiological image.

The sensitivity, specificity, accuracy, and precision (Table 2) of the AI algorithm were calculated, which are typically reported to summarize the performance of a model [28]. They are often used to evaluate algorithms performing DPR analysis [18]. The choice of variables resulted directly from the capabilities of the tested algorithm. The status of the following dichotomous variables was assessed: (1) decay—the presence of at least one defect in the crown of a permanent tooth, (2) missing—the absence of a permanent tooth in a given position in the oral cavity, (3) filled—the presence of at least one filling in a permanent tooth, (4) root canal filling—the presence of at least partial filling in the chamber or root canal of a permanent tooth, (5) endodontic lesion—the presence of radiolucency covering the apex of at least one of the roots of a permanent tooth. A conclusive result was understood as a confirmation or denial of a given diagnosis (decay, missing tooth, filling, etc.). The algorithm used did not provide other, i.e., inconclusive, results. The lack of a decision by the researchers regarding the diagnosis in a given location of the oral cavity was defined as an inconclusive result.

Table 2. Performance metrics used in the study.

Performance Metric	Formula
Sensitivity	$\frac{TP}{TP+FN}$
Specificity	$\frac{TN}{TN+FP}$
Precision	$\frac{TP}{TP+FP}$
Accuracy	$\frac{TP+TN}{TP+FP+TN+FN}$

TP—true positive; TN—true negative; FP—false positive; FN—false negative

2.4. Analyses

The agreement between the AI and human assessment results was analyzed for all patients, all 32 oral positions corresponding to the natural positions of permanent teeth, and all five Boolean variables discussed above. The sensitivity, specificity, accuracy, and precision of the measurements depending on the variable and position in the oral cavity were calculated. In addition, the Pearson's correlation coefficients of false-positive and false-negative results with the presence of a primary tooth in a given position in the oral cavity were calculated. The absolute values of the coefficient were interpreted as follows: (1) 0.00–0.09—negligible correlation; (2) 0.10–0.39—weak correlation; (3) 0.40–0.69—moderate correlation; (4) 0.70–0.89—strong correlation; (5) 0.90–1.00—very strong correlation.

The results were presented in tables and charts. Google Sheets (version 2024.05.31, Google LLC, Mountain View, CA, USA) and MedCalc software (version 23.0.1; MedCalc Software Ltd., Ostend, Belgium) were used [29].

3. Results

3.1. Sample Tested

In the study, 1021 consecutive DPRs were screened. All these radiographs were taken using the device Carestream CS9600 at a radiology department located in Kielce, a city in southern Poland, between September 2022 and June 2023. Most of the radiographs (97%) were rejected at the screening stage as non-pediatric. As a result, the DPRs of 35 patients of developmental age (16 females and 19 males) were included in the study. None of the initially qualified radiographs were excluded during further evaluation. There were no algorithm nor human errors resulting in missing or partial results. The average age of participants was approximately 10 years old (SD = 2.2, Range = 10).

3.2. Test Results

The principal investigator assessing DPRs had concerns in 22 (2%) of 1120 oral locations. In these cases, the initial assessment was verified by the other researcher. The raw results for individual variables and the results of the calculations of the sensitivity, specificity, accuracy, and precision of the AI algorithm are presented in Table 3. This table is a collective presentation of all tests with content corresponding to the STARD 2015 flow diagram [24]. The number of potentially eligible participants was equal to the eligible participants' number and the tested participants' number and was 35. There was no case of a missing reference standard. There were no inconclusive test results for either AI or human evaluation. The numbers of teeth identified by the AI and investigators for each diagnosis are presented in Figures 1–3.

Table 3. Outcomes.

	Decay	Missing	Filled	Root Canal Filling	Endodontic Lesion
Index test negative	991	1024	1044	1117	1090
Reference test negative	1075	1033	1087	1119	1115
Index test positive	129	96	76	3	30
Reference test positive	45	87	33	1	5
True positive results (correctly identified)	34	13	29	1	2
True negative results (correctly excluded)	980	950	1040	1117	1087
False-positive results (overdiagnosed)	95	83	47	2	28
False-negative results (misdiagnosed)	11	74	4	0	3
Sensitivity	75.56% (95% CI 60.46% to 87.12%)	14.94% (95% CI 8.20% to 24.20%)	87.88% (95% CI 71.80% to 96.60%)	100.00% (95% CI 2.50% to 100.00%)	40.00% (95% CI 5.27% to 85.34%)
Specificity	91.16% (95% CI 89.30% to 92.79%)	91.97% (95% CI 90.14% to 93.55%)	95.68% (95% CI 94.29% to 96.81%)	99.82% (95% CI 99.36% to 99.98%)	97.49% (95% CI 96.39% to 98.32%)
Precision	26.36% (95% CI 21.73% to 31.57%)	13.54% (95% CI 8.35% to 21.22%)	38.16% (95% CI 31.22% to 45.62%)	33.33% (95% CI 11.13% to 66.63%)	6.67% (95% CI 2.25% to 18.17%)
Accuracy	90.54% (95% CI 88.67% to 92.19%)	85.98% (95% CI 83.81% to 87.96%)	95.45% (95% CI 94.06% to 96.59%)	99.82% (95% CI 99.36% to 99.98%)	97.23% (95% CI 96.09% to 98.11%)

CI—confidence interval.




Figure 1. Decayed teeth by their location in the oral cavity.




Figure 2. Missing teeth by their location in the oral cavity.




Figure 3. Filled teeth by their location in the oral cavity.

Based on the researchers' assessment, the examined material revealed 224 primary teeth. This means that, statistically, deciduous teeth were present in 20% of the examined positions in the oral cavity. Therefore, there were, on average, 6.4 primary teeth per DPR. The correlations between a false-positive or a false-negative response in the index test and the presence of a primary tooth in a given position in the oral cavity were calculated. The results are presented in Table 4. None of them were strong. When assessing decayed and missing teeth, a slight positive correlation with false-positive results and a slight negative correlation with false-negative results is noteworthy. For the remaining variables, no correlation of the AI error with the presence of a primary tooth in a given position in the oral cavity was observed.

Table 4. Correlations of primary teeth presence with false positives and false negatives.

	Decayed Teeth	Missing Teeth	Filled Teeth	Root Canal Filling	Endodontic Lesions
Correlation with false positives	0.20	0.07	0.00	−0.02	−0.04
Correlation with false negatives	−0.05	−0.13	−0.03	N/A	−0.03

N/A—not applicable.

4. Discussion

The accuracy of artificial intelligence algorithms in evaluating permanent teeth in dental panoramic radiographs is lower for pediatric patients than for adults or the general population, showing high specificity but low precision.

4.1. Decayed Teeth

The results of the caries assessment by AI in this study are worth comparing with the results of two systematic reviews by Mohammad-Rahimi et al. and Prados-Privado et al., who reviewed deep learning studies on radiological caries detection [30,31]. In the first review, the average specificity of the analyzed models was 86%, precision was 84.97%, accuracy was 89.67%, and sensitivity was not assessed [30]. In the second review, only accuracy was assessed, and it reached 86% [31]. The results of our study are, therefore, comparable to the specificity and accuracy of the abovementioned reviews, except for a significant difference in precision (26.36% in the current study versus 84.97% in Mohammad-Rahimi et al.) [30]. The algorithm detected caries in 129 teeth, while the researchers identified this disease in 45 teeth. The number of decay-free teeth was 991 for the AI software and 1075 for the researcher, respectively. The calculated sensitivity of 75% was higher than in the preliminary study from 2023, where the AI framework was used to detect caries in DPRs and achieved 55.4% [32]. This performance metric was also higher compared to the study that used a deep convolutional neural network (CNN) to detect caries, which had a sensitivity of 44.5% [33]. However, it was lower than the 84% sensitivity achieved in identifying dentin caries in bitewings [34]. This difference may be attributed to bitewing radiographs being superior to DPRs for decay detection [35]. A positive correlation with false-positive results and a negative correlation with false-negative results in identifying teeth affected by caries suggest the subtle influence of the presence of a primary tooth in the assessment. It, therefore, can be assumed that a radiological image suggesting decay in a primary tooth may be interpreted by the AI algorithm as if it were in a permanent tooth.

4.2. Missing Teeth

Identically directed correlations are observed when assessing the presence of a permanent tooth in a given position in the oral cavity. The presence of a deciduous tooth increases the chance that the algorithm misidentifies a permanent tooth in a specific location. The absence of a deciduous tooth has the opposite effect, i.e., it increases the risk that the AI

omits a permanent tooth. It should be emphasized, however, that these correlations are very subtle.

The results regarding missing teeth can be compared with four other systematic reviews that also cover teeth identification and numbering by AI models [26,36–38]. In the current study, the specificity and accuracy values were high (above 85%) but still lower than in the studies included in the abovementioned systematic reviews. The algorithm identified more missing teeth (96) than the researcher (87). A very high specificity (99.4%) in detecting missing teeth also occurred in the study by Zhu et al. [32]. However, a significant difference was observed in the sensitivity and precision, which in our study are very low (approximately 14%), while in the studies by Khanagar et al. and Umer et al., they were on average above 95% [26,38]. A frequently noticeable error of the algorithm was the failure to identify the absence of third molars, which are usually noticeable in a DPR at the age of approximately 10–12 years.

4.3. Filled Teeth

The sensitivity, specificity, and accuracy of detecting dental fillings in DPRs in this study were high, reaching over 87%. The number of teeth with dental fillings identified was 76 for the algorithm and 33 for the researcher. There are two other studies assessing the reliability of AI evaluation in panoramic radiographs using a deep convolutional neural network that incorporates U-Net-like and Mask R-CNN models for segmentation and diagnosis [33,39]. In both, sensitivity and specificity were comparable, approximately 85% and 96%, respectively [33,39]. A low precision of detecting not only fillings but also dental caries and missing teeth means that the algorithm returns a lot of false positives.

For caries, a weak correlation of false-positive results with the presence of a primary tooth in a given position in the oral cavity is observed. However, there is no such correlation for the assessment of dental fillings. Artificial intelligence algorithms are trained to detect based on the appearance of the radiological image, which in the case of fillings, most often means a strong radiological hyperdense area. They should be differentiated, among other things, from the overlap of images of two adjacent teeth. It was noticed that sometimes the algorithm classified orthodontic fixed appliances such as brackets or molar bands as fillings.

Reducing the number of false positives and thus improving precision can be achieved by further training of the algorithm, in particular, undertaking training on mixed dentition. Alternatively, it should be considered to limit the evaluation of restorations in DPRs in favor of dedicated bitewing radiographs.

4.4. Root Canal Fillings and Endodontic Lesions

The number of root canal filling (3) and endodontic lesion (30) cases identified was too small to discuss these calculated indicators. It was impossible to calculate the sample size for these variables, and the one used appeared insufficient. Nevertheless, attention must be drawn to the over-detection of endodontic lesions by the AI, which probably resulted from incomplete root development. It manifests with radiolucency in DPRs, often strikingly similar to periapical periodontitis. In such cases, a trained professional evaluates the entire tooth and determines whether there are any radiological indications of typical co-occurring conditions, e.g., deep caries or fracture, which AI is currently incapable of. Therefore, in future work on the algorithmic assessment of the tooth chamber, root canals and periapical tissues, the possibility of linking the tooth crown state with the probability of periapical lesions should be considered. In addition, the proximity of the radiological image of unfinished root apex development to periapical periodontitis provides a basis for taking into account the patient's age.

4.5. Limitations

This study was conducted using only one AI algorithm. Individual algorithms are trained differently and produce different performance metrics. Therefore, it is not possible to extrapolate the results obtained to the overall capabilities of AI in analyzing DPRs.

Panoramic radiographs from a single diagnostic imaging facility were included. The frequency of specific diagnoses depends, among other things, on the selection of the study population. This study included patients who underwent diagnostic imaging in a medium-sized city in central Europe, all Caucasians. Hence, future studies should consider involving various, or even better, multiple centers.

Due to the paucity of data from previous studies, the sample size was calculated only based on the missing teeth variable. The required sample sizes for the variables decay, filled, root canal filling, and endodontic lesion have not yet been determined. Since the reference studies showed the highest accuracy for the variable missing teeth, it is assumed that smaller samples would be sufficient to assess the accuracy for the remaining variables. This and future studies will serve to refine the required sample sizes.

Another limitation is the assumption of the infallibility of human judgment, as doctors who evaluate panoramic radiographs and radiographs in general are fallible [40]. This was a necessary simplification resulting from the need to provide reference outcomes. Every doubt was consulted to reduce the percentage of errors. However, DPR analyses performed by different specialists can differ and lead to inconsistencies. The accuracy of diagnoses can depend on the experience or fatigue level of the dentist. The same person may also interpret the same radiograph differently at various times.

Primary dentition was also not assessed in this study as the algorithm was trained on permanent teeth. In the examined material, most of the deciduous teeth were partially resorbed in preparation for natural exfoliation. The lack of assessment of primary teeth in ideal conditions should not affect the assessment of permanent teeth. Nevertheless, it has been shown that there is an over-detection of decay and an under-detection of missing teeth in the case of a primary tooth in a given position in the oral cavity.

4.6. Strengths

The strengths of this study lie in its detailed assessment of AI performance in a previously neglected age group. This study provides information on the specific challenges AI faces when assessing the developing dentition of children.

The distinctions of sensitivity, specificity, precision, and accuracy in AI assessments are not standard in similar studies. They highlight directions for further training of the algorithm to achieve reliability in correctly identifying the presence of permanent teeth, caries, and fillings.

4.7. Future Perspectives

Given the increasing performance indicators of algorithmic DPR assessment, there is a temptation to raise the bar. AI detects basic pathologies in standard DPRs to a fairly satisfactory extent. The AI-driven assessment of unusual images is still a challenge. The atypicality may result from imaging errors, anatomical disorders, pathology presence, and developmental age. According to the presented results, the assessment of permanent dentition in the DPRs of pediatric patients can be performed algorithmically, but it is subject to greater errors. As for primary teeth, if carried out at all, an erroneous evaluation of a tooth that the algorithm interpreted as permanent occurs. Hence, identifying primary teeth should be implemented, at least so as to ignore them when assessing mixed dentition. Ultimately, deciduous dentition should undergo the same evaluation as permanent ones.

Nevertheless, the algorithm that was tested performed well, even though it was not intended to assess mixed dentition. It achieved specificity and accuracy values in detecting caries and missing teeth that were similar to those achieved in the AI models reported in a recent systematic review [18].

5. Conclusions

The overall accuracy of artificial intelligence algorithms for evaluating permanent dentition in dental panoramic radiographs is notably lower for pediatric patients compared to adults or the general population. Although the assessments demonstrate high specificity, they suffer from low precision. Low precision, and therefore a higher number of false positives, is a leading characteristic of the algorithmic assessment of mixed dentition, regardless of the diagnosis tested.

The lowest accuracy and sensitivity in detecting the absence of a permanent tooth in a specific position within the oral cavity may be largely attributed to the misidentification of primary teeth as permanent teeth, underscoring the need for more refined algorithms that account for the unique dental characteristics of pediatric patients.

The single-algorithm and single-center designs, inability to calculate sample size for most variables, assumption of the infallibility of human assessments, and the impossibility of primary dentition assessment limited the study design. Therefore, AI algorithms should be trained in the assessment of primary teeth in mixed dentition and further similar studies should be conducted in different populations or in multiple centers.

Author Contributions: Conceptualization, N.T. and M.S.; methodology, N.T. and M.C.; software, N.T. and K.C.; validation, K.L., F.B. and M.S.; formal analysis, N.T., K.C. and M.C.; investigation, N.T. and K.L.; resources, N.T.; data curation, N.T.; writing—original draft preparation, N.T., K.C., M.C., K.L. and F.B.; writing—review and editing, N.T., M.C., F.B. and M.S.; visualization, N.T. and M.C.; supervision, M.S.; project administration, M.S. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: This study was conducted in accordance with the Declaration of Helsinki and approved by the Bioethics Committee in Kielce at the Świętokrzyska Chamber of Physicians (approval number: 2.3/2023; 31 August 2023). The study protocol was registered in the ClinicalTrials.gov database: NCT06258798.

Informed Consent Statement: Patient consent was waived due to the inclusion in the research material of only dental panoramic radiographs previously performed following therapeutic needs and then anonymized. No further radiographs or other interventions were performed for this study.

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors on request.

Acknowledgments: We would like to thank Iwo Rutański at the Optident Sp. z o.o. company, for providing us with AI software and technical support.

Conflicts of Interest: The authors declare no conflicts of interest.

References

1. Mathur, V.P.; Dhillon, J.K. Dental Caries: A Disease Which Needs Attention. *Indian J. Pediatr.* **2018**, *85*, 202–206. [[CrossRef](#)] [[PubMed](#)]
2. Rathee, M.; Sapra, A. Dental Caries. In *StatPearls*; StatPearls Publishing: Treasure Island, FL, USA, 2024.
3. Olszowski, T.; Milona, M.; Janiszewska-Olszowska, J.; Safranow, K.; Uzar, I.; Walczak, A.; Sikora, M.; Chlubek, D.; Adler, G. FCN1 Polymorphisms Are Not the Markers of Dental Caries Susceptibility in Polish Children: A Case-Control Study. *Oral. Dis.* **2022**, *28*, 771–776. [[CrossRef](#)] [[PubMed](#)]
4. Olszowski, T.; Milona, M.; Janiszewska-Olszowska, J.; Safranow, K.; Skonieczna-Żydecka, K.; Walczak, A.; Sikora, M.; Chlubek, D.; Madlani, A.; Adler, G. The Lack of Association between FCN2 Gene Promoter Region Polymorphisms and Dental Caries in Polish Children. *Caries Res.* **2017**, *51*, 79–84. [[CrossRef](#)] [[PubMed](#)]
5. Milona, M.; Olszowski, T.; Uzar, I.; Safranow, K.; Janiszewska-Olszowska, J.; Szmidi-Kądys, M.; Rola, H.; Sikora, M.; Chlubek, D.; Adler, G. TLR2 and TLR4 Polymorphisms Are Not Associated with Dental Caries in Polish Children. *Int. J. Mol. Sci.* **2024**, *25*, 6985. [[CrossRef](#)]
6. Tungare, S.; Paranjpe, A.G. Early Childhood Caries. In *StatPearls*; StatPearls Publishing: Treasure Island, FL, USA, 2024.
7. DMF Index—An Overview | ScienceDirect Topics. Available online: <https://www.sciencedirect.com/topics/medicine-and-dentistry/dmf-index> (accessed on 20 June 2024).
8. Ghodasra, R.; Brizuela, M. Dental Caries Diagnostic Testing. In *StatPearls*; StatPearls Publishing: Treasure Island, FL, USA, 2024.

9. Różyło-Kalinowska, I. Panoramic Radiography in Dentistry. *Clin. Dent. Rev.* **2021**, *5*, 26. [CrossRef]
10. Rodrigues, J.A.; Hug, I.; Diniz, M.B.; Lussi, A. Performance of Fluorescence Methods, Radiographic Examination and ICDAS II on Occlusal Surfaces in Vitro. *Caries Res.* **2008**, *42*, 297–304. [CrossRef]
11. Pulido, G.; Arango, M.; Adriana, H.; Gaviria, Á.; Ocampo, J.; Gutiérrez, B.; Martínez, C.; Sinisterra, G.; Valencia, C. Degree of Concordance Between Cone Beam Computerized Tomography (Cbct) And 2d Digital Radiography System Used for Caries Diagnosis: An Observational Study. *Open Dent. J.* **2023**, *17*, e230414. [CrossRef]
12. American Dental Association. *Dental Radiographic Examinations: Recommendations for Patient Selection And Limiting Radiation Exposure*; American Dental Association: Chicago, IL, USA, 2012.
13. Li, Y.-W.; Liu, F.; Zhang, T.-N.; Xu, F.; Gao, Y.-C.; Wu, T. Artificial Intelligence in Pediatrics. *Chin. Med. J.* **2020**, *133*, 358–360. [CrossRef]
14. Della Corte, M.; Clemente, E.; Checcucci, E.; Amparore, D.; Cerchia, E.; Tulelli, B.; Fiori, C.; Porpiglia, F.; Gerocarni Nappo, S. Pediatric Urology Metaverse. *Surgeries* **2023**, *4*, 325–334. [CrossRef]
15. Padash, S.; Mohebbian, M.R.; Adams, S.J.; Henderson, R.D.E.; Babyn, P. Pediatric Chest Radiograph Interpretation: How Far Has Artificial Intelligence Come? A Systematic Literature Review. *Pediatr. Radiol.* **2022**, *52*, 1568–1580. [CrossRef]
16. Vishwanathaiah, S.; Fageeh, H.N.; Khanagar, S.B.; Maganur, P.C. Artificial Intelligence Its Uses and Application in Pediatric Dentistry: A Review. *Biomedicines* **2023**, *11*, 788. [CrossRef] [PubMed]
17. Park, Y.-H.; Kim, S.-H.; Choi, Y.-Y. Prediction Models of Early Childhood Caries Based on Machine Learning Algorithms. *Int. J. Environ. Res. Public Health* **2021**, *18*, 8613. [CrossRef] [PubMed]
18. Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of Artificial Intelligence in the Analysis of Dental Panoramic Radiographs: An Overview of Systematic Reviews. *Dentomaxillofac. Radiol.* **2023**, *52*, 20230284. [CrossRef]
19. Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. *J. Clin. Med.* **2024**, *13*, 3686. [CrossRef]
20. Frontier, A. Flywheel & AWS | Navigating the Pediatric AI Frontier: Overcoming Data Challenges [Internet]. Flywheel.io. 2024. Available online: <https://flywheel.io/insights/youtube-insights/flywheel-aws-navigating-the-pediatric-ai-frontier-overcoming-data-challenges> (accessed on 6 September 2024).
21. Di Sarno, L.; Caroselli, A.; Tonin, G.; Graglia, B.; Pansini, V.; Causio, F.A.; Gatto, A.; Chiaretti, A. Artificial Intelligence in Pediatric Emergency Medicine: Applications, Challenges, and Future Perspectives. *Biomedicines* **2024**, *12*, 1220. [CrossRef] [PubMed]
22. WMA. The World Medical Association Declaration of Helsinki: Ethical Principles for Medical Research Involving Human Subjects. *J. Am. Med. Assoc.* **2013**, *310*, 2191–2194. [CrossRef]
23. Study Details | The Use of Artificial Intelligence in the Dental X-rays Analysis | ClinicalTrials.Gov. Available online: <https://clinicaltrials.gov/study/NCT06258798?cond=NCT06258798&rank=1> (accessed on 22 August 2024).
24. Cohen, J.F.; Korevaar, D.A.; Altman, D.G.; Bruns, D.E.; Gatsonis, C.A.; Hooft, L.; Irwig, L.; Levine, D.; Reitsma, J.B.; de Vet, H.C.W.; et al. STARD 2015 Guidelines for Reporting Diagnostic Accuracy Studies: Explanation and Elaboration. *BMJ Open* **2016**, *6*, e012799. [CrossRef]
25. Sekhar, D.M.C.; Thabusum, D.D.A.; Firdous, D.P.S. Unfolding The Link: Age Estimation through Comparison of Demirijian and Moore’s Method. *Saudi J. Biomed. Res.* **2019**, *4*, 168–173.
26. Umer, F.; Habib, S.; Adnan, N. Application of Deep Learning in Teeth Identification Tasks on Panoramic Radiographs. *Dentomaxillofac. Radiol.* **2022**, *51*, 20210504. [CrossRef]
27. Akoglu, H. User’s Guide to Sample Size Estimation in Diagnostic Accuracy Studies. *Turk. J. Emerg. Med.* **2022**, *22*, 177–185. [CrossRef]
28. Hicks, S.A.; Strümke, I.; Thambawita, V.; Hammou, M.; Riegler, M.A.; Halvorsen, P.; Parasa, S. On Evaluation Metrics for Medical Applications of Artificial Intelligence. *Sci. Rep.* **2022**, *12*, 5979. [CrossRef] [PubMed]
29. Schoonjans, F. MedCalc Statistical Software. Available online: <https://www.medcalc.org/> (accessed on 14 November 2023).
30. Mohammad-Rahimi, H.; Motamedian, S.R.; Rohban, M.H.; Krois, J.; Uribe, S.E.; Mahmoudinia, E.; Rokhshad, R.; Nadimi, M.; Schwendicke, F. Deep Learning for Caries Detection: A Systematic Review. *J. Dent.* **2022**, *122*, 104115. [CrossRef]
31. Prados-Privado, M.; García Villalón, J.; Martínez-Martínez, C.H.; Ivorra, C.; Prados-Frutos, J.C. Dental Caries Diagnosis and Detection Using Neural Networks: A Systematic Review. *J. Clin. Med.* **2020**, *9*, 3579. [CrossRef]
32. Zhu, J.; Chen, Z.; Zhao, J.; Yu, Y.; Li, X.; Shi, K.; Zhang, F.; Yu, F.; Shi, K.; Sun, Z.; et al. Artificial Intelligence in the Diagnosis of Dental Diseases on Panoramic Radiographs: A Preliminary Study. *BMC Oral Health* **2023**, *23*, 358. [CrossRef]
33. Zadrożny, Ł.; Regulski, P.; Brus-Sawczuk, K.; Czajkowska, M.; Parkanyi, L.; Ganz, S.; Mijiritsky, E. Artificial Intelligence Application in Assessment of Panoramic Radiographs. *Diagnostics* **2022**, *12*, 224. [CrossRef]
34. Ammar, N.; Kühnisch, J. Diagnostic Performance of Artificial Intelligence-Aided Caries Detection on Bitewing Radiographs: A Systematic Review and Meta-Analysis. *Jpn. Dent. Sci. Rev.* **2024**, *60*, 128–136. [CrossRef] [PubMed]
35. Taylor-Weetman, K.; Wake, B.; Hyde, C. Comparison of Panoramic and Bitewing Radiography for the Detection of Dental Caries: A Systematic Review of Diagnostic Tests. In *Database of Abstracts of Reviews of Effects (DARE): Quality-Assessed Reviews*; Centre for Reviews and Dissemination: York, UK, 2002.

36. Hung, K.; Montalvao, C.; Tanaka, R.; Kawai, T.; Bornstein, M.M. The Use and Performance of Artificial Intelligence Applications in Dental and Maxillofacial Radiology: A Systematic Review. *Dentomaxillofac. Radiol.* **2020**, *49*, 20190107. [[CrossRef](#)]
37. Hwang, J.-J.; Jung, Y.-H.; Cho, B.-H.; Heo, M.-S. An Overview of Deep Learning in the Field of Dentistry. *Imaging Sci. Dent.* **2019**, *49*, 1–7. [[CrossRef](#)] [[PubMed](#)]
38. Khanagar, S.B.; Al-eihaideb, A.; Maganur, P.C.; Vishwanathaiah, S.; Patil, S.; Baeshen, H.A.; Sarode, S.C.; Bhandi, S. Developments, Application, and Performance of Artificial Intelligence in Dentistry—A Systematic Review. *J. Dent. Sci.* **2021**, *16*, 508–522. [[CrossRef](#)]
39. Orhan, K.; Aktuna Belgin, C.; Manulis, D.; Golitsyna, M.; Bayrak, S.; Aksoy, S.; Sanders, A.; Önder, M.; Ezhov, M.; Shamshiev, M.; et al. Determining the Reliability of Diagnosis and Treatment Using Artificial Intelligence Software with Panoramic Radiographs. *Imaging Sci. Dent.* **2023**, *53*, 199–208. [[CrossRef](#)]
40. Brady, A.; Laoide, R.Ó.; McCarthy, P.; McDermott, R. Discrepancy and Error in Radiology: Concepts, Causes and Consequences. *Ulst. Med. J.* **2012**, *81*, 3–9.

Disclaimer/Publisher’s Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.



Załącznik nr 1

**Do Procedury postępowania o nadanie stopni
naukowych**

**w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i
Administracji**

OŚWIADCZENIA WSPÓŁAUTORA

Namrowe....., dnia *07.06.2025*.....

Kamila Chęcińska
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afilacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

*Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M.
Applications of Artificial Intelligence in the Analysis of Dental Panoramic
Radiographs: An Overview of Systematic Reviews. Dentomaxillofacial Radiology
2023, 20230284, doi:10.1259/dmfr.20230284*

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie
i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w
dostarczeniu materiałów badawczych i narzędzi analitycznych, udział w opracowaniu
treści manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako
część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów
naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy
wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji,
wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Kamila Chęcińska



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Kraków....., dnia 12.06.2025

Maciej Chęciński
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of Artificial Intelligence in the Analysis of Dental Panoramic Radiographs: An Overview of Systematic Reviews. Dentomaxillofacial Radiology 2023, 20230284, doi:10.1259/dmfr.20230284

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w projektowaniu badania, walidacji metod i wyników, opracowaniu treści manuskryptu, redagowaniu i korekcie manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Maciej Chęciński.....
Czytelny własnoręczny podpis



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

.....KRAKÓW....., dnia11.06.2025.....

Anita Brzozowska
(Imię i nazwisko)

Centrum Medycyny Profilaktycznej
Bolesława Komorowskiego 12, 30-106 Kraków
(Afilacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of Artificial Intelligence in the Analysis of Dental Panoramic Radiographs: An Overview of Systematic Reviews. Dentomaxillofacial Radiology 2023, 20230284, doi:10.1259/dmfr.20230284

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w prowadzeniu badania, opracowaniu danych, opracowaniu treści manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

.....Anita Brzozowska.....
Czytelny własnoręczny podpis



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Glinice....., dnia *9.06.2025*

Zuzanna Szendera (Nowak)
(Imię i nazwisko)

Śląski Uniwersytet Medyczny w Katowicach
Zakład Dysfunkcji Narządu Żucia
Plac Traugutta 2, 41-800 Zabrze
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of Artificial Intelligence in the Analysis of Dental Panoramic Radiographs: An Overview of Systematic Reviews. Dentomaxillofacial Radiology 2023, 20230284, doi:10.1259/dmfr.20230284

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w walidacji metod i wyników, dostarczeniu materiałów badawczych i narzędzi analitycznych, redagowaniu i korekcie manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Zuzanna Szendera

Czytelny własnoręczny podpis



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Kielce, dnia 05.06.2023r.

Maciej Sikora
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Brzozowska, A.; Nowak, Z.; Sikora, M. Applications of Artificial Intelligence in the Analysis of Dental Panoramic Radiographs: An Overview of Systematic Reviews. Dentomaxillofacial Radiology 2023, 20230284, doi:10.1259/dmfr.20230284

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony) mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w projektowaniu badania, udział w redagowaniu i korekcie manuskryptu, nadzór naukowy, zarządzanie projektem.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.


Czytelny własnoręczny podpis



Załącznik nr 1

**Do Procedury postępowania o nadanie stopni
naukowych**

**w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i
Administracji**

OŚWIADCZENIA WSPÓŁAUTORA

N. Ormawie....., dnia *07.06.2025*.....

Kamila Chęcińska
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. Journal of Clinical Medicine 2024, 13, 3686, doi:10.3390/jcm13133686

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w analizie danych badawczych, opracowaniu treści manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Kamila Chęcińska

.....
Czytelny własnoręczny podpis



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Kraków....., dnia *12.06.2025*

Maciej Chęciński
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. Journal of Clinical Medicine 2024, 13, 3686, doi:10.3390/jcm13133686

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w prowadzeniu badania, opracowaniu treści manuskryptu, redagowaniu i korekcie manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Maciej Chęciński.....
Czytelny własnoręczny podpis



Państwowy Instytut
Medyczny MSWiA

ul. Wołoska 137, 02-507 Warszawa

Załącznik nr 1

**Do Procedury postępowania o nadanie stopni
naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i
Administracji**

OŚWIADCZENIA WSPÓŁAUTORA

..... Iwo Rutański, dnia 3 06. 2025
Drobiau

Iwo Rutański
(Imię i nazwisko)

Optident sp. z o.o.
Eugeniusza Kwiatkowskiego 4
52-326 Wrocław
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral
Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental
Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. Journal of Clinical
Medicine 2024, 13, 3686, doi:10.3390/jcm13133686
(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie
i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w
dostarczeniu narzędzi analitycznych, udział w dostarczeniu materiałów badawczych.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako
część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów
naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy
wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji,
wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

..... Iwo Rutański
Czytelny własnoręczny podpis



Załącznik nr 1

**Do Procedury postępowania o nadanie stopni
naukowych**

**w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i
Administracji**

OŚWIADCZENIA WSPÓŁAUTORA

Kielce....., dnia *02.06.2025*

Marcin Sielski
(Imię i nazwisko)

SP ZOZ MSWiA w Kielcach
Wojska Polskiego 51, 25-375 Kielce
(Afilacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. Journal of Clinical Medicine 2024, 13, 3686, doi:10.3390/jcm13133686

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w dostarczeniu materiałów badawczych, udział w opracowaniu danych.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Heaven Helan

Czytelny własnoręczny podpis



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Kielce, dnia 05.06.2025 r.

Maciej Sikora
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

Turosz, N.; Chęcińska, K.; Chęciński, M.; Rutański, I.; Sielski, M.; Sikora, M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. Journal of Clinical Medicine 2024, 13, 3686, doi:10.3390/jcm13133686

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w projektowaniu badania, udział w walidacji metod i wyników, udział w redagowaniu i korekcie manuskryptu, nadzór naukowy, zarządzanie projektem.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.


Czytelny własnoręczny podpis



Załącznik nr 1

**Do Procedury postępowania o nadanie stopni
naukowych**

**w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i
Administracji**

OŚWIADCZENIA WSPÓŁAUTORA

...*Kamila Chęcińska*..., dnia *04.06.2025*...

Kamila Chęcińska
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy

Turosz, N.; Chęcińska, K.; Chęciński, M.; Sielski, M.; Sikora, M. Evaluation of Dental Panoramic Radiographs by Artificial Intelligence Compared to Human Reference: A Diagnostic Accuracy Study. *Journal of Clinical Medicine* 2024, 13, 6859, doi:10.3390/jcm13226859.

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w opracowaniu metod badawczych, dostarczeniu narzędzi analitycznych, analizie danych badawczych, redagowaniu i korekcie manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Kamila Chęcińska



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Kraków, dnia 12.06.2025

Maciej Chęciński
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afilacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Sielski, M.; Sikora, M. Evaluation of Dental Panoramic Radiographs by Artificial Intelligence Compared to Human Reference: A Diagnostic Accuracy Study. *Journal of Clinical Medicine* 2024, 13, 6859, doi:10.3390/jcm13226859.
(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w walidacji metod i wyników, prowadzeniu badania, redagowaniu i korekcie manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Maciej Chęciński
Czytelny własnoręczny podpis



**Państwowy Instytut
Medyczny MSWiA**

ul. Wołoska 137, 02-507 Warszawa

Załącznik nr 1
Do Procedury postępowania o nadanie stopni
naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i
Administracji

OŚWIADCZENIA WSPÓŁAUTORA

....., dnia 02.06.2025

Marcin Sielski
(Imię i nazwisko)

SP ZOZ MSWiA w Kielcach
Wojska Polskiego 51, 25-375 Kielce
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Sielski, M.; Sikora, M. Evaluation of Dental
Panoramic Radiographs by Artificial Intelligence Compared to Human Reference: A
Diagnostic Accuracy Study. *Journal of Clinical Medicine* 2024, 13, 6859,
doi:10.3390/jcm13226859.

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie
i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w
dostarczeniu materiałów badawczych, udział w redagowaniu i korekcie manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako
część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów
naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy
wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji,
wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

.....
Marcin Sielski

Czytelny własnoręczny podpis



Załącznik nr 1

**Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji**

OŚWIADCZENIA WSPÓŁAUTORA

Kulce, dnia *05.06.2024*.

Maciej Sikora
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Sielski, M.; Sikora, M. Evaluation of Dental Panoramic
Radiographs by Artificial Intelligence Compared to Human Reference: A Diagnostic Accuracy
Study. *Journal of Clinical Medicine* 2024, 13, 6859, doi:10.3390/jcm13226859.
(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie
badań oraz przedstawienie pracy w formie publikacji to: udział w projektowaniu badania, udział
w redagowaniu i korekcie manuskryptu, nadzór naukowy, zarządzanie projektem.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część
rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych
opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje
indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części
eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Maciej Sikora
Czytelny własnoręczny podpis



**Państwowy Instytut
Medyczny MSWiA**

ul. Wołoska 137, 02-507 Warszawa

Załącznik nr 1
Do Procedury postępowania o nadanie stopni
naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i
Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Warszawa, dnia 04.06.2015

Kamila Chęcińska
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA ,
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Lubecka, K.; Bliźniak, F.; Sikora, M.
Artificial Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs
(DPRs): A Clinical Study. *Pediatric Reports* 2024, 16, 794–805,
doi:10.3390/pediatric16030067
(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie
i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w
dostarczeniu narzędzi analitycznych, analizie danych badawczych, opracowaniu
treści manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako
część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów
naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy
wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji,
wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Państwowy Instytut Medyczny Ministerstwa Spraw Wewnętrznych i Administracji

ul. Wołoska 137, Warszawa 02-507

REGON 524384845, NIP 521-400-45-58



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Kraków, dnia 12.06.2025

Maciej Chęciński
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Lubecka, K.; Bliźniak, F.; Sikora, M. Artificial Intelligence
(AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical Study. *Pediatric
Reports* 2024, 16, 794–805, doi:10.3390/pediatric16030067
(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie
badań oraz przedstawienie pracy w formie publikacji to: udział w opracowaniu metod
badawczych, analizie danych badawczych, opracowaniu treści manuskryptu, redagowaniu i
korekcie manuskryptu, wizualizacji danych.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część
rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych
opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje
indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części
eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Maciej Chęciński
Czytelny własnoręczny podpis



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

Kraków, dnia 6.06.2025r.

Karolina Lubecka
(Imię i nazwisko)

Centrum Medycyny Profilaktycznej
Bolesława Komorowskiego 12, 30-106 Kraków
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Lubecka, K.; Bliźniak, F.; Sikora, M. Artificial
Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical
Study. *Pediatric Reports* 2024, 16, 794–805, doi:10.3390/pediatric16030067
(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie
badań oraz przedstawienie pracy w formie publikacji to: udział w walidacji metod i wyników,
prowadzeniu badania, opracowaniu treści manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część
rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych
opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje
indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części
eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

Karolina Lubecka
Czytelny własnoręczny podpis



Załącznik nr 1

**Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji**

OŚWIADCZENIA WSPÓŁAUTORA

.....Kraków....., dnia06.06.2025.....

Filip Bliźniak
(Imię i nazwisko)

Szpital Specjalistyczny im. Ludwika Rydygiera
os. Złotej Jesieni 1, 31-826 Kraków
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Lubecka, K.; Bliźniak, F.; Sikora, M. Artificial
Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical
Study. *Pediatric Reports* 2024, 16, 794–805, doi:10.3390/pediatric16030067
(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)
mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie
badań oraz przedstawienie pracy w formie publikacji to: udział w walidacji metod i wyników,
opracowaniu treści manuskryptu, redagowaniu i korekcie manuskryptu.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część
rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych
opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje
indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części
eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

..........
Czytelny własnoręczny podpis



Załącznik nr 1

Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji

OŚWIADCZENIA WSPÓŁAUTORA

.....*Kielce*....., dnia *05.06.2025* r.

Maciej Sikora
(Imię i nazwisko)

Państwowy Instytut Medyczny MSWiA
Wołoska 137, 02-507 Warszawa
(Afiliacja)

OŚWIADCZENIE

Niniejszym oświadczam, że w pracy
Turosz, N.; Chęcińska, K.; Chęciński, M.; Lubecka, K.; Bliźniak, F.; Sikora, M. Artificial Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical Study. *Pediatric Reports* 2024, 16, 794–805, doi:10.3390/pediatric16030067.

(autorzy, rok wydania, tytuł, czasopismo lub wydawca, tom, strony)

mój indywidualny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji to: udział w projektowaniu badania, udział w walidacji metod i wyników, udział w redagowaniu i korekcie manuskryptu, nadzór naukowy, zarządzanie projektem.

Wyrażam zgodę na przedłożenie ww. pracy przez panią Natalię Turosz jako część rozprawy doktorskiej w formie spójnego tematycznie zbioru artykułów naukowych opublikowanych w czasopismach naukowych.

Oświadczam, iż samodzielna i możliwa do wyodrębnienia część ww. pracy wykazuje indywidualny wkład pani Natalii Turosz przy opracowywaniu koncepcji, wykonywaniu części eksperymentalnej, opracowaniu i interpretacji wyników tej pracy.

.....*Maciej Sikora*.....
Czytelny własnoręczny podpis



KOMISJA BIOETYCZNA
PRZY ŚWIĘTOKRZYSKIEJ IZBIE LEKARSKIEJ
25-155 Kielce, Aleja ks. Jerzego Popiełuszki 43
tel.: 41 362 15 40 faks: 41 362 15 00

Uchwała Nr 2.2/2023 – IX
Komisji Bioetycznej
Świętokrzyskiej Izby Lekarskiej w Kielcach
z dnia 31 sierpnia 2023r.

Na podstawie art. 29 ust. 6 ustawy z dnia 05 grudnia 1996 r. o zawodach lekarza i lekarza dentysty (Dz. U. z 2020 r., poz. 514 t.j.) oraz § 13 Rozporządzenia Ministra Zdrowia z dnia 02 lutego 2023r. w sprawie komisji bioetycznej oraz Odwoławczej Komisji Bioetycznej (Dz.U. z 2023r., poz. 218) oraz działając zgodnie z zasadami GCP (Good Clinical Practice), do Komisji Bioetycznej przy Świętokrzyskiej Izbie Lekarskiej w Kielcach wpłynęła prośba o wydanie opinii zgodnie z załączonymi dokumentami do badania pod tytułem:

„Ocena radiogramów stomatologicznych z wykorzystaniem sztucznej inteligencji i przez profesjonalistów medycznych po różnych kompetencjach na potrzeby analizy porównawczej oraz dla celów epidemiologicznych”.

Główni badacze:

1. Lek. dent., inż. Natalia Turosz

NZOZ ARS MEDICA Centrum Stomatologii, Chirurgii Szczękowo-Twarzowej i Implantologii
ul. Zagórska 20 lok.15-16, 25-355 Kielce

2. Dr hab.n.med. Maciej Sikora

Kierownik Oddziału Chirurgii Szczękowo-Twarzowej Szpital MSWiA w Kielcach, im. Jana Pawła II,

ul. Wojska Polskiego 51, 25-375 Kielce

Kierownik NZOZ ARS MEDICA Centrum Stomatologii, Chirurgii Szczękowo-Twarzowej i Implantologii

ul. Zagórska 20 lok.15-16, 25-355 Kielce

Oraz BRODENT Usługi Stomatologiczne i Radiologiczne, ul. Zagórska 20, 25-355 Kielce

Do Komisji wpłynęły następujące dokumenty:

1. List przewodni o wydanie opinii dotyczącej badań medycznych na ludziach z dnia 28 sierpnia 2023r. wraz z opisem badania oraz możliwych korzyści.
2. Protokół Badania.
3. Polisa OC.
4. CV Głównych Badaczy.
5. Lista ośrodków biorących udział w badaniu.
6. Zgoda Kierownika Zakładu.

Komisja Bioetyczna przy Świętokrzyskiej Izbie Lekarskiej w Kielcach w składzie:

- | | |
|--------------------------------------|----------------------------------|
| 1. Dr n. med. Krzysztof Bartosz | <i>Przewodniczący Komisji</i> |
| 2. Dr n.med. Ewa Maroszyńska – Dmoch | <i>Zastępca Przewodniczącego</i> |
| 3. Lek. med. Grażyna Borzęcka | |
| 4. Mgr Zbigniew Kopytek | |
| 5. Mgr Marek Król | |
| 6. Lek. Paweł Pabjan | |
| 7. Dr n. Hum. Ks Artur Skrzypek | |

na posiedzeniu w dniu 31 sierpnia 2023r. zapoznała się z przedstawioną w niniejszym badaniu dokumentacją i w głosowaniu pozytywnie zaopiniowała przedstawione materiały.

Uchwała wchodzi w życie z dniem podjęcia i obowiązuje w okresie trwania ważności polisy ubezpieczeniowej dołączonej do wniosku.

Wydana opinia dotyczy tylko rozpatrywanego wniosku z uwzględnieniem przedstawionego projektu; każda zmiana i modyfikacja wymaga uzyskania odrębnej opinii. Wnioskodawca zobowiązany jest do informowania o wszelkich poprawkach, które mogłyby mieć wpływ na opinię Komisji, o ciężkich lub niespodziewanych zdarzeniach niepożądanych i nieprzewidzianych okolicznościach, o zakończeniu badania, o jego wynikach i istotnych decyzjach innych komisji bioetycznych.

Skład i działanie Komisji Bioetycznej jest zgodne ze Wskazówkami i Zaleceniami dla Europejskich Komisji Etycznych opracowanych przez EFGCP, Zasadami Prawidłowego Prowadzenia Badań Klinicznych (GCP) oraz wymogami lokalnymi.

Przewodniczący Komisji Bioetycznej
Świętokrzyskiej Izby Lekarskiej
Krzysztof Bartosz
dr n.med. Krzysztof Bartosz

Pouczenie:

Zgodnie z art. 29 ust. 1 ustawy z dnia 05 grudnia 1996 r. o zawodach lekarza i lekarza dentysty (Dz. U. z 2022 r., poz. 1731ze zm.) odwołanie od niniejszej uchwały komisji bioetycznej wyrażającej opinie może wnieść:

- 1) Wnioskodawca;
- 2) Kierownik podmiotu, w którym eksperyment medyczny ma być przeprowadzony;
- 3) Komisja bioetyczna właściwa dla ośrodka, który ma uczestniczyć w wieloośrodkowym eksperymencie medycznym.

Odwołanie wnosi się za pośrednictwem komisji bioetycznej, która podjęła uchwałę, do odwoławczej Komisji Bioetycznej, ul. Miodowa 15, 00-952 Warszawa w terminie 14 dni od dnia otrzymania niniejszej uchwały wyrażającej opinie.

Biogram doktoranta

Natalia Turosz urodziła się 7 maja 1995 r. w Krakowie. Uczęszczała do V Liceum Ogólnokształcącego im. Augusta Witkowskiego w Krakowie, które ukończyła z wyróżnieniem. Jest absolwentką dwóch uczelni wyższych: Uniwersytetu Jagiellońskiego, gdzie uzyskała tytuł lekarza dentysty, oraz Akademii Górniczo-Hutniczej, na której zdobyła tytuł inżyniera w dziedzinie informatyki. Została kilkakrotnie wyróżniona stypendium Rektora AGH za wysoką średnią ocen. Staż podyplomowy lekarza dentysty odbyła w Centrum Medycyny Profilaktycznej w Krakowie. W latach 2021-2022 pracowała jako asystent naukowo-dydaktyczny w Zakładzie Promocji Zdrowia i e-Zdrowia Collegium Medicum Uniwersytetu Jagiellońskiego. Równocześnie rozpoczęła pracę kliniczną jako dentysta w zakresie stomatologii zachowawczej z endodoncją. Uczestniczyła w licznych kursach i szkoleniach, stale poszerzając swoją wiedzę teoretyczną i doskonaląc umiejętności praktyczne.

Od 2022 roku prowadzi działalność naukową, koncentrując się głównie na wykorzystaniu sztucznej inteligencji w stomatologii oraz leczeniu zaburzeń skroniowo-żuchwowych. Jest autorem i współautorem 18 artykułów opublikowanych w polskich i zagranicznych czasopismach naukowych o łącznym IF = 49,3, MEiN/MNiSW = 2165, sumarycznej liczbie cytowań = 132 (według Scopus), indeksie Hirscha = 7 (dane na dzień 04.06.2025 r.). Biegle włada językiem angielskim (poziom C1 potwierdzony certyfikatem Certificate in Advanced English).

Obecnie jest w trakcie specjalizacji z protetyki stomatologicznej w Wojewódzkiej Przychodni Stomatologicznej im. Zbigniewa Żaka w Krakowie oraz pracuje na stanowisku asystenta w Państwowym Instytucie Medycznym MSWiA.

Analiza bibliometryczna dorobku naukowego w sprawie nadania stopnia doktora.

Lp.	Rodzaj publikacji	Liczba	IF	Punktacja MEiN/MNiSW
1.	Artykuły w czasopismach posiadających IF	15	49.3	1880
2.	Artykuły w czasopismach nieposiadających IF	3	-	285
Razem		18	49.3	2165

Dane bibliometryczne wg naukowych baz danych na dzień 04.06.2025

1. Baza Web of Science

Liczba cytowań ogółem: 122

Liczba cytowań bez autocytowań: 97


Indeks Hirscha: 7

2. Baza Scopus

Liczba cytowań ogółem: 132

Liczba cytowań bez autocytowań: 107

Indeks Hirscha: 7

dr Katarzyna Pajerska

Dział Nauki PIM MSWiA

Wykaz publikacji naukowych – załącznik do analizy bibliometrycznej w sprawie nadania stopnia doktora.

I Artykuły w czasopismach posiadających IF

1. Sielski M, Chęcińska K, Turosz N, Chęciński M, Sikora M. Single intra-articular administration of injectable platelet-rich fibrin (I-PRF) in alleviating temporomandibular joint pain: A pilot clinical trial. *Dental and Medical Problems* (ISSN 1644-387X), 2025; 62(1):187-192. <https://doi.org/10.17219/dmp/188273>

IF: 2.7

Punktacja ministerialna: 70 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

2. Turosz N, Chęcińska K, Chęciński M, Lubecka K, Bliźniak F, Sikora M. Artificial Intelligence (AI) Assessment of Pediatric Dental Panoramic Radiographs (DPRs): A Clinical Study. *Pediatric Reports* (ISSN 2036-7503), 2024; 16(3):794-805. <https://doi.org/10.3390/pediatric16030067>

IF:1.4

Punktacja ministerialna: 70 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

3. Turosz N, Chęcińska K, Chęciński M, Sielski M, Sikora M. Evaluation of Dental Panoramic Radiographs by Artificial Intelligence Compared to Human Reference: A Diagnostic Accuracy Study. *Journal of Clinical Medicine* (ISSN 2077-0383), 2024; 13(22):6859. <https://doi.org/10.3390/jcm13226859>

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

4. Lubecka K, Chęcińska K, Bliźniak F, Chęciński M, Turosz N, Michcik A, Chlubek D, Sikora M. Intra-Articular Local Anesthetics in Temporomandibular Disorders: A Systematic Review and Meta-

Analysis. *Journal of Clinical Medicine* (ISSN 2077-0383), 2024; 13(1):106.
<https://doi.org/10.3390/jcm13010106>

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

5. Turosz N, Chęcińska K, Chęciński M, Rutański I, Sielski M, Sikora M. Oral Health Status and Treatment Needs Based on Artificial Intelligence (AI) Dental Panoramic Radiograph (DPR) Analysis: A Cross-Sectional Study. *Journal of Clinical Medicine* (ISSN 2077-0383), 2024; 13(13):3686. <https://doi.org/10.3390/jcm13133686>

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

6. Galant K, Turosz N, Chęcińska K, Chęciński M, Cholewa-Kowalska K, Karwan S, Chlubek D, Sikora M. Silver Nanoparticles (AgNPs) Incorporation into Polymethyl Methacrylate (PMMA) for Dental Appliance Fabrication: A Systematic Review and Meta-Analysis of Mechanical Properties. *International Journal of Molecular Sciences* (ISSN 1661-6596), 2024; 25(23):12645. <https://doi.org/10.3390/ijms252312645>

IF: 4.9

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

7. Turosz N, Chęcińska K, Chęciński M, Lubecka K, Bliźniak F, Chlubek D, Olszowski T, Sikora M. Temporomandibular Joint Injections and Lavage: An Overview of Reviews. *Journal of Clinical Medicine* (ISSN 2077-0383), 2024; 13(10), 2855. DOI: 10.3390/jcm13102855

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

8. Chęciński M, Chęcińska K, Bliźniak F, Lubecka K, Turosz N, Rąpalska I, Michcik A, Chlubek D, Sikora M. Temporomandibular Joint (TMJ) Replacement Affects Quality of Life: A Systematic Review and Synthesis of Clinical Trials. *Applied Sciences* (ISSN 2076-3417), 2024; 14(7):2912. <https://doi.org/10.3390/app14072912>

IF: 2.5

Punktacja ministerialna: 100 p.

9. Lubecka K, Chęcińska K, Bliźniak F, Chęciński M, Turosz N, Rąpalska I, Michcik A, Chlubek D, Sikora M. Update on Evidence and Directions in Temporomandibular Joint Injection Techniques: A Rapid Review of Primary Research. *Journal of Clinical Medicine* (ISSN 2077-0383), 2024; 13(14):4022. <https://doi.org/10.3390/jcm13144022>

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

10. Turosz N, Chęcińska K, Chęciński M, Brzozowska A, Nowak Z, Sikora M. Applications of artificial intelligence in the analysis of dental panoramic radiographs: an overview of systematic reviews. *Dentomaxillofacial Radiology* (ISSN 0250-832X), 2023; 52(7):20230284. <https://doi.org/10.1259/dmfr.20230284>

IF: 2.9

Punktacja ministerialna: 100 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

11. Chęciński M, Chęcińska K, Rąpalska I, Turosz N, Chlubek D, Sikora M. Autologous Blood Injections in Temporomandibular Hypermobility: A Systematic Review. *Journal of Clinical Medicine* (ISSN 2077-0383), 2023; 12(17):5590. <https://doi.org/10.3390/jcm12175590>

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

12. Chęciński M, Chęcińska K, Turosz N, Brzozowska A, Chlubek D, Sikora M. Current Clinical Research Directions on Temporomandibular Joint Intra-Articular Injections: A Mapping Review. *Journal of Clinical Medicine* (ISSN 2077-0383), 2023; 12(14):4655. <https://doi.org/10.3390/jcm12144655>

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

13. Chęciński M, Chęcińska K, Turosz N, Sikora M, Chlubek D. Intra-Articular Injections into the Inferior versus Superior Compartment of the Temporomandibular Joint: A Systematic Review and Meta-Analysis. *Journal of Clinical Medicine* (ISSN 2077-0383), 2023; 12(4):1664. <https://doi.org/10.3390/jcm12041664>

IF: 3.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

14. Chęciński M, Chęcińska K, Turosz N, Kamińska M, Nowak Z, Sikora M, Chlubek D. Autologous Stem Cells Transplants in the Treatment of Temporomandibular Joints Disorders: A Systematic Review and Meta-Analysis of Clinical Trials. *Cells* (ISSN 2073-4409), 2022; 11(17):2709. <https://doi.org/10.3390/cells11172709>

IF: 6.0

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

15. Duplaga M, Turosz N. User Satisfaction and the Readiness-to-Use e-Health Applications in the Future in Polish Society in the Early Phase of the COVID-19 Pandemic: A Cross-Sectional Study. *International Journal of Medical Informatics* (ISSN 1386-5056), 2022; 168, 104904, DOI: 10.1016/j.ijmedinf.2022.104904.

IF: 4.9

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

II Artykuły w czasopismach nieposiadających IF

1. Turosz N, Kamińska M, Chęcińska K, Chęciński M. An airgun projectile in the maxillary sinus of an adult: a case report. *NEMESIS. Negative effects in medical sciences oral and maxillofacial surgery* (ISSN 2593-3604), 2024; 34(1), 1–13.

<https://doi.org/10.14428/nemesis.v34i1.82193>

Punktacja ministerialna: 5 p.

Czasopismo w dyscyplinie: nauki medyczne

2. Turosz N, Chęcińska K, Chęciński M, Michcik A, Chlubek D, Sikora M. Adverse events of intra-articular temporomandibular joint injections: a systematic search and review. *Pomeranian Journal of Life Sciences* (ISSN 2450-4637), 2023; 69(4):48-54.

<https://doi.org/10.21164/pomjlifesci.1000>


Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

3. Turosz N, Chęcińska K, Chęciński M, Kamińska M, Nowak Z, Sikora M, Chlubek D. A Scoping Review of the Use of Pioglitazone in the Treatment of Temporo-Mandibular Joint Arthritis. *International Journal of Environmental Research and Public Health* (ISSN 1660-4601), 2022; 19(24):16518. <https://doi.org/10.3390/ijerph192416518>

Punktacja ministerialna: 140 p.

Czasopismo w dyscyplinie: nauki medyczne, nauki o zdrowiu

dr Katarzyna Pajerska

Dział Nauki PIM MSWiA



ul. Wołoska 137, 02-507 Warszawa

**Państwowy Instytut
Medyczny MSWiA**

Załącznik nr 9

**Do Procedury postępowania o nadanie stopni naukowych
w Państwowym Instytucie Medycznym Ministerstwa Spraw Wewnętrznych i Administracji**

Oświadczenie Kandydata o oryginalności rozprawy doktorskiej

Ja, niżej podpisany oświadczam, że:

- 1) rozprawa doktorska pt.:
„Ocena aktualnych możliwości zastosowania sztucznej inteligencji w analizie zdjęć
pantomograficznych”
jest wynikiem mojej działalności twórczej i powstała bez niedozwolonego udziału osób
trzecich,
- 2) wszystkie wykorzystane przeze mnie materiały źródłowe i opracowania zostały w niej
wymienione, a napisana przeze mnie praca nie narusza praw autorskich osób trzecich,
- 3) załączona wersja elektroniczna rozprawa doktorska zapisana na informatycznym nośniku
danych jest tożsama z wydrukiem rozprawy.

Natalia Turon
.....
(czytelny własnoręczny podpis Kandydata)